



**POLITECNICO  
SETÚBAL**

**António Carlos Ferreira  
Pinto**

**Inteligência Artificial para a deteção automática de  
lesões patológicas do cancro da mama**

Melhoria da precisão na deteção de tumores por recurso  
à extração de características em imagens médicas.

Instituto Politécnico de Setúbal

Trabalho de Projeto submetido como requisito parcial  
para obtenção do grau de **Mestre em Engenharia de  
Informática**

**Júri**

*Presidente* - Professor Cláudio Miguel Garcia Loureiro  
dos Santos Sapateiro (ESTSetúbal/IPS)

*Orientador* - Professor Miguel Angel Guevara López  
(ESTSetúbal/IPS))

*Arguente* - Professora Teresa Cristina de Freitas  
Gonçalves (Universidade de Évora)

Dezembro 2024

## **Agradecimentos**

Expresso a minha gratidão às pessoas que generosamente reservaram parte do seu tempo para contribuir e oferecer assistência neste projeto. A colaboração e o apoio recebido foram fundamentais, e expresso a minha sincera gratidão pela valiosa contribuição de cada pessoa mencionada abaixo.

Expresso a minha profunda gratidão ao Dr. Prof. Miguel López, cujo acompanhamento diligente foi essencial durante todo o desenvolvimento do projeto. A sua contribuição foi além da ajuda, incluindo feedback valioso e sugestões construtivas.

Expresso os meus agradecimentos a Javier, administrador do VISION, pela cedência do computador VISION e pela sua assistência crucial na instalação e preparação do ambiente de desenvolvimento, contribuindo significativamente para o desenvolvimento bem-sucedido do projeto.

Também, gostaria de expressar minha gratidão a Yusbel Castilla, cuja ajuda foi fundamental na integração dos dados provenientes do pré-processamento, contribuindo para a integração do projeto.

## Resumo

O cancro da mama é a doença maligna mais comum entre as mulheres, ultrapassando o cancro do pulmão com 11,7% dos casos [1]. A deteção precoce é crucial, uma vez que a doença é frequentemente assintomática nas suas fases iniciais. Embora a Ressonância Magnética (MRI) forneça imagens de alta qualidade essenciais para uma deteção precisa e demonstre um desempenho superior na deteção de lesões, com uma taxa de 30% a 40% maior do que a mamografia, a sua adoção para a deteção precoce ainda é limitada devido à complexidade e aos custos elevados (Saeed et al., 2022). Em vez disso, a mamografia é preferida por ser significativamente mais económica e fácil de utilizar. No entanto, as imagens de MRI continuam a ser valiosas para a investigação e para futuros avanços, podendo tornar-se mais acessíveis e viáveis para fins de diagnóstico ao longo do tempo. O principal objetivo deste projeto de tese de mestrado é desenvolver algoritmos e métodos, com base em técnicas de inteligência artificial emergentes, para melhorar a deteção (anotação) automática de lesões patológicas de cancro da mama, nomeadamente, modelos de *machine learning* / *deep learning* (ML/DL) treinados com imagens de ressonância magnética e os metadados associados. A anotação manual por médicos especialistas é morosa e difícil devido ao elevado volume de imagens e às complexidades da identificação e categorização dos tumores. Nesse sentido, é uma contribuição deste trabalho o desenvolvimento de um método que permite na fase de pré-processamento, de forma automática, ajustar o *boundingbox* das lesões anotadas. Com isto, é possível melhorar o desempenho / precisão dos modelos de ML/DL. Ao propor um conjunto de dados refinados resultante do pré-processamento, a qualidade dos dados é melhorada para além do que foi anotado manualmente. Os algoritmos desenvolvidos extraem características críticas das imagens médicas, melhorando a precisão e a robustez dos modelos de aprendizagem automática. As técnicas avançadas de extração de características foram fundamentais neste projeto, tirando partido das anotações de especialistas para representar melhor o tecido tumoral. Isto resultou em modelos mais precisos, alcançando uma precisão média de 84,9%, com instâncias que atingiram 90,2%. Os resultados bem-sucedidos do projeto sugerem um avanço significativo na deteção automática do cancro da mama, reduzindo potencialmente as taxas de mortalidade e enriquecendo o conjunto de dados para investigação futura.

**Palavras-chave:** Cancro da mama, Inteligência artificial, Deteção precoce, Ressonância magnética, Pré-processamento, Ajuste de anotações, Extração de características, Aprendizagem automática.

# Abstract

Breast cancer is the most common malignancy among women, surpassing lung cancer with 11.7% of cases [1]. Early detection is crucial, as the disease is often asymptomatic in its early stages. Although Magnetic Resonance Imaging (MRI) provides high-quality images essential for accurate detection and demonstrates superior performance in detecting lesions, with a 30% to 40% higher rate than mammography, its adoption for early detection is still limited due to complexity and high costs (Saeed et al., 2022). Instead, mammography is preferred because it is significantly cheaper and easier to use. However, MRI images remain valuable for research and future advances, and may become more accessible and viable for diagnostic purposes over time. The main objective of this master's thesis project is to develop algorithms and methods, based on emerging artificial intelligence techniques, to improve the automatic detection (annotation) of pathological breast cancer lesions, namely *machine learning* / *deep learning* (ML/DL) models trained with MRI images and the associated metadata. Manual annotation by medical specialists is time-consuming and difficult due to the high volume of images and the complexities of identifying and categorizing tumours. With this in mind, the contribution of this work is the development of a method that allows the bounding box of annotated lesions to be automatically adjusted in the pre-processing phase. This will improve the performance/accuracy of ML/DL models. By proposing a refined data set resulting from pre-processing, the quality of the data is improved beyond what was manually annotated. The algorithms developed extract critical features from medical images, improving the accuracy and robustness of machine learning models. Advanced feature extraction techniques were key in this project, taking advantage of expert annotations to better represent tumour tissue. This resulted in more accurate models, achieving an average accuracy of 84.9%, with instances reaching 90.2%. The successful results of the project suggest a significant advance in the automatic detection of breast cancer, potentially reducing mortality rates and enriching the dataset for future research.

Keywords: Breast cancer, Artificial intelligence, Early detection, Magnetic resonance imaging, Pre-processing, Annotation adjustment, Feature extraction, Machine learning.

# Índice

|                                                                       |           |
|-----------------------------------------------------------------------|-----------|
| <b>Agradecimentos .....</b>                                           | <b>2</b>  |
| <b>Resumo .....</b>                                                   | <b>3</b>  |
| <b>Abstract .....</b>                                                 | <b>4</b>  |
| <b>Índice .....</b>                                                   | <b>5</b>  |
| <b>Lista de Figuras .....</b>                                         | <b>8</b>  |
| <b>Lista de Tabelas .....</b>                                         | <b>10</b> |
| <b>Glossário .....</b>                                                | <b>12</b> |
| <b>Lista de Siglas e Acrónimos .....</b>                              | <b>16</b> |
| <b>Capítulo 1 .....</b>                                               | <b>17</b> |
| <b>Introdução .....</b>                                               | <b>17</b> |
| <b>1.1. Contexto e Motivação .....</b>                                | <b>17</b> |
| <b>1.2. Descrição do Problema .....</b>                               | <b>18</b> |
| <b>1.3. Objetivos .....</b>                                           | <b>19</b> |
| <b>1.4. Metodologia .....</b>                                         | <b>19</b> |
| 1.4.1. Metodologia S.M.A.R.T. ....                                    | 19        |
| 1.4.2. Metodologia de trabalho .....                                  | 20        |
| 1.4.3. Framework de desenvolvimento .....                             | 21        |
| <b>1.5. Organização do Documento .....</b>                            | <b>22</b> |
| <b>1.6. Gráfico Gantt .....</b>                                       | <b>23</b> |
| <b>1.7. Contribuições Técnico-Científicas .....</b>                   | <b>24</b> |
| <b>Capítulo 2 .....</b>                                               | <b>25</b> |
| <b>Enquadramento Teórico .....</b>                                    | <b>25</b> |
| <b>2.1. Uso de Imagens Médicas na deteção do cancro da mama .....</b> | <b>25</b> |
| 2.1.1. Imagens médicas .....                                          | 25        |
| 2.1.2. Cancro da Mama .....                                           | 26        |
| 2.1.3. Métodos de Diagnóstico do Cancro da Mama e Tratamentos .....   | 27        |
| 2.1.4. Sumário .....                                                  | 30        |
| <b>2.2. Inteligência Artificial e Redes Neurais .....</b>             | <b>30</b> |
| 2.2.1. Introdução à Inteligência Artificial .....                     | 30        |
| 2.2.2. Redes Neurais Artificiais (ANNs) .....                         | 30        |
| 2.2.3. Seleção e Extração de Características .....                    | 36        |

|                                                                                     |           |
|-------------------------------------------------------------------------------------|-----------|
| <b>2.3. Visão por Computador e Detecção de Objetos .....</b>                        | <b>36</b> |
| 2.3.1. <i>Introdução .....</i>                                                      | 36        |
| 2.3.2. <i>Detecção de objetos .....</i>                                             | 38        |
| 2.3.3. <i>Segmentação de Imagens .....</i>                                          | 40        |
| <b>2.4. Redes Neurais Convolucionais (CNN).....</b>                                 | <b>41</b> |
| 2.4.1. <i>Introdução às redes neurais baseadas em regiões.....</i>                  | 41        |
| 2.4.2. <i>Operações Fundamentais das CNNs.....</i>                                  | 42        |
| 2.4.3. <i>RCNNs.....</i>                                                            | 46        |
| 2.4.4. <i>Métricas.....</i>                                                         | 49        |
| <b>Capítulo 3 .....</b>                                                             | <b>51</b> |
| <b>Materiais e Métodos .....</b>                                                    | <b>51</b> |
| <b>3.1. Dataset .....</b>                                                           | <b>51</b> |
| 3.1.1. <i>Observação Detalhada de Características .....</i>                         | 51        |
| 3.1.2. <i>Análise critica.....</i>                                                  | 54        |
| <b>3.2. Algoritmos e métodos propostos .....</b>                                    | <b>56</b> |
| 3.2.1. <i>Detecção da slice com a maior pronúncia do tumor .....</i>                | 56        |
| 3.2.2. <i>Funções de escala da anotação com recurso á intensidade do sinal.....</i> | 58        |
| 3.2.3. <i>Redimensionamento das slices .....</i>                                    | 65        |
| 3.2.4. <i>Detecção dos centroides.....</i>                                          | 66        |
| <b>3.3. Implementação.....</b>                                                      | <b>68</b> |
| 3.3.1. <i>Linguagem de implementação.....</i>                                       | 69        |
| 3.3.2. <i>Frameworks Python para Aprendizagem Máquina .....</i>                     | 71        |
| 3.3.3. <i>Script de Pré-processamento.....</i>                                      | 72        |
| 3.3.4. <i>Resultados do pré-processamento.....</i>                                  | 75        |
| <b>Capítulo 4 .....</b>                                                             | <b>77</b> |
| <b>Resultados .....</b>                                                             | <b>77</b> |
| <b>4.1. Dados de treino, teste e validação .....</b>                                | <b>77</b> |
| <b>4.2. Modelos pré-treinados.....</b>                                              | <b>79</b> |
| <b>4.3. Parâmetros de treino .....</b>                                              | <b>79</b> |
| 4.3.1. <i>Hiperparâmetros e aprendizagem.....</i>                                   | 79        |
| 4.3.2. <i>Taxa de aprendizagem.....</i>                                             | 80        |
| 4.3.3. <i>Data Augmentation.....</i>                                                | 81        |
| <b>4.4. Treino dos modelos.....</b>                                                 | <b>81</b> |
| <b>4.5. Resultados .....</b>                                                        | <b>82</b> |

|                                                                                  |           |
|----------------------------------------------------------------------------------|-----------|
| <b>4.6. Validação de Resultados .....</b>                                        | <b>84</b> |
| <b>Capítulo 5 .....</b>                                                          | <b>89</b> |
| <b>Conclusão e desenvolvimentos futuros .....</b>                                | <b>89</b> |
| <b>5.1. Conclusão .....</b>                                                      | <b>89</b> |
| <i>5.1.1. Extração de Características e Melhoria da Precisão do Modelo .....</i> | <i>90</i> |
| <i>5.1.2. Ferramenta de previsão e anonimização .....</i>                        | <i>90</i> |
| <b>5.2. Limitações do projeto.....</b>                                           | <b>91</b> |
| <b>5.3. Futuros desenvolvimentos.....</b>                                        | <b>93</b> |
| <i>5.3.1. Utilização de modelos específicos ou personalizados.....</i>           | <i>93</i> |
| <i>5.3.2. Criação de um novo dataset.....</i>                                    | <i>95</i> |
| <b>Referências Bibliográficas .....</b>                                          | <b>96</b> |



## Lista de Figuras

|                                                                                                                                                                                                                                                                   |    |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 1 – Metodologia de trabalho adotada. ....                                                                                                                                                                                                                  | 21 |
| Figura 2 - Fluxo de trabalho de alto nível da framework de trabalho utilizada.<br>[Retirado de [3] ] .....                                                                                                                                                        | 22 |
| Figura 3 - Gráfico Gantt do desenvolvimento do projeto [onlinegantt.com/#/gantt].<br>.....                                                                                                                                                                        | 24 |
| Figura 4 – Diversas imagens médicas com diferentes modalidades. ....                                                                                                                                                                                              | 29 |
| Figura 5 - Camadas de rede neuronal artificial [Retirado de [19]]. ....                                                                                                                                                                                           | 32 |
| Figura 6 – Funções de ativação em ANNs. ....                                                                                                                                                                                                                      | 33 |
| Figura 7 – Aplicação da função Softmax na camada de saída para a obtenção das<br>probabilidades de decisão. ....                                                                                                                                                  | 34 |
| Figura 8 – Exemplos de função de perda de acordo com o tipo de previsão [Retirado<br>de [20]]. ....                                                                                                                                                               | 35 |
| Figura 9 - Exemplar da Base de dados MNIST .....                                                                                                                                                                                                                  | 38 |
| Figura 10 – Exemplo de cálculo de um mapa de características com recurso a<br>convoluções. ....                                                                                                                                                                   | 43 |
| Figura 11 – Arquitetura AlexNet demonstrando as operações de convolução,<br>pooling e camadas densas. [Retirado de<br><a href="https://en.wikipedia.org/wiki/Convolutional_neural_network">https://en.wikipedia.org/wiki/Convolutional_neural_network</a> ] ..... | 45 |
| Figura 12 - Arquitetura de alto nível do Faster R-CNN [37] .....                                                                                                                                                                                                  | 48 |
| Figura 13 - Ilustração do esquema de anotação 3D compreendido por anotações 2D<br>e pelo número de <i>slices</i> . Retirado de [3]. ....                                                                                                                          | 52 |
| Figura 14 - Fatias com diferentes sinais de ruído com a mesma intensidade de sinal<br>Total. ....                                                                                                                                                                 | 57 |
| Figura 15 - Alisamento de três pontos pela função circular comparado com pesos<br>originais ( $k = 5$ , $n = 11$ ). ....                                                                                                                                          | 60 |
| Figura 16 - Alisamento de três pontos pela função circular comparado com pesos<br>originais ( $k = 8$ , $n = 11$ ). ....                                                                                                                                          | 61 |
| Figura 17 - Alisamento de três pontos pela função quadrática comparado com pesos<br>originais ( $k = 5$ , $n = 11$ ). ....                                                                                                                                        | 62 |
| Figura 18 - Alisamento de três pontos pela função quadrática comparado com pesos<br>originais ( $k = 8$ , $n = 11$ ). ....                                                                                                                                        | 63 |

|                                                                                                                                  |    |
|----------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 19 - Resultado da normalização da intensidade do sinal no paciente 229 ( $k = 7, n = 20$ ). .....                         | 64 |
| Figura 20 - Redimensionamento da anotação de uma <i>slice</i> .....                                                              | 65 |
| Figura 21 – Centro do centroide demarcado por círculo de raio de 5 pixéis e contorno do tumor detetado pela biblioteca cv2. .... | 67 |
| Figura 22 – Fluxo do script de pré processamento.....                                                                            | 73 |
| Figura 23 - Disposição espacial das anotações antes e depois do processamento. ....                                              | 76 |
| Figura 24 – Taxa de aprendizagem ao longo dos steps com a função de aprendizagem Decaimento de cosseno aproximando um mínimo..   | 80 |
| Figura 25 – TensorBoard e métricas em ao longo do tempo do treino do modelo                                                      | 82 |
| Figura 26 – Esquematização de 10-Fold Cross Validation. Retirado de [3] .....                                                    | 84 |
| Figura 27 – Ferramenta de previsão e anotação de tecido tumoral. ....                                                            | 91 |
| Figura 28 – Exemplo de aplicação do algoritmo teorizado via anotações máscara. ....                                              | 94 |

## Lista de Tabelas

|                                                                                                                                                                                                         |     |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Tabela 1 – Estrutura da tabela com as de anotações de cada paciente. ....                                                                                                                               | 52  |
| Tabela 2 - Número de casos por modelo e fabricante de ressonância magnética<br>ordenado por número de casos. Retirado de [3] e adaptado. ....                                                           | 53  |
| Tabela 3 - Resolução das imagens e número de casos .....                                                                                                                                                | 54  |
| Tabela 4 – Repartição das imagens e pacientes com um rácio de treino de 80% e<br>rácio de teste e validação de 20%, 10% para cada um respetivamente.<br>[Retirada de Anexo III]. ....                   | 75  |
| Tabela 5 – Comparação dos datasets Original, KeepHalf e<br>ImageAnnotationEnhanced. [Retirada de Anexo III]. ....                                                                                       | 78  |
| Tabela 6 – Hiperparâmetros e características de treino. [Retirada de Anexo III].                                                                                                                        | 80  |
| Tabela 7 - Especificações do sistema VISION com CPUs, GPUs e detalhes de<br>memória pertencente ao VISTA Lab, Centro de Investigação da<br>Universidade de Évora, Portugal.....                         | 81  |
| Tabela 8 - Resultados do treino dos modelos de cada algoritmo (Anexo III). ....                                                                                                                         | 83  |
| Tabela 9 – Cross Validation de cada 10-fold. ....                                                                                                                                                       | 85  |
| Tabela 10 – Comparação de desempenho de múltiplos algoritmos em diferentes<br>conjuntos de dados. ....                                                                                                  | 86  |
| Tabela 11 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da deteção de imagens do dataset original. ....                                                                | 1 - |
| Tabela 12 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da deteção de imagens do dataset que fez uso do<br>algoritmo KeepHalf.....                                     | 3 - |
| Tabela 13 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da deteção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced. ....                     | 5 - |
| Tabela 14 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da deteção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced, referente a fold 1. .... | 1 - |
| Tabela 15 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da deteção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced, referente a fold 2. .... | 3 - |

|                                                                                                                                                                                                           |      |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------|
| Tabela 16 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da detecção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced, referente a fold 3. ....  | 5 -  |
| Tabela 17 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da detecção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced, referente a fold 4. ....  | 7 -  |
| Tabela 18 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da detecção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced, referente a fold 5. ....  | 9 -  |
| Tabela 19 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da detecção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced, referente a fold 6. ....  | 11 - |
| Tabela 20 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da detecção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced, referente a fold 7. ....  | 13 - |
| Tabela 21 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da detecção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced, referente a fold 8. ....  | 15 - |
| Tabela 22 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da detecção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced, referente a fold 9. ....  | 17 - |
| Tabela 23 - Médias e Máximos de Iou e Score de cada paciente de validação<br>proveniente da detecção de imagens do dataset que fez uso do<br>algoritmo ImageAnnotationEnhanced, referente a fold 10. .... | 19 - |

## Glossário

[A]

- API – É um conjunto de regras e definições que permite a interação entre diferentes softwares. Esta facilita a comunicação e partilha de dados entre sistemas distintos possibilitando a integração de funcionalidades de maneira eficiente.
- Aprendizagem Máquina / Machine Learning – É um campo da Inteligência Artificial que se concentra no desenvolvimento de algoritmos capazes de aprender padrões a partir de dados, permitindo que os sistemas automatizem tarefas.
- Annotation Boxes – É a representação visual de uma área específica de uma imagem ou conjunto de dados, usada para identificar e descrever objetos ou regiões de interesse, geralmente categorizados.

[B]

[C]

- Clustering – É uma técnica de análise de dados que agrupa objetos similares em clusters ou grupos.

[D]

- Data Augmentation – É o processo de aumentar a quantidade de dados disponíveis para o treino de um modelo, aplicando técnicas como rotação, inversão de orientação, mudança de escala e outras transformações aos dados originais, com finalidade de melhorar a generalização e o desempenho do modelo.
- Dataset – É uma coleção organizada de informações, geralmente representando observações ou eventos relacionados, utilizado para treinar e avaliar modelos em tarefas e aprendizagem máquina e análise estatística.
- Deep Learning – É uma subárea da aprendizagem máquina que utiliza redes neurais artificiais com múltiplas camadas para aprender representações complexas de dados.
- DICOM – É um padrão internacional que define formatos e protocolos para a troca de informações em imagens médicas, promovendo a interoperabilidade entre

dispositivos e facilitando a gestão de dados no ambiente da saúde.

[E]

[F]

- Feature – É uma propriedade ou característica mensurável dos dados utilizada como entrada de um modelo com o propósito de o treinar para fazer previsões ou classificações.
- Framework – É um conjunto estruturado de ferramentas, bibliotecas e convenções que oferecem apoio para o desenvolvimento de software, facilitando a criação e implementação de aplicações.

[G]

[H]

[I]

- Inteligência Artificial – É um campo da ciência da computação que procura desenvolver sistemas capazes de realizar tarefas que normalmente exigiriam inteligência humana, como aprendizagem, raciocínio e reconhecimento de padrões.

[J]

[K]

[L]

[M]

[N]

[O]

[P]

- PyTorch – É uma framework de aprendizagem máquina de código aberto que facilita a criação e treino de modelos de redes neurais.
- Python – É uma linguagem de programação de alto nível, versátil e de fácil leitura, amplamente utilizada em diversas áreas.

[Q]

[R]

- Rede neuronal – É um modelo computacional inspirado no cérebro humano, composto por tensores.

[S]

- Script – É um conjunto de instruções ou comandos escritos numa linguagem de programação que define uma sequência de ações a serem executadas por um computador ou outro dispositivo automatizado.
- Segmentação de instâncias – É uma tarefa de visão por computador que envolve a identificação e rotulação individual de objetos específicos de uma imagem, atribuindo uma etiqueta única a cada instância de objeto presente na cena.
- Slice – É uma fina seleção de uma imagem tridimensional obtida por meio de ressonância magnética ou outro tipo de mecanismo que proporcione imagens 3D, proporcionando uma visualização detalhada de objetos tridimensionais.
- Step - Uma única atualização dos parâmetros do modelo, referente a uma execução de *Front Propagation*, uma *Back Propagation* e uma atualização de parâmetros.
- Stride - Refere-se ao número de pixels que um filtro se move pela entrada durante a operação de convolução numa rede neuronal de convolução.

[T]

- Tensor – É uma estrutura de dados fundamental para a aprendizagem máquina. Estrutura base em redes neurais que procuram mimicar o funcionamento de neurónios, armazenando dados processados em várias camadas.
- Tensorflow – É uma framework de código aberto desenvolvido pela Google que facilita a criação e treino de modelos de aprendizagem máquina e Deep Learning.
- Thread – É uma sequência contínua de instruções de código que pode ser executada de forma independente, compartilhando recursos e contexto com outras threads no mesmo processo.

[U]

[V]

- Visão por computador – É um campo da Inteligência Artificial que capacita os sistemas a interpretar e compreenderem informações visuais a partir de imagens ou vídeos.

[W]

[X]

[Y]

[Z]



## Lista de Siglas e Acrónimos

|       |                                                                           |
|-------|---------------------------------------------------------------------------|
| AI    | Artificial Intelligence (Inteligência Artificial)                         |
| ANN   | Artificial Neural Network (Rede Neuronal Artificial)                      |
| API   | Application Programming Interface (Interface de Programação de Aplicação) |
| BP    | Back Propagation (Retro Propagação)                                       |
| CNN   | Convolution Neural Network (Redes Neurais Convolucionais)                 |
| CT    | Computed Tomography (Tomografia Computadorizada)                          |
| DICOM | Digital Imaging and Communications in Medicine                            |
| DL    | Deep Learning (Aprendizagem Profunda)                                     |
| DNN   | Deep Neural Network (Rede Neuronal Profunda)                              |
| FP    | Forward Propagation (Propagação de Frente)                                |
| GPU   | Graphics Processing Unit (Unidade de Processamento Gráfico)               |
| GD    | Gradient Descent (Gradiente Descendente)                                  |
| IOU   | Intersection over Union (Interseção sobre União)                          |
| MRI   | Magnetic Resonance Imaging (Ressonância Magnética)                        |
| OCR   | Optical Character Recognition (Reconhecimento ótico de caracteres)        |
| PCA   | Principal Component Analysis (Análise de componentes principais)          |
| PET   | Positron Emission Tomography (Tomografia por emissão de pósitrons)        |
| RPN   | Region Proposal Network (Rede de propostas regionais)                     |
| TPU   | Tensor Processing Unit (Unidade de Processamento de Tensores)             |

# Capítulo 1

## Introdução

Neste capítulo introdutório, são abordados os elementos essenciais que fornecerão uma compreensão abrangente do estudo realizado. Expor-se-á o contexto e motivação por detrás do projeto, destacando a relevância de explorar o tema em questão. De seguida, é descrito de forma detalhada o problema abordado, proporcionando uma visão clara da proposta de solução desenvolvida. A secção seguinte traz uma revisão do estado da arte relativo à Inteligência Artificial na deteção de objetos e ao estado da arte no espectro das imagens médicas para a deteção do cancro da mama.

Os objetivos deste estudo são delineados de forma clara e específica, seguindo abordagens de definição e estabelecimento de objetivos como a abordagem S.M.A.R.T - “Específico, Mensurável, Alcançável, Relevante e Temporal”, que garantirá a definição de metas e consequentemente o cumprimento de prazos com maior facilidade e permite a avaliação do progresso ao longo do projeto, adicionalmente é apresentada a metodologia utilizada para conduzir as técnicas de desenvolvimento, extração de resultados e iteração de parâmetros conforme os produtos.

Por fim, é estabelecida uma estrutura organizacional para o documento, delineando os capítulos que guiarão o leitor para a compreensão do conteúdo, além da definição dos prazos de execução do projeto através de um gráfico GANT.

### 1.1. Contexto e Motivação

O cancro da mama é a doença maligna mais comum nas mulheres, ultrapassando recentemente o cancro pulmonar, que perfaz um total de 11,4% dos diagnósticos de cancro comparado com 11.7% dos casos de cancro da mama. Esta é caracterizada por ser assintomática nos primeiros estágios da doença, o que pode levar a uma deteção tardia da mesma [1].

Este tipo de cancro é mais comum em mulheres com a idade compreendida entre os 59 e os 69 com variados estudos a demonstrar a importância na realização de exames para a deteção prematura do cancro da mama [2]. As realizações destes exames, e a consequente deteção prévia do cancro da mama, resulta num aumento da taxa de

sobrevivência dos pacientes. Estes autores afirmam também que a análise de imagens por Imagem Ressonância Magnética (MRI), imagens médicas de escala cinzenta, apresentam a melhor qualidade de imagem e a forma mais segura de identificação do cancro da mama, mas ainda assim não é o procedimento médico mais utilizado para as deteções. De acordo com a mesma fonte, existem vários tipos de tecidos presentes na mama. O tecido com mais gordura é retratado na escala de cinza com valores mais baixos, apresentando uma coloração mais escura nas imagens médicas. Em contraste, os tecidos mais densos apresentam áreas de intensidade variada, dependendo das características específicas do tecido, resultando numa aparência mais clara nas imagens. O tecido com maior quantidade de gordura é menos denso, o que facilita a deteção do cancro, já que o tecido cancerígeno possui uma densidade superior aos tecidos circundantes e, portanto, aparece mais claro nas imagens. Com base no projeto anterior, foi desenvolvendo um método inovador que de forma automática analisa as anotações (manuais) feitas, em particular aquelas com baixa fidelidade de representação do tumor, nomeadamente, onde o tumor ocupa uma porção muito pequena do *bounding box* que identifica uma (possível) lesão patológica, adaptando-as para ajustar e representar com maior fidelidade o tecido tumoral de modo a criar um *benchmarking dataset* com maior nível de detalhe nas anotações e subsequentemente, uma ferramenta de previsão automática e de anotação de possíveis lesões patológicas do cancro da mama.

## 1.2. Descrição do Problema

O problema que visa solução é a deteção automática de possíveis lesões patológicas do cancro da mama, em pacientes não diagnosticados. Para o desenvolvimento de um modelo que procura automatizar o processo de deteção do cancro da mama é necessário recolher casos de pacientes com resultados / provas de biopsia (positivas) e anotar manualmente nas imagens a localização de lesões patológicas, geralmente é selecionada uma área (retângulo) na imagem que representa a parte do tecido em que se enquadra a lesão (conhecido também como *bounding box*) e categorizar/classificar os mesmos. Isto é um problema que os especialistas médicos (e.g., radiologistas, oncologistas) na área do cancro da mama enfrentam, pois é um procedimento moroso devido à quantidade elevada de imagens a serem analisadas, e a demora associada à delimitação da anotação mais o esforço de identificação e deteção de tecido tumoral de forma manual.

Neste projeto é proposta a utilização de um conjunto de dados mais exíguo ao original, fruto do resultado de um processo de pré-processamento automático que visa a criação de anotações com maior qualidade de informação a partir das anotações anteriormente propostas por médicos especialistas visto que as mesmas foram anotadas com precisão em apenas uma fatia da imagem devido á complexidade que envolve anotar cada deteção em cada imagem, problema este que se incrementa quando é preciso anotar casos de pacientes com estudos de imagens de ressonância magnética. Diminuir o tempo de anotação dos médicos especialistas e aumentar a qualidade do conjunto de dados (*dataset* de benchmarking) utilizados para alimentar os modelos de ML/DL é essencial para o sucesso da deteção automática do cancro da mama.

### **1.3. Objetivos**

A realização deste projeto tem como finalidade a criação de um framework, que com recurso a modelos de ML/DL capaz de detetar de forma automática e com maior precisão a localização de possíveis lesões patológicas em casos de pacientes com exames realizados de MRI, ainda não diagnosticados. Para esta finalidade, a abordagem empregue pretende fazer uso de conjuntos de dados com anotações pré-existentes (*datasets* de benchmarking), utilizando as anotações e extraindo caraterísticas nas imagens médicas de maneira a enriquecer a qualidade das características originais.

### **1.4. Metodologia**

Compreende-se pela metodologia utilizada, os procedimentos, estratégias e ferramentas na conceção deste trabalho. A metodologia de trabalho desempenha um papel fundamental, sendo vital de modo a garantir o sucesso, eficiência e consistência do projeto, para além de assegurar a qualidade final e o cumprimento dos prazos estabelecidos.

#### *1.4.1. Metodologia S.M.A.R.T.*

A metodologia S.M.A.R.T. é uma abordagem utilizada para definir e estabelecer metas de forma eficaz. O acrónimo S.M.A.R.T. significa que os objetivos devem ser

específicos, mensuráveis, atingíveis, relevantes e que respeitem um espaço temporal. Esta metodologia é amplamente utilizada na gestão de projetos, negócios, entre outros... pois ajuda a garantir que as metas sejam claras, realistas e realizáveis dentro de um período determinado.

Aplicando assim a metodologia S.M.A.R.T. temos que o objetivo da realização deste projeto é desenvolver uma **solução automática para a detecção do cancro da mama**, com recurso á Inteligência Artificial. O projeto procura afetar positivamente a comunidade ao **fornecer uma forma de detecção do cancro da mama automática**, sendo possível através da **melhoraria da precisão da detecção do modelo anteriormente desenvolvido até ao final do ano 2024**, estabelecendo a meta mensurável de **atingir uma precisão acima de 73,1%**, valor este que provém da melhor precisão obtida de um modelo em condições similares.

#### *1.4.2. Metodologia de trabalho*

A metodologia adotada é iniciada com a identificação do problema em questão, sendo realizada uma análise inicial dos artefactos disponíveis e estado da arte, procurando compreender a natureza do problema a ser solucionado.

Após esta análise preliminar, são conjeturadas diversas hipóteses que, por sua vez, apresentam uma fundamentação teórica. Esta etapa de conceção de hipóteses é seguida pela filtragem das mesmas, na qual são descartadas as menos viáveis ou as que apresentam uma baixa possibilidade de execução. O objetivo é seleccionar as hipóteses mais promissoras e viáveis para a implementação prática que permitam obter os melhores resultados possíveis. Essas hipóteses são posteriormente submetidas a testes, através da avaliação de resultados.

Subsequentemente este processo envolve a validação de resultados e ajustes na implementação para melhorar o algoritmo, em termos de eficiência e precisão. Este ciclo iterativo recomeça a partir do passo de implementação prática, permitindo uma análise contínua dos resultados, como ilustra a Figura 1 metodologia de trabalho descrita anteriormente, destacando cada passo iterativo tomado na conceção deste projeto.




Figura 1 – Metodologia de trabalho adotada.

#### 1.4.3. Framework de desenvolvimento

A Figura 2 demonstra o fluxo de trabalho de alto nível utilizado na avaliação e validação de resultados, conforme proposto pela framework de [3], que se inspira no fluxo natural de treino de modelos com a framework Tensorflow adicionando uma primeira fase de pré-processamento.

Este processo é iniciado pelo pré-processamento das imagens na sua forma original. Durante o pré-processamento, são lidas configurações de processamento de um ficheiro com a extensão “.ini”, (abordado em maior detalhe no subcapítulo 3.3.3). Os dados resultantes do pré-processamento são divididos em sets de imagens processadas. Um dos sets será utilizado para treinar o modelo de deteção (training set), e os restantes servirão para avaliar e validar a performance do modelo (test set, validation set). O treino dos dados resulta na criação de um modelo que será avaliado e comparado com outros modelos gerados no processo cíclico descrito anteriormente da metodologia utilizada, de forma a seleccionar as melhores configurações e seleccionar o modelo mais apto para a deteção do tecido tumoral.




Figura 2 - Fluxo de trabalho de alto nível da framework de trabalho utilizada. [Retirado de [3] ]

Em suma, as metodologias e as *frameworks* adotadas devem servir como guia estruturado que direciona o desenvolvimento do trabalho, contribuindo significativamente para alcançar os objetivos de forma eficaz respeitando os parâmetros definidos.

## 1.5. Organização do Documento

O primeiro capítulo expõe o tema principal do projeto, discutindo o problema a ser abordado, as metodologias empregues e os objetivos esperados. Além disso, oferece uma visão geral sobre o desenvolvimento do trabalho, incluindo o cronograma de execução, as atividades realizadas e as principais contribuições técnico-científicas obtidas ao longo do processo.

O segundo capítulo é dedicado a fornecer ao leitor um enquadramento teórico das questões em análise. Conceitos mais complexos são abordados de maneira a contextualizar o leitor sobre a matéria em capítulos futuros. Os temas discutidos incluem métodos de diagnóstico por meio de imagens médicas, cancro da mama, inteligência artificial, visão por computador e redes neuronais.

No terceiro capítulo, é inicialmente conduzida uma análise aprofundada ao *dataset* utilizado no projeto abordando aspectos relevantes como a sua composição, qualidade e características. Adicionalmente são analisados os algoritmos inovadores desenvolvidos para a melhoria das anotações, destacando as estratégias adotadas para otimizar a precisão e confiança dos dados, oferecendo uma visão detalhada das ferramentas utilizadas na implementação prática do projeto, de maneira a proporcionar conhecimento sobre o ambiente de desenvolvimento e as tecnologias utilizadas. É descrita também a implementação prática do processo de pré-processamento das imagens fornecendo uma visão detalhada das etapas e decisões tomadas durante o processo de desenvolvimento.

O quarto capítulo, explica a abordagem tomada na escolha dos parâmetros e modelos, com a intenção de escolher a melhor combinação através de inúmeros treinos de modelos e valores de parâmetros, de maneira a proporcionar os melhores resultados na detecção automática do cancro da mama. E por fim validar a performance dos modelos treinados com outros modelos de variadas características.

Por fim, no quinto capítulo são analisados os resultados obtidos fruto do desenvolvimento do projeto, juntamente com uma ferramenta de previsão criada para a detecção do cancro da mama em imagens médicas, conclusões do desenvolvimento, limitações e futuros desenvolvimentos.

## **1.6. Gráfico Gantt**

O gráfico de Gantt é uma ferramenta essencial para a gestão de projetos, permitindo que indivíduos ou equipas acompanhem o progresso das tarefas ao longo do tempo de forma visual e organizada. Este é representado horizontalmente por meio de um eixo de tempo de escala variável, que se ajusta à extensão e à duração do projeto. Cada tarefa é representada por uma barra no gráfico, cujo comprimento indica a sua duração e o seu posicionamento ao longo do eixo de tempo mostra quando ocorrerá essa tarefa.

Além disso, o gráfico de Gantt pode incluir informações adicionais, como dependências entre tarefas, marcos importantes, recursos alocados e responsáveis por cada atividade. Esses elementos fornecem uma visão abrangente do cronograma do projeto e facilitam a identificação de possíveis percalços ou atrasos.

Na Figura 3, é apresentado o gráfico de Gantt específico do projeto em questão, destacando as principais etapas, prazos e alocação de recursos ao longo do tempo. Essa representação visual é essencial para o acompanhamento eficaz do progresso do projeto e para garantir que todas as atividades sejam concluídas dentro dos prazos estabelecidos.




Figura 3 - Gráfico Gantt do desenvolvimento do projeto [onlinegantt.com/#/gantt].

### 1.7. Contribuições Técnico-Científicas

O projeto desenvolvido trouxe diversas contribuições técnico-científicas significativas no campo de detecção do cancro da mama, ao combinar técnicas de aprendizagem de máquina / profunda e análise de imagens médicas / VC. Das contribuições na extração de características e melhoria da previsão dos modelos, nomeadamente, o uso de técnicas avançadas para a extração de características dos dados médicos durante o pré-processamento das imagens que possibilitou a melhoria das anotações originais, e a seleção de imagens médicas com maior qualidade na representação do tecido tumoral. Esta contribuição possibilitou o desenvolvimento da automatização das anotações, contribuindo para a detecção eficaz do cancro da mama.

## Capítulo 2

### Enquadramento Teórico

O âmbito deste capítulo é procurar fornecer uma base sólida para uma fundamentação teórica do tema central deste projeto e contextualizar o leitor sobre os conceitos necessários para o desenvolvimento coerente e abrangente do trabalho. Essa compreensão preparatória é essencial para uma apreciação completa das análises, resultados e conclusões que serão apresentados nos capítulos subsequentes, contribuindo assim, para a coesão e relevância do trabalho de pesquisa desenvolvido.

#### 2.1. Uso de Imagens Médicas na deteção do cancro da mama

##### 2.1.1. Imagens médicas

As imagens médicas desempenham um papel significativo nos ensaios clínicos, sendo amplamente empregues para a avaliação de critérios de elegibilidade, eficácia e segurança. Além da sua importância em ensaios clínicos, as imagens médicas são fundamentais no fluxo de trabalho clínico diário, contribuindo para a deteção precoce de doenças, diagnóstico preciso, monitorização do tratamento e avaliação de resultados terapêuticos [4].

Os métodos de diagnóstico através de imagens médicas permitem visualizar internamente o corpo humano, identificar condições patológicas e monitorizar o progresso e eficácia de tratamentos, sem a necessidade de fazer incisões ou expor o paciente a procedimentos invasivos. Ao incorporar métodos não invasivos como a ressonância magnética (MRI), a ultrassonografia, mamografia e a radiografia, os médicos especialistas da área da saúde podem obter informações valiosas sobre diversas patologias como a lesão tumoral da mama.

À medida que as tecnologias avançam, há uma crescente integração de tecnologias de ponta, como a Inteligência Artificial (AI) em várias aplicações incluindo nos processos de diagnóstico, tornando-os mais eficientes e procurando reproduzir a precisão de uma anotação feita por um especialista. A integração destas novas tecnologias têm permitido

uma análise mais rápida e em volume de imagens médicas potenciando a criação de *insights* detalhadas, auxiliando na tomada de decisões clínicas. Um dos pilares dessa evolução tecnológica é o DICOM, acrónimo para “*Digital Imaging and Communications in Medicine*” (Imagens Digitais e Comunicações em Medicina) é um conjunto de normas estruturadas perfazendo um protocolo, desenvolvido para proporcionar estrutura e padronização de imagens médicas geradas por equipamentos de diagnóstico. Este padrão visa facilitar a interoperabilidade entre dispositivos de sistemas de saúde, permitindo a troca eficiente e consistente de informações médicas.

O padrão DICOM, frequentemente identificado pela extensão de arquivo *.dcm*, é utilizado para arquivar, transmitir e visualizar registos de imagens médicas de forma digital. Além de representar os dados da imagem, este inclui metadados que descrevem informações importantes, como o protocolo de transferência utilizado, dados do paciente, informações sobre a aquisição da imagem, e parâmetros de apresentação e reconstrução.

Uma característica fundamental do DICOM é sua capacidade de suportar uma ampla variedade de modalidades de imagem, como radiografia, ressonância magnética (RM) e ultrassom. Isso garante que imagens médicas provenientes de diferentes dispositivos e fabricantes possam ser interpretadas e visualizadas de maneira consistente em sistemas de saúde.

### 2.1.2. Cancro da Mama

O cancro da mama é o cancro mais comum entre as mulheres, ultrapassando o cancro dos pulmões em 2020. De todos os casos detetados em 2020, (11.7%) ou 2.3 milhões de casos, foram identificados como cancro da mama, seguido de 11.4% de cancro dos pulmões, apesar do cancro dos pulmões apresentar uma taxa de mortalidade superior. Estes casos de tumor manifestaram-se na sua maioria em mulheres com idades compreendidas entre os 40 e os 60 anos de idade. É aconselhado que a partir do início desse intervalo de valores de idade, um exame anual seja feito para detetar precocemente o cancro da mama. [1], [5].

A procura pela cura do cancro da mama persiste devido às características destes tumores, que se manifestam em diversos tipos com características distintas. Existem inúmeros tipos de cancro da mama, sendo o carcinoma ductal um dos mais comuns, que se origina nas células dos ductos mamários. Outra forma é o carcinoma lobular, que começa nos lóbulos mamários e pode afetar ambos os seios. Existem igualmente tipos menos comuns, como o cancro da mama inflamatório, que provoca inchaço, vermelhidão e sensação de calor na mama [6], [7]. Além disso, cerca de 5% a 10% dos casos são hereditários, associados a mutações nos genes BRCA1 e BRCA2 (Breast Cancer gene 1 e Breast Cancer gene 2, respetivamente), aumentando a complexidade no diagnóstico e tratamento [8].

Devido a esta diversidade, não existe uma única solução viável para a luta contra o cancro da mama. O tratamento geralmente envolve uma combinação de abordagens terapêuticas como cirurgia, quimioterapia, radioterapia e imunoterapia. A mamografia, seguida pelo tratamento adequado, continua a ser uma das estratégias mais eficazes na redução da mortalidade por cancro da mama [9], [10]. A abordagem mais significativa na redução da taxa de mortalidade referente ao cancro da mama faz-se através da realização de exames de rastreio aleatório e controlados. Embora estes exames apresentarem uma redução significativa na taxa de mortalidade em países desenvolvidos, nos países menos desenvolvidos a falta ou reduzida realização desses exames preventivos contribui para o aumento da taxa de mortalidade nas mulheres. A deteção preventiva do cancro da mama continua a ser a solução mais impactante na redução da taxa de mortalidade relativo ao cancro da mama [11].

### *2.1.3. Métodos de Diagnóstico do Cancro da Mama e Tratamentos*

A utilização de imagens médicas é essencial na deteção do cancro da mama e existem diversas modalidades tais como Magnetic Resonance Imaging (MRI), Mamografia, Positron Emission Tomography (PET) e Computed Tomography (CT) que são utilizadas para fazer deteções e análise de tumores [12]. Dentro destas, o MRI continua a ser a escolha de eleição para a análise do cancro da mama por ser tratar atualmente da ferramenta radiológica mais precisa no estudo do cancro da mama,

podendo extrair valores de multifocalidade e multicentricidade do tumor. Apesar disso, o uso da MRI é limitado em alguns países e geralmente utilizado apenas como recurso adicional na análise das características do tumor, devido ao custo elevado e ao processo moroso do exame. Para superar essas limitações, é realizada uma mamografia com a finalidade de detecção inicial do tumor. A mamografia é a abordagem mais comum na detecção do cancro da mama devido ao seu custo reduzido e facilidade de execução. Por essa razão, é a escolha preferida na detecção do cancro da mama. É essencial reduzir o custo da MRI e diminuir o tempo de detecção manualmente exercida pelos médicos especialistas no futuro, para possibilitar diagnósticos mais precisos. No entanto, em países desenvolvidos como a Alemanha e os Estados Unidos, a MRI é cada vez mais utilizada no rastreio devido à sua superioridade na detecção precoce e avaliação precisa das lesões do cancro da mama quando comparada com a mamografia [13].

#### MAMOGRAFIA

A mamografia é um exame médico que utiliza raios X de baixa dosagem, de maneira a obter imagens detalhadas do tecido mamário (mamograma). Este exame é mais utilizado na detecção precoce do cancro da mama, o que é de extrema importância pois contribui para a redução da mortalidade associada a esta doença, especialmente em mulheres com a idade compreendida entre os 40 e 60 anos. A realização regular de mamografias nesta faixa etária permite identificar alterações no tecido mamário antes que os sintomas como a alteração da dimensão e formato do peito se manifestem, possibilitando um tratamento mais eficaz e aumentando as chances de cura [1], [14]. Foi determinado que mulheres com idades compreendidas entre os 50 e 74 anos de idade, experienciam uma redução do risco relativo de 0,74 (intervalo de confiança de 95% de 0,66 a 0,83) quando submetidas a rastreio por mamografia quando comparados com pacientes que não foram rastreados [14]. O uso de mamografia continua a ser a melhor escolha atual para um método de detecção precoce do cancro da mama quando comparada com outros métodos devido ao seu baixo custo, facilidade de execução e qualidade de imagem médica.

#### RESSONÂNCIA MAGNÉTICA

A Ressonância Magnética (MRI) destaca-se por ter uma qualidade de imagem superior, tendo uma melhor precisão na medição de dimensão do tumor, multifocalidade e multicentricidade, tendo ainda a maior sensibilidade e fornece uma maior precisão no

diagnóstico. O MRI não é realizado individualmente por causa da desvantagem do custo associado e dificuldade acrescida de realizar o exame comparado com a mamografia. Por essa razão a execução do MRI é efetuada aquando da anterior deteção positiva de lesão tumoral através de mamografia e também em casos de pacientes onde a mamografia não é conclusiva. É inegável a importância destas duas técnicas de imagem pois as vantagens dos dois complementam-se [1]. Segue-se a Figura 4 que ilustra as imagens médicas de cada metodologia de exame referida.




Figura 4 – Diversas imagens médicas com diferentes modalidades.

*A: Exemplo de Ressonância Magnética Mamária [15]*

*B: Exemplo de Imagem Mamográfica [16]*

#### TOMOGRAFIA COMPUTADORIZADA

A Tomografia Computadorizada utiliza raios-X para criar imagens transversais tridimensionais da secção do corpo, sendo utilizada com grande frequência no diagnóstico de tumores e lesões. Esta surgiu na década de 1970 para visualização de um tumor cerebral num paciente feminino de 41 anos [17]. A necessidade da utilização desta tecnologia surgiu devido à impossibilidade de analisar a região interior do cérebro, devido à pequena atenuação apresentada pelo tecido cerebral em comparação com a atenuação mais pronunciada causada pelo osso cortical do crânio que o envolve. Este avanço permitiu analisar internamente partes do corpo que não eram acessíveis de visualizar sem recurso a incisão.

#### 2.1.4. Sumário

Os métodos de diagnóstico por imagens revolucionaram a abordagem diagnóstica na medicina, como também desempenharam um papel crucial na promoção de uma prática clínica mais personalizada, centrada em resultados, elevando a qualidade de vida dos pacientes e expandindo as opções terapêuticas ao alcance dos profissionais de saúde.

## 2.2. Inteligência Artificial e Redes Neurais

### 2.2.1. Introdução à Inteligência Artificial

A Inteligência Artificial (AI) é uma área multidisciplinar que procura criar sistemas capazes de desempenhar funções complexas, normalmente associadas à inteligência humana. Esta inclui diversos campos de estudo, como Aprendizagem Máquina (ML), Aprendizagem Profunda (DL) e outros campos essenciais como o processamento de dados. A ML concentra-se na criação de sistemas capazes de identificar padrões e tomar decisões, utilizando técnicas como a regressão linear, árvores de decisão, *clustering*, entre outras, para prever valores com base em parâmetros históricos.

### 2.2.2. Redes Neurais Artificiais (ANNs)

O primeiro modelo de uma rede neuronal artificial (ANN) foi criada por Warren McCulloch em 1943 denominada por *perceptron*. Esta estabeleceu uma conexão entre a atividade neuronal e a lógica formal, tirando partido de que o cérebro pode ser visto como uma máquina e a simulação do funcionamento do cérebro levaria a grandes avanços tecnológicos no futuro [18]. As redes neuronais requerem muito poder de computação, mas recentemente tornaram-se amplamente disponíveis graças a grandes avanços na tecnologia, especialmente com o uso de Unidades de Processamento Gráfico (GPUs) e Unidades de Processamento Tensor (TPUs). Essas unidades de processamento especializadas são projetadas para acelerar os cálculos necessários para treinar e executar redes neurais, permitindo que modelos complexos processem grandes quantidades de dados de maneira mais eficiente.

As ANNs apresentam três grandes secções cruciais para o seu funcionamento, como demonstrado na Figura 5 as ANNs são compostas por uma camada de entrada de parâmetros seguida de uma ou várias camadas de neurónios ocultos e finalmente da camada de saída de resultados. A primeira camada de entrada de dados desempenha um papel crucial na introdução de características no sistema. No contexto da classificação e deteção de objetos numa imagem, cada um destes neurónios representam uma característica da imagem. O processamento e análise da imagem apresenta um grande desafio pela elevada quantidade de pixéis numa imagem, levando a uma ANN altamente complexa e computacionalmente dispendiosa. A representação unidimensional da imagem na primeira camada representa um desafio para estes modelos, havendo abordagens que visam resolver este problema, como as CNNs entre outras que serão abordadas posteriormente.

A segunda camada compreende todos os neurónios ocultos na ANN. Antes da descoberta do Deep Learning, os Multilayer Perceptrons (MLPs) já utilizavam várias camadas e neurónios por camada para processar informações. No entanto, o avanço do Deep Learning permitiu redes cada vez mais profundas e complexas, com maior capacidade de abstração. Em ambas as abordagens, a função desses neurónios é criar uma rede complexa para realizar cálculos variáveis entre si. Cada neurónio nesta camada processa informações provenientes da camada anterior e, por meio de pesos e ativações, contribui para a formação de representações mais abstratas e complexas. Essa camada é fundamental para a capacidade da ANN de aprender padrões e realizar cálculos mais sofisticados.

A camada de saída, por sua vez, representa a fase final da ANN e é composta pelos neurónios que fornecem os resultados da rede. Cada neurónio nesta camada está associado a uma classe específica ou a uma saída desejada, dependendo do tipo de tarefa que a ANN está projetada para realizar. A principal função dos neurónios na camada de saída é sintetizar as informações processadas nas camadas anteriores e gerar uma resposta final. Essa resposta pode ser interpretada como a previsão da classe de um objeto em tarefas de classificação, ou como valores contínuos em tarefas de regressão.

Através do processo de *backwards propagation*, a camada de saída contribui para o ajuste dos pesos e dos *bias* da rede, otimizando o desempenho da ANN em relação aos resultados desejados. Em resumo, a camada de saída desempenha um papel crucial na produção das saídas finais da rede, refletindo a aprendizagem e a capacidade de generalização conquistados durante o treino do modelo.




Figura 5 - Camadas de rede neuronal artificial [Retirado de [19]].

## CAPACIDADE DE APRENDIZAGEM DAS REDES NEURONAIS

### *Front Propagation (FP)*

A FP possui um papel crucial no funcionamento de cada operação numa ANN. A FP envolve o processo de passagem de dados da camada de entrada até à camada de saída. Cada neurónio realiza uma multiplicação de pesos e somatório de *bias*, *weighted sum*, seguida de uma passagem do valor resultante numa função de ativação.

As funções de ativação desempenham um papel fundamental no sucesso dos resultados das previsões da ANN pois cada neurónio é afetado por uma função de ativação que introduz não linearidade às operações na rede. Algumas das funções mais utilizadas são as funções Sigmoide, ReLU, Leaky ReLU e Tanh (Figura 6). A Função Sigmoide é uma função não linear que mapeia qualquer valor de entrada num intervalo entre zero e um. Esta função é frequentemente utilizada no contexto de classificação binária, onde a saída precisa de ser interpretada como probabilidades.

ReLU é uma função linear retificada que transforma os valores de entrada negativos em zero e deixa os valores positivos inalterados. A grande vantagem da utilização desta função é a sua simplicidade e eficiência computacional. Leaky ReLU é uma extensão da função ReLU tradicional, permitindo um pequeno gradiente diferente de zero, associando valores diferentes de zero para valores negativos de entrada. Leaky ReLU corrige o problema que o ReLU apresenta em relação a valores negativos, onde os neurónios podem ficar inativos e perdem a habilidade de aprender durante o treino da ANN, devido á não alteração de resultados para valores muito negativos.

Tanh ou tangente hiperbólica, é uma função de ativação que mapeia valores no intervalo de menos um a um, simetricamente em torno de zero. A função Tanh exhibe maior sensibilidade a valores de entrada próximos a zero e menor sensibilidade a valores distantes de zero.




Figura 6 – Funções de ativação em ANNs.

O valor resultante da função de ativação, obtida pela Fórmula (1), é utilizado na próxima camada e por aí a diante pelas diversas camadas neuronais na rede até que o resultado seja encaminhado para a última camada da rede neural, a camada final.

**Seja:**

$l$  – a camada com ativação  $a^{[l-1]}$ ,

$W^l$  – Pesos da camada  $l$ ,

$B^l$  – Bias da camada  $l$ ,

$g^l$  – Função de ativação da camada  $l$ ,

$a^{[l]}$  – Ativações da camada  $l$ ,

$Z^{[l]}$  – Vetor de pré – ativação para a camada  $l$

$$Z^l = W^l \cdot a^{[l-1]} + B^l ;$$

$$a^{[l]} = g^l(Z^l)$$

( 1 )

### Obtenção de Previsão

Para a obtenção de resultados na previsão, é necessário distinguir entre dois cenários: previsões binárias e multiclasse. No caso de previsões binárias, geralmente é aplicada a função sigmoide na camada final, que converte os valores dos neurónios num resultado entre 0 e 1, representando a probabilidade de cada classe. Já em cenários de previsão multiclasse, os valores presentes nos neurónios da camada final devem ser alvo da aplicação de uma função de normalização, como a função Softmax. Esta função, também conhecida como função exponencial normalizada, converte um vetor K de números reais numa distribuição de probabilidades de K resultados possíveis (Figura 7).




Figura 7 – Aplicação da função Softmax na camada de saída para a obtenção das probabilidades de decisão.

### Back Propagation

*Back Propagation* (BP) é uma técnica essencial para o treino das ANNs. Durante este processo o erro entre a saída calculada e a saída desejada de resultados é calculada e propagada de volta através da rede de modo a ajustar os pesos e os *bias* dos neurónios da rede. A BP utiliza a derivada da função de ativação em relação aos parâmetros da rede para determinar a direção e a magnitude dos ajustes necessários.

A função de perda escolhida é uma medida que quantifica o quão bem um modelo está a prever os resultados desejados durante o treino do modelo. Esta função determina o erro do modelo ao comparar as previsões com os valores reais esperados. A escolha da função de perda varia com o tipo de previsão e é responsável por quantificar a distância da previsão da ANN com os valores pretendidos durante o treino (Figura 8). O objetivo é

minimizar a função de perda ao máximo para que as previsões se aproximem dos rótulos do treino.

A BP ajusta iterativamente os pesos ( $W$ ) e os *bias* ( $B$ ) para minimizar a função de perda, utilizando o gradiente descendente (GD). Este método é utilizado para ajustar os pesos e *bias* durante o treino, movendo-os na direção oposta ao gradiente da função de perda. A fórmula geral da atualização dos pesos, Fórmula (2), envolve o cálculo do gradiente da função de ativação ( $L$ ) em relação aos pesos ( $W$ ) e *bias* ( $B$ ).

**Sendo:**

$\alpha$  – taxa de aprendizagem,

$l$  – função de ativação,

$W$  – pesos,

$B$  – *bias*

$$\nabla W^L = \frac{\partial L}{\partial W}$$

$$\nabla B^L = \frac{\partial L}{\partial B}$$

$$W_{novo} = W_{antigo} - \alpha \cdot \nabla W^L$$

$$B_{novo} = B_{antigo} - \alpha \cdot \nabla B^L$$

(2)

| Task           | Error type               | Loss function                                                                       |
|----------------|--------------------------|-------------------------------------------------------------------------------------|
| Regression     | Mean-squared error       | $\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$                                      |
|                | Mean absolute error      | $\frac{1}{n} \sum_{i=1}^n  y_i - \hat{y}_i $                                        |
| Classification | Cross entropy = Log loss | $-\frac{1}{n} \sum_{i=1}^n [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] =$ |

Figura 8 – Exemplos de função de perda de acordo com o tipo de previsão [Retirado de [20]].

### 2.2.3. Seleção e Extração de Características

A extração de características não é apenas aplicada no campo da Inteligência Artificial, como também é fulcral na análise de dados. Esta destaca-se por ser uma ferramenta crucial para transformar dados na sua forma original, em informação mais relevante e acionável. Esta transformação tem como objetivo representar os dados de forma mais eficiente, reduzindo as características das mesmas, mantendo a qualidade dos dados e por consequência melhorar o desempenho dos algoritmos que as usam.

A aplicação da extração de características é vasta e abrangida por diversas áreas como o processamento de imagens, reconhecimento de padrões, Visualização por computador, como é o caso das Redes Neurais Convolucionais (CNNs), entre outras.

Na generalidade das ocasiões de estudo, é necessário diminuir a dimensionalidade dos dados, algo que o PCA (Principal Component Analysis) faz. Este é um algoritmo que combina duas características numa só, diminuindo assim a dimensionalidade dos dados, enquanto mantém o máximo de qualidade informacional possível. No entanto é possível extrair informação dos dados existentes, de forma a aumentar a dimensionalidade dos dados. Este processo pode parecer contraintuitivo, mas em casos específicos, como neste projeto, a análise das imagens permite extrair informações que não estão contidas nas características do *dataset*, permitindo aumentar a precisão dos modelos de deteção de objetos.

## 2.3. Visão por Computador e Deteção de Objetos

### 2.3.1. Introdução

Desde a década de 1950, os pesquisadores enfrentaram desafios no desenvolvimento de sistemas capazes de compreender dados visuais, dando origem ao campo da Visão por Computador (VC). Em 2012, houve um avanço significativo da ciência com o desenvolvimento do AlexNet, um modelo DL criado pela Universidade de Toronto que venceu a competição ImageNet de VC com uma precisão notável de 85%, superando todos os algoritmos anteriores.

A VC é a ciência que permite às máquinas analisar imagens e vídeos, extraindo informações significativas, de modo semelhante à forma como os humanos processam dados visuais. De maneira mais técnica, a VC, também conhecida como compreensão de imagens ou análise de cenas, é a combinação do processamento de imagens, reconhecimento de padrões (aprendizagem de máquina) e tecnologias de Inteligência Artificial que se concentra na análise de uma ou mais imagens captadas por sensores simples ou multibanda, ou em sequências temporais. Esta análise permite reconhecer, localizar a posição e orientação, e fornecer uma descrição simbólica detalhada ou o reconhecimento dos objetos representados, aqueles considerados de interesse no ambiente tridimensional. [21][22].

A primeira etapa para a Visão por Computador é a aquisição de dados visuais. Esta obtenção de resultados pode ocorrer via sensores, câmaras ou outros dispositivos. Consecutivamente é comum pré-processar os dados recolhidos de modo a alterar os dados para aperfeiçoar a qualidade da imagem através de técnicas de correção de cor, redução de ruído, ajuste de contraste, entre outras.

No âmbito da deteção de objetos, é essencial obter resultados por meio da análise dos dados, os quais devem ser anotados através do processo de extração de características. Nesse processo são identificadas as características relevantes a serem analisadas nos dados. Uma imagem pode conter múltiplas anotações e as anotações podem ser feitas de diversas formas. Uma das formas de anotações mais simples é a classificação total da imagem em que esta representa na sua íntegra uma única classificação, como é exemplo da Base de dados MNIST, Figura 9, [23]. Outros exemplos de anotações compreendem-se por *bounding boxes* que contêm coordenadas específicas de dois pontos que formam uma anotação retangular que delimitam a zona de interesse, podendo uma imagem conter múltiplas anotações. Finalmente máscaras ou *masks* são imagens binárias que indicam as regiões de pixéis com interesse de uma imagem original. Estas permitem uma representação mais fiel em comparação com as *bounding boxes*, tendo como desvantagem a sua complexidade computacional em modelos que as utilizem.




Figura 9 - Exemplar da Base de dados MNIST

### 2.3.2. *Deteção de objetos*

No universo da Visão por Computador (VC), a detecção de objetos é uma tarefa / passo crítico, que se destaca pela diversidade na forma de utilização. Muitas áreas de aplicação da VC partem da detecção de objetos e distinguem-se para as suas áreas de especialização. Exemplos destas áreas incluem veículos autónomos na indústria automóvel, detecção facial, análise de imagens médicas, entre outros. A detecção de objetos / partes de uma imagem é fundamental em inúmeros setores, sendo frequentemente indispensável para diversas disciplinas científicas. Uma das áreas em que a detecção de objetos é crucial é na análise de imagens médicas, particularmente na detecção de tumores / lesões patológicas nas diferentes modalidades de imagens. No contexto da detecção do cancro da mama, algoritmos avançados de Inteligência Artificial são treinados para identificar e localizar áreas suspeitas em diferentes modalidades de imagem médica. A identificação de áreas suspeitas é um passo crucial na análise de qualquer modalidade, como por exemplo a ressonância magnética (MRI) e na mamografia, utilizadas na análise e detecção da doença, respetivamente. Essa detecção precisa permite que os médicos filtrem e se concentrem em regiões de interesse, reduzindo significativamente o tempo necessário para analisar cada imagem e aumentando a precisão do diagnóstico. Após a detecção das áreas suspeitas, técnicas avançadas de processamento de imagem podem ser aplicadas para melhorar a qualidade da imagem, permitindo uma análise mais detalhada e precisa, que é crucial para a identificação precoce e tratamento eficaz do cancro da mama.

Anterior a 2014, existiam modelos como Viola-Jones Detector (2001)[24], que representou um dos primeiros avanços significativos na área de detecção de objetos, o HOG Detector (2006)[25], e o DPM (2008)[26] em particular, o trabalho de Moura, D.C. and M.A. Guevara López (2013)[27], no qual foi desenvolvido um novo descritor invariante à rotação, Histogramas de Divergência do Gradiente (HGD), para lidar com objetos de forma arredondada, como massas (nódulos mamários). Estes métodos geralmente baseiam-se em técnicas *clássicas* de processamento de imagem e VC.

Em 2014 registou-se um avanço tecnológico significativo com a introdução do modelo RCNN (Region-based Convolution Neural Network). Este modelo pioneiro aplicou uma abordagem orientada por regiões para a detecção e classificação de objetos em imagens. Posteriormente, surgiram modelos evoluídos com base no RCNN como o Fast R-CNN (2015) [28] e o Faster R-CNN (2015) [29], que melhoraram a eficiência e performance ao incorporar a abordagem aplicada em regiões de forma direta na rede neuronal.

Outros modelos de detecção de objetos que merecem ser destacados incluem o Mask R-CNN (2017) [30], que introduziu a segmentação de instâncias, consistindo em dividir uma imagem em pequenas instâncias individuais dos objetos em análise. Esta capacidade permitiu detetar e classificar objetos, mas também segmentar individualmente cada instância do objeto na imagem, proporcionando uma compreensão mais detalhada e precisa da presença e localização de objetos específicos. Outros modelos destacados incluem o Feature Pyramid Networks (FPN) (2017) [31], que aperfeiçoou a detecção em diferentes escalas ao utilizar uma arquitetura de pirâmide de características [32], e o G-RCNN (2021) [33], que introduziu uma inovação no OCR ao adicionar um componente crítico, o Gated Recurrent Convolution Layer de modo a melhorar o reconhecimento de texto em imagens ao combinar características das redes neurais e as redes neurais recorrentes, para capturar dependências espaciais e temporais em dados sequenciais [34]. Os modelos descritos anteriormente, no contexto pós 2014, apresentam uma constituição de duas fases na área de detecção de objetos. Estes modelos possuem uma estrutura distintiva, caracterizada pela divisão do processo em duas fases principais. A primeira fase concentra-se na extração de características da imagem, enquanto a segunda fase é dedicada à classificação da imagem. Estes modelos têm demonstrado um desempenho notável na localização precisa e no reconhecimento eficaz de objetos.

Para além destes modelos, após 2014 surgiram também modelos com apenas uma fase. Estes distinguem-se pela integração das fases de extração de características e classificação num único processo. Como resultado dessa abordagem, estes modelos apresentam uma alta velocidade de inferência em comparação com os modelos de duas fases. Essa característica torna-os particularmente adequados para situações que exigem análise e processamento em tempo real, especialmente em contextos de vídeo, fruto dos seus tempos de inferência que variam entre 35 ms e 65 ms (milissegundos) [35].

### *2.3.3. Segmentação de Imagens*

Posteriormente à extração de características é possível a realização da segmentação de imagens, um processo crucial em diversas aplicações de VC. A segmentação refere-se à subdivisão de uma imagem em diferentes regiões ou objetos com base em características específicas. Esse procedimento é fundamental para a compreensão detalhada da imagem, permitindo uma análise mais aprofundada e precisa.

Existem diferentes métodos de segmentação de imagens, sendo dois dos principais a segmentação por contorno e a segmentação por região. A segmentação por contorno propõe-se identificar os limites dos objetos na imagem. Já a segmentação por região agrupa pixels semelhantes para formar regiões distintas na imagem, facilitando a identificação e análise de objetos completos. Após a segmentação, diversas aplicações podem ser exploradas, como o reconhecimento e classificação de objetos. Com a imagem dividida em regiões ou objetos isolados, é possível aplicar algoritmos de ML para atribuir rótulos ou categorias a cada elemento identificado. Isso é fundamental em sistemas de reconhecimento de objetos em imagens, como em veículos autónomos, vigilância por câmaras e diagnóstico médico.

Além disso, a segmentação de imagens é essencial na deteção de movimento. Com a capacidade de identificar e isolar objetos em diferentes quadros consecutivos, é possível acompanhar a trajetória de objetos em movimento ao longo do tempo. Isso tem aplicações práticas em áreas como monitoramento de tráfego, análise de comportamento humano em vídeos de vigilância e em sistemas de realidade aumentada.

A interpretação e tomada de decisão baseiam-se fortemente na capacidade de entender e analisar as informações extraídas da imagem. A segmentação adequada é um pré-requisito para uma interpretação precisa. Por exemplo, em sistemas de assistência médica, a segmentação de órgãos em imagens de exames médicos é crucial para a interpretação correta e diagnóstico preciso.

Em resumo, a segmentação de imagens desempenha um papel fundamental na análise visual, proporcionando a base para uma variedade de tarefas, desde o reconhecimento de objetos até à detecção de movimento e tomada de decisão em sistemas autônomos e de Inteligência Artificial. O constante avanço nessa área contribui significativamente para o desenvolvimento de soluções mais eficientes e precisas em diversas aplicações práticas.

## **2.4. Redes Neurais Convolucionais (CNN)**

### *2.4.1. Introdução às redes neurais baseadas em regiões*

O campo de DL tem se destacado na última década devido à capacidade de lidar com grandes volumes de dados e extrair padrões complexos e representações de alto nível a partir dos mesmos. As redes neurais profundas, têm muitas aplicações práticas, em particular as CNNs, são amplamente utilizadas em aplicações de Visão por Computador.

Em Deep Learning, as CNNs são uma classe de ANNs amplamente utilizadas na área da VC. As CNNs diferenciam-se das ANNs tradicionais devido à aplicação de técnicas inovadoras conhecidas como convoluções. O AlexNet foi pioneiro ao utilizar as Redes Neurais Convolucionais (CNNs), as quais são projetadas para imitar de forma aproximada o funcionamento do sistema visual humano. Ao longo dos anos, as CNNs tornaram-se essenciais em diversas aplicações de VC, graças à sua capacidade de aprender automaticamente características discriminativas diretamente dos dados brutos, sem a necessidade de extração manual de características. Elas são amplamente utilizadas em tarefas como classificação de imagens, detecção de objetos, reconhecimento facial, segmentação de imagens entre outras.

O crescente destaque das CNNs no campo da VC é inegável, refletindo-se no seu desempenho impressionante em diversas aplicações e estabelecendo-se como uma tecnologia fundamental nessa área. As CNNs não apenas impulsionaram avanços significativos na AI e ML, como também abriram novas perspectivas e possibilidades numa variedade diversa de domínios. A sua capacidade de aprendizagem e generalização permitiu avanços notáveis no reconhecimento de padrões, classificação de imagens, detecção de objetos e muito mais, tornando-as uma ferramenta indispensável para resolver problemas complexos e desafiadores.

#### 2.4.2. Operações Fundamentais das CNNs

##### **Convoluções**

Nas CNNs, as convoluções são utilizadas para processar dados de entrada, como imagens. A convolução é uma operação matemática entre dois conjuntos de dados que resulta em um terceiro conjunto de dados. Elas ajudam a capturar padrões espaciais e hierárquicos nas características da imagem. Para além de conectar cada neurónio a todos os neurónios na camada seguinte, como nas ANNs tradicionais, as CNNs usam filtros ou “*kernels*” para realizar convoluções locais na camada de entrada.

Essa abordagem permite que as CNNs aprendam características como margens, texturas e formas em diferentes regiões da imagem. Além disso, são frequentemente usadas para reduzir a dimensionalidade dos dados e preservar as características mais importantes.

A operação de convolução em redes neurais convolucionais (CNNs) é um processo fundamental para extrair características significativas nos dados de entrada de um modelo, comumente aplicado em dados com elevadas quantidades de características, como imagens. A convolução ocorre por meio de filtros, também conhecidos como “*kernels*”, que deslizam sobre a entrada, multiplicando os seus pesos pelos valores correspondentes na região coberta pela operação (convolução).

Ao longo da operação é realizada uma multiplicação elementar ou “*elementwise multiplication*”, e os resultados são somados para gerar um único valor na saída como se

pode verificar na Figura 10, formando assim o que é chamado de mapa de características. Esse mapa revela como o filtro responde a diferentes padrões presentes na imagem, capturando informações espaciais.




Figura 10 – Exemplo de cálculo de um mapa de características com recurso a convoluções.

O processo de convolução é definido, entre outros fatores, pelo *stride*, que se refere ao tamanho do passo com que o filtro se move pela entrada durante a operação de convolução. Na Figura 10, foi utilizado um *stride* de valor 1, o que significa que o filtro se desloca um pixel de cada vez. O uso de um *stride* com valor 1 resulta num mapa de características mais detalhado, pois o filtro percorre a entrada pixel a pixel. Por outro lado, *strides* com valores maiores que 1 fazem com que o filtro salte vários pixéis, gerando um mapa de características com menor resolução. Além disso, podem ser utilizadas técnicas de *padding*, que adicionam pixéis ao redor da imagem, permitindo que a convolução seja aplicada também nos pixéis nas margens, preservando o tamanho original da entrada. Ao aplicar a convolução a uma imagem, esta gera um mapa de características de dimensão mais reduzida, podendo ser calculada através das seguintes Fórmulas (3) e (4). A Fórmula (3) calcula a dimensão da largura do mapa de características e a Fórmula (4) a altura do mapa de características.

Seja:

$W_{in} . H_{in}$  – as dimensões da imagem,

$K . K$  – as dimensões do kernel ou filtro,

$S$  – o valor de *stride* ou passo,

$P$  – o valor de *padding*

O mapa de ativação de saída terá as seguintes dimensões:

$$W_{out} = \frac{W_{in} - K + 2P}{S} + 1 \quad (3)$$

$$H_{out} = \frac{H_{in} - K + 2P}{S} + 1 \quad (4)$$

Após a convolução, é comum aplicar uma função de ativação, como a ReLU descrita em 2.2.2.2, para introduzir não linearidades permitindo que a rede aprenda padrões mais complexos. Múltiplos filtros podem ser utilizados numa camada de convolução, possibilitando à rede aprender diversas características simultaneamente.

A convolução, com a sua capacidade de capturar características hierárquicas, é uma técnica essencial na área da VC, contribuindo para o sucesso das CNNs na análise e interpretação de dados visuais.

### ***Pooling***

Pooling é uma operação de subamostragem realizada após as camadas de convolução. Duas formas comuns de pooling são o max pooling e o average pooling. O pooling ajuda a reduzir a dimensionalidade dos mapas de características, preservando as informações mais relevantes. Durante esta operação, uma janela de valores percorre o mapa de características e, em cada posição, no caso por exemplo do max pooling, extrai o valor máximo dos valores da região.

A adição de pooling à arquitetura das CNNs contribui para tornar a rede mais eficiente computacionalmente, ao reduzir a dimensionalidade dos dados e, consequentemente, o número de parâmetros na rede. Além disso, o pooling ajuda a prevenir o *overfitting*, ao permitir uma generalização melhorada dos padrões aprendidos, especialmente em grandes conjuntos de dados. A combinação de convolução e pooling permite que as CNNs captem características hierárquicas, sendo essencial em aplicações de VC.

## Flattening

Após as camadas de convolução e pooling, é aplicada a operação de flattening. Esta etapa consiste em converter os mapas de características bidimensionais num vetor unidimensional. Esta etapa é essencial para conectar as camadas de convolução e pooling às camadas densamente conectadas, as quais requerem entradas unidimensionais para processamento. O vetor unidimensional resultante é inserido nas camadas densas para realizar tarefas de classificação, regressão ou classificação. O flattening é essencial para preparar os dados, convertendo os mapas de características bidimensionais num vetor unidimensional, facilitando a transição para camadas densamente conectadas. Isso permite que a rede neuronal aprenda padrões mais abstratos e complexos, combinando informações de diferentes regiões das imagens. Todas as operações referidas anteriormente podem ser visualizadas na Figura 11 relativo á AlexNet.




Figura 11 – Arquitetura AlexNet demonstrando as operações de convolução, pooling e camadas densas. [Retirado de [https://en.wikipedia.org/wiki/Convolutional\\_neural\\_network](https://en.wikipedia.org/wiki/Convolutional_neural_network)]

### 2.4.3. RCNNs

Em 2014, uma inovação revolucionária marcou a área da VC com a introdução da Rede Neuronal Convolutiva Baseada em Região, mais conhecida como R-CNN, [36]. Esta abordagem representou um avanço significativo na detecção e localização de objetos de forma precisa, demarcando o início de uma nova era na pesquisa da VC.

#### R-CNN

R-CNN destaca-se pela sua abordagem de duas etapas, envolvendo a proposição de regiões candidatas e a extração de características. Inicialmente, são geradas propostas de regiões por meio de um algoritmo de procura seletiva. Posteriormente, regiões específicas são selecionadas da imagem original e submetidas a uma rede neuronal convolutiva anteriormente treinada para a extração de características. Essas características são utilizadas na classificação de objetos e no melhoramento das regiões, resultando numa detecção precisa e localização exata dos objetos na imagem.

Apesar de ser um marco significativo, o R-CNN enfrenta desafios computacionais, que impulsionou o desenvolvimento de variantes de R-CNN mais eficientes, como o Fast R-CNN e o Faster R-CNN. Estas iterações subsequentes melhoraram a eficiência e a precisão, solidificando o R-CNN como uma peça fundamental no desenvolvimento de algoritmos para detecção de objetos em imagens.

#### FAST R-CNN

Continuando a trajetória iniciada pelo R-CNN, o Fast R-CNN surge em 2015 trazendo melhorias substanciais na detecção de objetos em imagens. Ross Girshick, líder na vanguarda da pesquisa em VC, propôs este novo paradigma para superar as limitações computacionais encontradas no R-CNN.

O Fast R-CNN representa uma resposta aos desafios enfrentados pelo seu antecessor que realizava a proposição de regiões e a extração de características de forma separada, o Fast R-CNN unifica estas etapas numa abordagem mais eficiente e integrada.

Na primeira etapa do Fast R-CNN, uma imagem de input passa por uma CNN para a extração de características. A inovação central reside na criação direta de Regiões de Interesse (ROI)s a partir dessas características, eliminando a necessidade de um algoritmo externo de proposta de regiões. Isso simplifica a arquitetura e acelera significativamente todo o processo.

As ROIs obtidas são adaptadas para um formato fixo e utilizadas para a classificação e o aperfeiçoamento da localização dos objetos na imagem. Esta abordagem integrada melhora a eficiência computacional e preserva a precisão na detecção de objetos, consolidando o Fast R-CNN como um marco fundamental na evolução dos algoritmos de VC.

Ao superar as limitações do R-CNN, o Fast R-CNN estabeleceu um novo padrão para a detecção de objetos, abrindo caminho para inovações subsequentes, como o Faster R-CNN.

#### FASTER R-CNN

O Faster R-CNN redefiniu os limites ao integrar a criação de propostas de regiões diretamente no modelo, removendo a necessidade de algoritmos externos. Essa inovação acelerou consideravelmente o processo de detecção de objetos, criando uma arquitetura mais eficiente e precisa.

A principal contribuição do Faster R-CNN é a introdução de uma CNN (RPN - Region Proposal Network) que atua em paralelo com a rede de características convolucionais, o que se pode analisar na Figura 12 que demonstra a arquitetura de alto nível deste modelo. A RPN gera propostas de regiões de forma eficiente, usando âncoras de diferentes escalas e aspectos para capturar objetos de variadas dimensões.

As propostas geradas pela RPN são combinadas com as características extraídas pela CNN e utilizadas para a classificação e localização dos objetos. A abordagem unificada e eficiente do Faster R-CNN estabeleceu novos padrões em termos de velocidade e precisão na detecção de objetos, consolidando a sua posição como uma referência na VC.




Figura 12 - Arquitetura de alto nível do Faster R-CNN [37]

## MASK R-CNN

Mask R-CNN é uma extensão avançada do Faster R-CNN, projetada para abordar não apenas a detecção de objetos, mas também a segmentação semântica pixel a pixel. Essa abordagem foi introduzida por Kaiming He, Georgia Gkioxari, Piotr Dollár e Ross Girshick em 2017, representando um marco significativo na capacidade de compreensão detalhada de objetos em imagens.

A principal contribuição do Mask R-CNN é a inclusão de um ramo adicional na rede, chamada de máscara, que opera em paralelo com a parte de detecção do Faster R-CNN. Este ramo é responsável por criar máscaras de segmentação para cada região proposta, permitindo uma segmentação precisa dos objetos.

As aplicações do Mask R-CNN são vastas e variadas. Em contextos médicos, o modelo destaca-se na segmentação de órgãos em imagens médicas, proporcionando uma ferramenta valiosa para diagnósticos mais precisos. Na área de análise de vídeo e vigilância, a detecção automática de pessoas e animais é melhorada pela capacidade de segmentação, tornando o modelo crucial para cenários de segurança e supervisão.

#### 2.4.4. Métricas

A avaliação de modelos de detecção de objetos é crucial para medir a sua eficácia e desempenho. Diversas métricas são aplicadas para avaliar o sucesso das previsões de um modelo na identificação e localização de objetos numa imagem. A análise dessas métricas é fundamental para iterar e melhorar continuamente os modelos de detecção de objetos, garantindo que atendam aos requisitos de qualidade e confiabilidade necessários nas suas aplicações práticas.

##### ***Precisão ou Accuracy***

A precisão é a proporção de verdadeiros positivos (objetos corretamente detetados) em relação ao total de detecções feitas pelo modelo (verdadeiros positivos mais falsos positivos). É uma métrica útil para avaliar a taxa de detecções corretas entre as detecções.

$$Precisão = \frac{Verdadeiros\ Positivos}{Verdadeiros\ Positivos + Falsos\ Positivos}$$

##### ***Sensibilidade ou Recall:***

A revocação, também conhecida como sensibilidade, é a proporção de verdadeiros positivos em relação ao total de objetos positivos detetados (verdadeiros positivos mais falsos negativos).

$$Recall = \frac{Verdadeiros\ Positivos}{Verdadeiros\ Positivos + Falsos\ Negativos}$$

##### ***F1 Score:***

O F1 Score é uma métrica que combina a precisão e revocação numa única medida, calculada como a média harmónica entre essas duas métricas. Esta é útil quando se deseja equilibrar a importância de ambas as características.

$$F1 = 2 \cdot \frac{Precisão \cdot Recall}{Precisão + Recall}$$

##### ***Média de Interseção sobre União (mIoU ou IoU):***

A métrica IoU mede a sobreposição entre a anotação prevista e a anotação de referência ou *ground truth*, sendo particularmente útil em tarefas de segmentação de

objetos. A mIoU é calculada pela área da interseção dividida pela área da união entre a predição e a referência para cada caso a média dos valores é calculada.

$$IoU = \frac{\text{Área da Interseção}}{\text{Área da União}}$$

$$mIoU = \frac{1}{N} \sum_{i=1}^N IoU_i$$

***Average Precision (AP):***

Average Precision é uma métrica comum na detecção de objetos. Ela calcula a área sob a curva de precisão-recall (PR), fornecendo uma medida composta pelo desempenho do modelo em diferentes níveis de confiança na detecção.

***Mean Average Precision (MAP):***

O MAP é uma média das pontuações de precisão média (AP) para várias classes ou categorias de objetos proporcionando uma visão geral do desempenho do modelo num conjunto de dados.

## Capítulo 3

### Materiais e Métodos

#### 3.1. Dataset

Neste capítulo, será introduzido o conjunto de dados que serviu como base para o desenvolvimento deste projeto. O objetivo deste capítulo é a realização do pré-processamento dos dados com qualidade para treinar e avaliar o modelo de detecção de objetos, visando identificar com precisão os casos positivos de tecido tumoral em pacientes.

Os dados utilizados para a concepção e treino do modelo provêm do *dataset* fornecido pela Duke University e denominado por DukeBC Dataset. Este é um *dataset* completo e variado, com casos de cânceros invasivos e segundo as fontes destacadas [3], [38], é um *dataset* que fornece os melhores resultados aquando do processo de treino dos dados. Por essa razão, este foi utilizado para testar os algoritmos teorizados na fase de concepção de hipóteses da metodologia utilizada.

##### 3.1.1. Observação Detalhada de Características

DukeBC é um *dataset* que compreende 922 casos de pacientes positivamente diagnosticados com cancro da mama, com provas de biópsia. Este *dataset* consiste em anotações e imagens médicas fornecidas pela Universidade Duke, Durham, North Carolina, USA. As imagens médicas compreendem a zona de interesse na zona torácica, capturadas com recurso a MRI de alto contraste. Este *dataset* inclui informações adicionais como a localização dos tumores via caixas de anotação 2D, possíveis de entender pela análise da Tabela 1, que através das características *Start slice* e *End slice*, permite extrair uma delimitação espacial 3D da anotação. Estes dados podem ser melhor preceptivos pela interpretação da Figura 13, que ilustra uma visualização 3D de uma representação do tumor e das caixas de anotação.

Adicionalmente é fornecido em conjunto uma tabela que contém informações acerca do tumor e do paciente, como o volume do tumor, volume do peito, opções de contraste, entre outras. Estes valores são relevantes para o âmbito de classificação do

tumor, mas não foram consideradas para o efeito de detecção de tecido tumoral.

Cada paciente é identificado pelo formato “*Breast\_MRI\_*” seguido do identificador do paciente. Este identificador permite que se distinga as diferentes anotações e imagens entre pacientes, tanto na estrutura de diretorias como no ficheiro de anotações identificadas no *dataset*. A anonimização dos dados começa com a atribuição de um identificador único para cada paciente, desvinculando qualquer informação pessoal das imagens médicas. Este processo de anonimização é mantido ao longo de todo o projeto, garantindo o anonimato dos pacientes, o que é crucial em termos de privacidade, ética, e cumprindo com os regulamentos atuais de proteção de dados. As imagens dos casos de pacientes em formato DICOM, provenientes de Ressonâncias Magnéticas normalmente contêm informações de identificação do paciente na sua estrutura interna, as quais foram devidamente removidas antes da divulgação pública deste *dataset* pela universidade de Duke, de maneira a proteger a privacidade e a imagem do paciente.

Tabela 1 – Estrutura da tabela com as de anotações de cada paciente.

| Patient ID     | Start Row | End Row | Start Column | End Column | Start slice | End slice |
|----------------|-----------|---------|--------------|------------|-------------|-----------|
| Breast_MRI_001 | 234       | 271     | 308          | 341        | 89          | 112       |
| Breast_MRI_002 | 251       | 294     | 108          | 136        | 59          | 72        |
| ...            | ...       | ...     | ...          | ...        | ...         | ...       |




Figura 13 - Ilustração do esquema de anotação 3D compreendido por anotações 2D e pelo número de *slices*. Retirado de [3].

O conjunto de imagens fornecidas está organizado por paciente, sendo que cada paciente possui múltiplas séries de imagens médicas correspondentes a diversas passagens realizadas. O *dataset* engloba passagens de sequências ponderadas em T1 saturadas sem gordura, passagens pré-contraste ponderadas em T1 com gradiente echo saturado de gordura e, por fim, entre três a quatro passagens pós-contraste [39]. Apenas estas últimas passagens pós-contraste foram consideradas devido à alta qualidade de imagem resultante da alteração de parâmetros que permitem uma visualização mais fiel do tumor, em comparação com as passagens anteriores que não apresentam suficiente qualidade de imagem.

A realização dos exames de ressonância magnética foi feita utilizando equipamentos de dois fabricantes distintos: GE Medical Systems e Siemens. Cada fabricante é representado por quatro modelos diferentes neste *dataset*, conforme demonstrado na Tabela 2. As máquinas apresentam variações de software e hardware, refletindo em imagens com resoluções que variam entre 320x320, 448x448 e 512x512 pixels, conforme indicado na Tabela 3.

As disparidades nas resoluções das imagens têm um impacto direto na performance do modelo. Como estratégia, optou-se por não realizar nenhum ajuste no dimensionamento inicial das imagens, decisão essa para preservar a integridade dos dados brutos, transferindo a responsabilidade de dimensionamento para a API da framework Tensorflow de detecção de objetos que foi utilizada posteriormente no treino do modelo de detecção de objetos. Essa abordagem ressalta a flexibilidade da framework diante da diversidade técnica das máquinas utilizadas.

Tabela 2 - Número de casos por modelo e fabricante de ressonância magnética ordenado por número de casos.  
Retirado de [3] e adaptado.

| Fabricante         | Modelo        | Nº de Casos |
|--------------------|---------------|-------------|
| GE Medical Systems | Signa HDx     | 272         |
|                    | Signa HDxt    | 248         |
|                    | Optima MR450z | 98          |
|                    | Signa Excite  | 10          |
| Siemens            | Avanto        | 179         |
|                    | Skyra         | 57          |
|                    | Trio-trim     | 57          |
|                    | Trio          | 1           |

Tabela 3 - Resolução das imagens e número de casos

| Resolução de Imagem (pixéis x pixéis) | Número de casos (pacientes) |
|---------------------------------------|-----------------------------|
| 320 x 320                             | 33                          |
| 448 x 448                             | 261                         |
| 512 x 512                             | 628                         |

### 3.1.2. Análise crítica

Apesar do *dataset* apresentar uma excelente variedade de exemplos, múltiplas passagens por pacientes e excelentes artefactos para a identificação do tumor a nível de posição e características, o *dataset* apresenta algumas fraquezas.

Uma das maiores críticas se pode fazer ao *dataset* é a inexistência de múltiplas anotações tumorais por paciente. Apenas é identificada uma lesão tumoral por paciente, mesmo que existam casos com múltiplas deteções. Caso haja várias lesões na imagem, apenas a lesão de maior dimensão é anotada. Esta desvantagem impacta o sucesso da deteção pois mesmo que o modelo de deteção esteja a identificar positivamente um tumor que de facto existe, este pode não estar assinalado, impactando a confiança do modelo na deteção de lesões e afetando o treino do modelo e posteriormente a sua performance.

Os algoritmos de pré-processamento poderiam beneficiar da disponibilidade de uma maior quantidade de características, como a identificação da *slice* com a maior dimensão do tumor, referenciada como *k*, conforme observado na Figura 13. Essa inclusão proporcionaria uma riqueza adicional de informações para análise durante o pré-processamento. Tal contribuição poderia cooperar significativamente para o pré-processamento das imagens e posteriormente o treino do modelo, oferecendo uma representação mais precisa e detalhada das características dos tumores.

Para incorporar múltiplas anotações por imagem, é aconselhado duplicar as entradas do mesmo paciente na Tabela 1, registando cada uma das anotações de tumores identificados. Essa estratégia permitiria uma ampliação dos dados sem necessidade de alterações significativas na estrutura do conjunto de dados existente, resultando mais informação de maior qualidade. Esta abordagem é utilizada no protótipo produzido no final do documento que possibilita efetuar múltiplas anotações por paciente.

É importante destacar que o conjunto de dados atualmente disponível abrange apenas casos de verdadeiros positivos, onde a presença de lesões tumorais foi confirmada. No entanto, essa abordagem pode apresentar desafios futuros em relação à detecção de falsos positivos. Para mitigar essa questão, seria necessário considerar a inclusão de casos negativos no conjunto de dados, de modo a treinar os modelos para distinguir com maior precisão entre casos positivos e negativos, garantindo uma detecção mais confiável e robusta.

Em resumo, é fundamental abordar essas limitações para garantir a qualidade e a confiabilidade dos dados utilizados no treino e avaliação de modelos de detecção de tumores. Isso não apenas melhorará o desempenho dos algoritmos, mas também contribuirá para resultados mais precisos e clinicamente relevantes.



### 3.2. Algoritmos e métodos propostos

Os algoritmos propostos neste projeto tiveram um papel crucial na análise de imagens médicas, permitindo a extração de características que não estavam anteriormente demarcadas. Esta contribuição representa o principal avanço do projeto, uma vez que o seu sucesso foi diretamente influenciado pelo desenvolvimento destes algoritmos. Estes possibilitaram a análise das imagens fornecidas pelo dataset, a extração de informações e a criação de dados que representam de forma mais precisa as características do tumor, utilizando a quantidade mínima de dados necessária.

O algoritmo utilizado desempenha um papel central neste processo, uma vez que permite a análise detalhada das imagens e a extração de informação crucial que não está diretamente disponível no conjunto de dados original. Esta informação adicional é fundamental para a criação de dados que descrevam o tumor de forma mais precisa. Na sua essência, o algoritmo recolhe e extrapola informação das imagens, alargando o conjunto de dados disponíveis para análise e treino do modelo, otimizando a qualidade e eficácia dos resultados.

#### 3.2.1. Deteção da slice com a maior pronúnciação do tumor

O algoritmo desenvolvido extrai dados importantes das imagens, incluindo a fatia ou *slice* em que o tumor se expressa com maior dimensão, identificando os pixéis contidos na anotação original do tecido tumoral. Esses valores são recolhidos para processamento. A informação é segmentada por fatias e, para cada fatia, é aplicada a Fórmula (5), a seguir, que soma os valores dos pixéis dentro da anotação original. É feito este cálculo de maneira a recolher a intensidade do sinal. Esta é uma boa aproximação do tamanho do tumor uma vez que as imagens contêm pixéis com valores entre 0 e 255, em que valores superiores representam artefactos na imagem com maior densidade com a coloração branca. A Figura 14 mostra que para diferentes valores de ruído, quanto menor for o ruído, melhor será a aproximação do sinal do tumor pela intensidade do sinal total. A partir do cálculo da intensidade do sinal é possível extrapolar a fatia em que a anotação original foi feita através da fatia com maior intensidade do sinal na anotação.

O índice em que esse valor máximo ocorre denominado por  $k$ , representa a aproximação da fatia em que o tumor apresenta sua maior manifestação na imagem. A

combinação da intensidade do sinal e do valor  $k$  é fundamental para os próximos passos do algoritmo, fornecendo informações cruciais para a análise e interpretação dos dados. Esses dados são essenciais para a identificação e localização adequadas do tumor, contribuindo para o sucesso geral do algoritmo na análise das imagens médicas.

**Seja:**

*Slice* – array bidimensional representa a localização do tumor da Imagem

*ci* – coluna inicial da anotação de um dado Paciente,

*cf* – coluna final da anotação de um dado Paciente,

*ri* – linha inicial da anotação de um dado Paciente,

*rf* – linha final da anotação de um dado Paciente,

$$Intensidade\ do\ sinal = \sum_{i=ri}^{rf} \sum_{j=ci}^{cf} Slice[i][j]$$

( 5 )

*Intensidade do sinal Total =*

*Intensidade do sinal Tumoral + Intensidade do sinal Envolvente*

( 6 )




Figura 14 - Fatias com diferentes sinais de ruído com a mesma intensidade de sinal Total.

A utilização de imagens com supressão de gordura, aliada àquelas que não possuem tecidos envolventes menos densos, é crucial para melhorar a identificação do tumor, pois a menor intensidade do sinal nesses casos facilita a diferenciação do tumor. Deste modo,

tendo uma redução do sinal do tecido envolvente, a intensidade total aproximar-se-á da intensidade do tumor, representando este de uma forma mais precisa como mostra a Fórmula (6) apoiado pela Figura 14. Esta fórmula é apoiada a partir das características do MRI referidas por [40] na qual o tecido mais denso apresenta um valor mais elevado quando comparado com tecidos menos densos.

Após a identificação da *slice* com maior dimensão, são normalizados os valores para posterior utilização no ajuste da anotação inicial, de modo que esta passe pelos pontos  $(-1,0)$ ,  $(k,1)$  e  $(n,0)$  nos eixos  $(x,y)$  em que  $k$  é o índice da fatia com maior dimensão, e  $n$  o número de fatias. Estes pontos foram considerados porque nos índices das fatias  $0$  e  $n-1$  o tumor ainda se manifesta, tendo uma dimensão maior que  $0$ . A normalização é crucial para distribuir os valores entre  $0$  e  $1$ , onde  $1$  representa o tamanho original anotado e  $0$  indica ausência de anotação. A necessidade de adaptar a anotação resultou na criação de funções destinadas a representar a escala do tumor de forma aproximada. A proposta consiste em normalizar os valores para influenciar a dimensão da anotação com base na intensidade total. Nos extremos em que a intensidade é menor, os valores tenderiam a aproximar-se de  $0$ , enquanto na camada em que o tumor apresenta maior dimensão, o valor se aproximaria de  $1$ , não sofrendo alteração na dimensão da anotação. As funções propostas apresentam sempre em comum as características de serem crescentes no espaço  $[0, k]$  e decrescentes entre  $[k, n]$ , tendo um máximo em  $k$  com o valor  $1$  e os valores mínimos nas extremidades. Características importantes para a aproximação final da anotação que representará com maior fidelidade a dimensão e localização do tumor.

### 3.2.2. Funções de escala da anotação com recurso á intensidade do sinal

Propõe-se uma função que utiliza a intensidade total do sinal de cada *slice* para fornecer informações adicionais e realizar uma aproximação da anotação pós processamento mais precisa em comparação com a anotação original. É fundamental ressaltar que, embora outras funções tenham sido consideradas, a função apresentada na Fórmula (14) utilizando as Fórmulas (7) e (8) emergiu como a mais promissora, proporcionando os melhores resultados analisados. Este processo de avaliação e seleção de funções foi crucial para garantir a precisão e a adequação do modelo aos dados e às necessidades específicas do problema em questão. A escolha da função baseou-se em critérios observados no modelo como ajuste dos dados observados, capacidade de

generalização e interpretação, entre outros. Portanto, a função selecionada representa não apenas uma solução viável, mas também a mais robusta e eficaz entre as alternativas consideradas.

#### ESCALONAMENTO DA ANOTAÇÃO ATRAVÉS DE DISTRIBUIÇÃO NATURAL

Esta função propõe-se representar a silhueta de um objeto com proporções normais. Com uma inspiração na natureza, a função munida de um valor  $k$  (índice da maior pronúncia), apontando fazer uma ligação natural entre o início do tumor, a sua posição máxima ou central e o final do tumor ao mimizar na perfeição as silhuetas de um círculo. Esta distribuição é uma abordagem conservadora na manipulação da escala da anotação, na qual valores perto de  $k$  apresentarão um peso igualmente elevado ao de  $f(k)$ . Esta função é ideal para casos em que a certeza da variável  $k$  não é elevada, podendo assim considerar os valores vizinhos como potenciais  $k$  devido á natureza desta função. O resultado dependerá do número de *slices* a serem analisadas e da posição do índice  $k$ .

Nas Figuras 15 e 16 são demonstrados valores resultantes da utilização da função circular com vários parâmetros. As figuras mostram o alisamento feito em 11 *slices*, podendo comparar o valor original, representado a (laranja, linha contínua e cruces nos pontos), comparando com os valores gerados representados por (azul, linha picotada e pontos redondos). A função é apresentada na Fórmula (9) é composta pelas Fórmulas (7) e (8).

**Seja:**

$R$  – um array de comprimento  $n$ ,

$k$  – o índice do valor máximo em  $R$ .

$i$  – o índice do array  $R$

$R_i$  – o valor do array na posição  $i$

Definimos duas funções de Inclinação:

**Para a esquerda do ponto máximo:**

$$slopeLeft(x) = \sqrt{1 - \left(\frac{x+1}{k+1} - 1\right)^2}$$

( 7 )

**Para a direita do ponto máximo:**

$$slopeRight(x) = \sqrt{1 - \left(\frac{x-k}{n-k}\right)^2}$$

( 8 )

A função final utiliza as funções anteriormente definidas retornando um novo *array* *R* de comprimento *n*, onde cada elemento *R<sub>i</sub>* é calculado da seguinte maneira:

$$R_i = \begin{cases} slopeLeft(x), i < k \\ 1, i = k \\ slopeRight(x), i > k \end{cases}$$

( 9 )

Exemplos de retorno da função conforme os dados fornecidos:




Figura 15 - Alisamento de três pontos pela função circular comparado com pesos originais (k = 5, n = 11)




Figura 16 - Alisamento de três pontos pela função circular comparado com pesos originais ( $k = 8$ ,  $n = 11$ )

## ESCALONAMENTO DA ANOTAÇÃO ATRAVÉS DA FUNÇÃO QUADRÁTICA

A função referida neste subcapítulo é uma adaptação da função quadrática ( $x^2$ ) que coincide com os pontos extremos da função anterior, nomeadamente o ponto  $(-1, 0)$ ,  $(k, 1)$  e  $(n, 0)$  do eixo  $(x, y)$  em que  $k$  é o índice da fatia com maior dimensão, e  $n$  o número de fatias. O resultado dependerá do número de *slices* a serem analisadas e da posição do índice  $k$ . Esta função foi idealizada para casos em que a confiança do valor de  $k$  é mais elevada. A curva da escala da anotação é mais acentuada comparando com a proposta anterior. Esta abordagem embora idealizada para casos em que se saiba com total certeza do índice  $k$ , durante a fase de testes não apresentou os melhores resultados e por isso não foi utilizada no pré-processamento final.

Nas Figuras 17 e 18 são demonstrados valores resultantes da utilização da função quadrática adaptada. As figuras mostram o alisamento feito em 11 *slices*, podendo comparar o valor original, representado a (laranja, linha contínua e cruzeiros nos pontos), comparando com os valores gerados representados por (azul, linha picotada e pontos redondos). A função é apresentada na Fórmula (12) é uma composta pelas Fórmulas (10) e (11).

**Seja:**

$R$  – um array de comprimento  $n$ ,

$k$  – o índice do valor máximo em  $R$ .

$i$  – o índice do array  $R$

$R_i$  – o valor do array na posição  $i$

Definimos duas funções de Inclinação:

**Para a esquerda do ponto máximo:**

$$slopeLeft(x) = 1 - \frac{(x - k)^2}{(k + 1)^2} \quad (10)$$

**Para a direita do ponto máximo:**

$$slopeRight(x) = 1 - \frac{(x - k)^2}{(n - k)^2} \quad (11)$$

A função final utiliza as funções anteriormente definidas retornando um novo *array*  $R$  de comprimento  $n$ , onde cada elemento  $R_i$  é calculado da seguinte maneira:

$$R_i = \begin{cases} slopeLeft(x), i < k \\ 1, i = k \\ slopeRight(x), i > k \end{cases} \quad (12)$$

Exemplos de retorno da função conforme os dados fornecidos:



Figura 17 - Alisamento de três pontos pela função quadrática comparado com pesos originais ( $k = 5$ ,  $n = 11$ ).




Figura 18 - Alisamento de três pontos pela função quadrática comparado com pesos originais ( $k = 8$ ,  $n = 11$ ).

## ESCALONAMENTO DA ANOTAÇÃO COM RECURSO À INTENSIDADE DO SINAL

Além disso, por meio da análise da intensidade do sinal dentro de cada anotação de *slice*, é possível realizar uma estimativa da escala da anotação do tumor com maior confiança, visando produzir uma anotação com maior fidelidade. Isto não permite apenas identificar a localização aproximada da *slice* com a maior área do tumor representada, mas também capturar as variações de intensidade ao longo do tumor. Nesse sentido, utilizando as técnicas de normalização de valores anteriormente descritas, foram desenvolvidas duas propostas que incorporam essas abordagens.

Ao analisar os valores de intensidade e determinar os valores máximos e mínimos, é praticável calcular a intensidade do sinal normalizado, denominada de *bias*, obtido durante a normalização de cada valor  $x$  em relação aos extremos como demonstra a Fórmula (13). O *bias* é um elemento determinante do sucesso do redimensionamento da anotação. Este é o valor normalizado da intensidade do sinal em cada *slice*, permitindo fazer uma estimativa da dimensão e localização do tumor.

Adicionalmente, com a utilização das funções mencionadas anteriormente, é possível calcular a escala final de cada *slice* por meio da anotação original, escalando-a em cada valor como mostra a Fórmula (14).

**Seja:**

$A$  – um array de comprimento  $n$ ,  
 $\min$  – o valor mínimo de  $A$ ,

$\max$  – o valor máximo de  $A$ ,  
 $k$  – o índice do valor máximo em  $A$ .

$$bias = \frac{x - \min}{\max - \min} \quad (13)$$

A função final utiliza as funções anteriormente definidas (*slopeLeft()* e *slopeRight()*) retornando um novo *array R* de comprimento  $n$ , onde cada elemento  $R_i$  é calculado através a Fórmula (14).

$$R_i = \begin{cases} slopeLeft(x) + (1 - slopeLeft(x) * bias), i < k \\ 1, i = k \\ slopeRight(x) + (1 - slopeRight(x) * bias), i > k \end{cases} \quad (14)$$

A Figura 19 representa os resultados, tanto através da normalização da intensidade do sinal com recurso á normalização natural representado a (laranja, linha contínua e cruces nos pontos), comparando com os valores gerados com recurso á normalização quadrática por (azul, linha picotada e pontos redondos). Adicionalmente é mostrado o *bias* para cada *slice* (a verde, linha contínua e pontos redondos), de modo a demonstrar a importância da Fórmula (14).




Figura 19 - Resultado da normalização da intensidade do sinal no paciente 229 ( $k = 7$ ,  $n = 20$ ).

### 3.2.3. Redimensionamento das slices

Cada valor obtido no subcapítulo anterior, com a aplicação da Fórmula (14), ter-se-á aplicado um redimensionamento das anotações a cada *slice*. Estes valores servirão também para retirar as *slices* que seriam redimensionadas abaixo de um certo limite, sendo que se pertencerem abaixo desse limite não seriam empregues e não contabilizadas para o treino do modelo. A Figura 19 não representa um mapeamento direto entre a escala da anotação nem da intensidade do sinal, mas sim um valor criado através das duas variáveis. Este valor é uma aproximação do valor real á qual a escala tem de ser adaptada para circunscrever o tumor na perfeição. Estes valores gerados multiplicados darão uma aproximação das dimensões da anotação original. O limite mínimo considerado de uma anotação foi de 0.71, valor escolhido de modo a considerar *slices* que no mínimo são escaladas a menos de metade da área da anotação inicial. É de notar que um redimensionamento de 0.5, ou seja, dividir a metade as dimensões de altura e largura da anotação para metade, resultaria numa redução de área de 75%. Para obter um redimensionamento da área de 50%, ou seja, a área resultante do redimensionamento ser reduzida a metade, deve-se aplicar uma escala da altura e largura da *slice* de  $\approx 0.71$  visto que a área resultante de um quadrado com os lados a medir 0.7071..., iria possuir uma área de 0.5. Portanto para um retângulo ter-se-á de aplicar a Fórmula (15), alterando a variável  $m$  para 0.5. A Figura 20 mostra o resultado do redimensionamento da anotação (a verde ou o quadrado mais exterior a anotação inicial, a vermelho ou o quadrado mais pequeno, a anotação gerada pelo pré-processamento).




Figura 20 - Redimensionamento da anotação de uma *slice*.

**Sendo:**

$A$  – área da anotação,

$L$  – comprimento da anotação,

$W$  – largura da anotação,

$x$  – o fator de escala pretendido,

$s$  – o fator de escala a aplicar ao comprimento e largura

Temos:

$$A = L \cdot W$$

$$\Leftrightarrow A \cdot x = x \cdot (L \cdot W)$$

$$\Leftrightarrow A \cdot x = \sqrt{x} \cdot \sqrt{x} \cdot (L \cdot W)$$

$$\Leftrightarrow A \cdot x = (L \cdot \sqrt{x}) \cdot (W \cdot \sqrt{x})$$

$$A \cdot x = (L \cdot s) \cdot (W \cdot s), \quad \text{c.q.m. } s = \sqrt{x}$$

( 15 )

#### 3.2.4. Detecção dos centroides

Com a manipulação da anotação da *slice* através do redimensionamento da mesma, em alguns casos o centro do tumor representado através das várias *slices* não permanece o mesmo, ou seja, o tumor tem um formato mais complexo e por isso a anotação inicial não representa o centro do tumor ao longo das *slices*. Portanto, para corrigir esse comportamento foi utilizado o software OpenCV (Open Source Computer Vision Library), uma biblioteca de software de código aberto para visão por computador e aprendizagem automática, através de uma biblioteca (módulo) Python denominada por CV2. Com recurso a CV2 se realizou a deteção de centroides. Esta biblioteca deteta contornos em imagens (representadas por matrizes). Deste modo é possível analisar o contorno e detetar o seu centroide. A Figura 21 demonstra a utilização da mesma, mostrando a preto o contorno detetado do tumor e a vermelho um círculo ao redor do centroide da anotação do tumor. Caso ocorra mais do que uma deteção de centroide, é considerado o que apresentar maior dimensão.

Com a translação da anotação para o ponto correto do centro do tumor, é considerado que podem ocorrer translações que não respeitem os limites da anotação inicial. Por esta razão e sabendo que a anotação inicial é a anotação na qual temos mais confiança

tratando-se de uma anotação feita por médicos especialistas, a translação nunca excede os limites posicionais da anotação inicial, fazendo uma translação no máximo aos limites da anotação inicial.




Figura 21 – Centro do centroide demarcado por círculo de raio de 5 pixéis e contorno do tumor detetado pela biblioteca cv2.

Caso a biblioteca CV2 não detete nenhum contorno, não será possível calcular um centroide, portanto é calculado o centroide dos valores na anotação inteira sem o uso de bibliotecas externas através da Fórmula (19). Essa fórmula é composta pelas Fórmulas (17) e (18), que por sua vez dependem da Fórmula (16).

**Seja:**

$I(x, y)$  – a intensidade do valor no pixel com coordenadas  $(x, y)$ ,

**Sabendo que:**

$$Intensidade\ do\ sinal = \sum_{i=ri}^{rf} \sum_{j=ci}^{cf} Slice[i][j], \quad (definida\ anteriormente)$$

**( 16 )**

$$\bar{x} = \frac{\sum_x \sum_y x * I(x, y)}{\sum_x \sum_y I(x, y)}, \quad adaptado\ de\ (\"Calculus\ II\ -\ Center\ of\ Mass,\" n. d.)$$

**( 17 )**

$$\bar{y} = \frac{\sum_x \sum_y y * I(x, y)}{\sum_x \sum_y I(x, y)}, \quad \text{adaptado de ("Calculus II – Center of Mass," n. d.)}$$

( 18 )

Calcula-se as coordenadas do centroide na anotação da imagem através de:

$$Centroide(\bar{x}, \bar{y}) = (\bar{x}, \bar{y})$$

( 19 )

### 3.3. Implementação

No contexto da detecção de objetos, a seleção das ferramentas de desenvolvimento desempenha um papel crucial no processo de criação eficiente e bem-sucedida da implementação prática para alcançar os objetivos estabelecidos inicialmente.

Entre as diversas *frameworks* disponíveis para a criação de modelos de detecção de objetos, o Tensorflow destaca-se por ser uma base sólida no desenvolvimento de soluções personalizadas e eficientes de Inteligência Artificial. No entanto, existem alternativas igualmente equiparáveis, como por exemplo o PyTorch. Iniciado em 2015, o Tensorflow é um framework desenvolvida pela Google, que permite o desenvolvimento de modelos de redes de neurónios profundas com alto desempenho, incluindo modelos de detecção de objetos, com uma metodologia bem documentada e de fácil implementação.

A integração entre Python e Tensorflow é notável na detecção de objetos. O Tensorflow oferece *APIs* especializadas como a Tensorflow Object Detection API, utilizada neste projeto, que simplifica o ciclo de desenvolvimento ao fornecer modelos pré-treinados e ferramentas essenciais para a implementação de soluções personalizadas.

Além disso, foi desenvolvido um script em Python para o pré-processamento dos dados, formatando-os de maneira ideal para o processamento e realizando o tratamento necessário para o treino do modelo no TensorFlow. Esse script desempenha um papel essencial na preparação dos dados de entrada, garantindo que estejam corretamente formatados e prontos para atender aos requisitos do TensorFlow. Todo o código fonte

pode ser visualizado em: [https://github.com/AntonioPint/medical\\_images\\_uploader](https://github.com/AntonioPint/medical_images_uploader).

Algumas bibliotecas, como CV2 (OpenCV), Keras, Matplotlib, Plotly, e Numpy, foram utilizadas para auxiliar o desenvolvimento do script de pré-processamento e visualização das imagens dos casos de pacientes. Isso é especialmente importante, considerando a complexidade adicional que as imagens médicas podem apresentar em relação a desafios já resolvidos pelas bibliotecas, como manipulação de dados e conversões de formatos, entre outros.

### 3.3.1. Linguagem de implementação

#### **Python**

Todas as implementações práticas deste projeto, incluindo a elaboração do script de pré-processamento e a implementação da ferramenta de visualização e previsão de tumores, foram realizadas utilizando a linguagem de programação Python. Python é uma linguagem de alto nível, versátil e interpretada, criada por Guido van Rossum em 1991. A sua popularidade crescente deve-se à sua sintaxe simples e legível, tornando-a uma escolha ideal tanto para iniciantes quanto para programadores experientes que procuram desenvolver aplicações complexas de forma eficiente.

Além disso, Python é amplamente reconhecido no campo da Inteligência Artificial (AI) devido à sua rica variedade de *frameworks* e bibliotecas robustas. O uso extensivo das bibliotecas Python, desenvolvidas pela comunidade, é crucial para a criação de aplicações eficientes e inovadoras, especialmente no domínio da AI. A facilidade de interpretação do Python agrega um valor significativo ao desenvolvimento de algoritmos complexos em conjunto com *frameworks* populares como Tensorflow e PyTorch, Python contribui para o avanço contínuo no desenvolvimento de soluções de AI, sendo a escolha preferida por muitos profissionais e cientistas neste campo. Essa combinação de simplicidade e versatilidade faz do Python uma ferramenta de eleição no desenvolvimento de aplicações avançadas de AI.

#### **Bibliotecas Python**

A reutilização de código, rapidez de desenvolvimento e integração de código pré-construído são algumas das vantagens que as bibliotecas proporcionam no

desenvolvimento de código. As bibliotecas para Python utilizadas neste projeto servem vários propósitos. Algumas apresentam funcionalidades especializadas, que podem ser facilmente utilizadas sem desenvolver código adicional, enquanto outras implementam funcionalidades essenciais para o desenvolvimento de aplicações.

Algumas das bibliotecas utilizadas:

- CV2 (OpenCV) - Biblioteca essencial para visão por computador (VC) e processamento de imagens em Python.
- Pydicom - Facilita a manipulação e análise de arquivos DICOM, frequentemente utilizado em imagens médicas.
- Numpy - Fundamental para a computação numérica, proporcionando *arrays* eficientes e funções matemáticas.
- Xml - Módulo padrão na análise e criação de documentos XML em Python.
- Pandas - Ferramenta para a manipulação e análise de dados, especialmente em formato tabular.
- Pillow - É utilizado para processamento de imagens, com suporte a diversos formatos.
- Pyinstaller - Converte programas Python em executáveis independentes, facilitando a distribuição dos mesmos.
- Plotly - Biblioteca para a criação de gráficos interativos, contribuindo para visualizações atraentes.

O CV2 (OpenCV) é uma biblioteca amplamente reconhecida para a visão por computador e processamento de imagens em Python. Oferece um vasto leque de funcionalidades, como detecção de objetos, reconhecimento de padrões, transformações geométricas e análise de vídeos em tempo real. Isso torna-a uma ferramenta indispensável em projetos de visão por computador. Por sua vez, o Pydicom facilita a manipulação de arquivos DICOM, um padrão comumente usado em imagens médicas, como ressonâncias magnéticas e tomografias, permitindo que os utilizadores acessem, modifiquem e analisem dados médicos com eficiência.

O Numpy é uma biblioteca essencial para a computação numérica em Python, fornecendo *arrays* multidimensionais de alto desempenho e uma ampla gama de funções

matemáticas. É fundamental para bibliotecas científicas, como Pandas e SciPy, sendo crucial em áreas como álgebra linear, análise de dados e aprendizado de máquina. O módulo Xml, parte da biblioteca padrão do Python, simplifica a criação e análise de documentos XML, facilitando a manipulação de dados estruturados. Já o Pandas é uma ferramenta poderosa para a manipulação e análise de dados, especialmente em formatos tabulares. Ele oferece estruturas de dados robustas, como os DataFrames, que tornam o processamento de grandes volumes de dados eficiente, sendo amplamente utilizado em ciência de dados e estatísticas.

A biblioteca Pillow é focada no processamento de imagens, com suporte para vários formatos populares, como PNG, JPEG e GIF, sendo amplamente empregada em aplicações que exigem manipulação de imagens, desde tarefas simples até transformações mais avançadas. O PyInstaller, por sua vez, é uma ferramenta que converte scripts Python em executáveis independentes, simplificando a distribuição de aplicações, eliminando a necessidade do utilizador final ter o Python instalado. Por fim, o Plotly é uma biblioteca de visualização de dados que permite criar gráficos interativos e esteticamente atraentes. É amplamente utilizada para apresentações e análises exploratórias de dados, especialmente quando há a necessidade de gerar visualizações dinâmicas diretamente em navegadores.

### *3.3.2. Frameworks Python para Aprendizagem Máquina*

Frameworks para Aprendizagem Máquina são ferramentas essenciais para desenvolvedores e pesquisadores na área que procuram a criação de modelos ML eficientes e escaláveis. Python é uma linguagem que devido à sua sintaxe simples toma partido de uma vasta comunidade de desenvolvedores que concebem bibliotecas e as mantêm com frequência, aumentando a relevância da linguagem.

TensorFlow é uma poderosa framework de Machine Learning (ML) e Deep Learning (DL) desenvolvida pela Google, amplamente reconhecida pela sua flexibilidade e escalabilidade. A sua versatilidade torna-a adequada para uma ampla gama de projetos, desde os mais simples até aos mais complexos. Além disso, TensorFlow é altamente escalável, permitindo que os utilizadores explorem desde tarefas de treino em máquinas locais até implementações em ambientes distribuídos e em grande escala.

Uma característica insigne do TensorFlow é a sua ferramenta integrada de visualização de características do modelo, o TensorBoard. Esta ferramenta é valiosa para compreender e otimizar o desempenho dos modelos durante o treino. O TensorBoard facilita a análise de métricas, visualização de grafos computacionais e monitoramento em tempo real, contribuindo para um treino supervisionado mais eficiente e compreensível.

Além disso, o ecossistema TensorFlow oferece sub-módulos especializados que atendem a necessidades específicas. O TensorFlow Lite, por exemplo, é projetado para implementações em aplicações móveis, permitindo a execução eficiente de modelos em dispositivos com recursos limitados. Já o TensorFlow.js possibilita o desenvolvimento de modelos para execução em navegadores web, abrindo oportunidades para aplicações interativas e inovadoras na web.

Outras características importantes do TensorFlow incluem o suporte a uma variedade de dispositivos de hardware, incluindo GPUs e TPUs, bem como a presença de uma comunidade ativa e colaborativa.

### 3.3.3. Script de Pré-processamento

O script de pré-processamento desempenha um papel crucial na manipulação e leitura dos dados originais, com o intuito de gerar dados pré-processados conforme o algoritmo delineado no início deste capítulo. Este script, implementado em Python, segue o fluxo de trabalho descrito na Figura 22, iniciando-se com a leitura de um arquivo de configurações denominado “*config.ini*”. Como alternativa, é possível fornecer um outro arquivo de configurações como parâmetro do script utilizando o argumento “-c”, seguido do nome do arquivo desejado. Um exemplo de arquivo de configurações, está disponível no Anexo I, possibilita a modificação do comportamento do script de pré-processamento através da alteração das variáveis nele contidas. É possível alterar a diretoria em que as imagens são originárias e a diretoria destinada para os dados pré-processados. Isso concede a flexibilidade de executar o script em qualquer diretoria do sistema, tornando-a maleável e configurável. Outras opções incluem a escolha dos pacientes a serem processados, permitindo a divisão do script em várias execuções para fins de teste e segmentação da execução. Também são apresentadas configurações para a separação de

imagens, tanto em *folds* quanto em splits de treino, teste e validação. Por fim é fornecida uma configuração que possibilita a alteração do fator de escala mínima em relação á anotação original, removendo as imagens com anotações abaixo do fator de escala escolhido.

Este ficheiro de configuração foi concebido com o intuito de melhorar a eficiência de implementação, permitindo a realização de testes em pequenas secções de código sem processar todas as imagens médicas de uma só vez. A capacidade de executar múltiplos arquivos de configuração possibilitou a realização de testes em diversos cenários, verificando assim o correto funcionamento do script na sua concepção.




Figura 22 – Fluxo do script de pré processamento

Após a leitura das configurações do script, é realizado um filtro que exclui as diretorias que não possuem qualidade na representação do tumor. Essas passagens, geralmente conduzidas por médicos especialistas, costumam ser passagens iniciais que visam aperfeiçoar parâmetros como o contraste e brilho, entre outras configurações da máquina de ressonância magnética (MRI). Essa otimização é realizada com o objetivo de obter uma imagem mais nítida e clara do tecido tumoral, contribuindo para uma análise mais precisa durante o processo de pré-processamento.

A próxima etapa envolve a análise de uma passagem total da ressonância magnética de um paciente, esse processo é repetido de forma a examinar todas as passagens de todos os pacientes. Durante essa etapa, é criada uma *thread* para realizar o cálculo da

intensidade do sinal, a escala da anotação, detecção do centroide e a posição da anotação para uma determinada passagem de um paciente. As operações detalhadas em 3.2.2 são executadas com o propósito de calcular e aplicar a anotação à imagem. Nesta etapa, é selecionado o algoritmo de normalização e distribuição dos pesos das anotações, levando em consideração as características da informação disponível. A escolha do algoritmo é baseada na incerteza relacionada à *slice* com maior representação do tumor, ou seja, a *slice* na qual a anotação foi originalmente baseada. Dado que essa informação não é fornecida, é calculada através da intensidade do sinal e confirmada posteriormente através da performance dos modelos com os dados processados pelos dois algoritmos.

A desvantagem desta abordagem é a inclusão de mais imagens que possuem anotações com dimensões semelhantes à original, podendo não refletir precisamente a realidade e não representar satisfatoriamente o tecido tumoral. Ainda assim apresenta uma melhoria considerável ao adaptar as anotações às dimensões do tumor. No entanto, essa abordagem é mais conservadora e a que apresenta os melhores resultados e, portanto, escolhida.

Outro parâmetro essencial é a escolha do valor mínimo da escala da anotação. Devido à baixa certeza de representação das camadas limites do tumor, torna-se necessário excluir essas camadas. Para atingir esse objetivo, foi escolhido um valor mínimo de escala de 0.71 ou  $\sqrt{0.5}$ , utilizado no processo de filtragem para eliminar as camadas que não atingem esses limites e para redimensionar as anotações das mesmas. E explicado o valor escolhido no subcapítulo 3.2.3.

Em seguida, aplica-se o fator de escala do comprimento e largura da anotação, reduzindo assim a sua escala pelo fator  $s$ , reduzindo a sua área pelo fator  $x$ , Fórmula (15). A redução das dimensões da anotação implica a realização de uma translação, de maneira a ajustar o centro da anotação para o centroide do tumor. É crucial garantir que o limite da anotação depois da translação, esteja contido nos limites originais da anotação original.

Por fim, o processo é concluído com o armazenamento das imagens e as respectivas anotações, ambas com o mesmo nome de arquivo, apenas diferendo na extensão de arquivo. As imagens são guardadas em formato JPG com um canal de cor 8 bits, utilizando escala cinzenta e mantendo as dimensões originais. Essa escolha específica de

utilizar a escala de cinzentos tem a vantagem de reduzir o tamanho das imagens, sem comprometer a qualidade da imagem. Essa redução de tamanho é um benefício no treino do modelo, uma vez que resulta em menos cálculos computacionais, otimizando assim a eficiência do processo de treino. As anotações correspondentes a cada imagem são guardadas em formato XML, seguindo a estrutura de exemplo demonstrado no Anexo II.

No desfecho do processo, as imagens são divididas em partições, conduta essencial para o treino do modelo para a obtenção de previsões via inferência. Essa divisão é manipulada de maneira flexível através do ficheiro de configurações em Anexo I, permitindo a adaptação conforme as necessidades específicas do projeto. A estratégia de repartição agrupa um único paciente em apenas uma das secções. Essa abordagem visa prevenir o *overfitting* do modelo, garantindo que o processo de teste e validação seja conduzido sem a visualização antecedente de imagens do mesmo paciente no qual o modelo foi treinado. Para o teste e validação do modelo, foi adotada uma repartição com a proporção 10% para teste e 10% para validação, reservando 80% para treino de modo a fornecer uma amostragem significativa para fazer um treino do modelo significativo. As repartições das imagens são detalhadas conforme é possível analisar na Tabela 4 que detalha a repartição das imagens.

Tabela 4 – Repartição das imagens e pacientes com um rácio de treino de 80% e rácio de teste e validação de 20%, 10% para cada um respetivamente. [Retirada de Anexo III].

|                               | Treino        | Teste       | Validação   |
|-------------------------------|---------------|-------------|-------------|
| Número de pacientes           | 737           | 92          | 93          |
| Número de imagens             | 61 656        | 7 208       | 6 726       |
| Número total de ficheiros     | 123 312       | 14 416      | 13 452      |
| Tamanho dos ficheiros (bytes) | 1 357 740 662 | 156 410 602 | 150 616 341 |

### 3.3.4. Resultados do pré-processamento

Aplicando o pré-processamento a cada *slice* tem-se a Figura 23 que demonstra as diferentes anotações com diferentes disposições espaciais: anotação original e anotação pós-processamento. Na Figura 23 A é mostrada a posição espacial do tumor. O espaço ( $x$ ,  $y$ ,  $z$ ) representado através de um espaço a cinzento representam área analisada presente nas imagens médicas, mostrando a vermelho a anotação original e a azul a anotação pós

processamento. Para analisar melhor as anotações foi aplicado um zoom á imagem e uma translação de 50 pixéis a uma das anotações (a translação não influencia as anotações, apenas a representação visual) com a intenção de melhor demonstrar as diferenças entre as duas anotações dispondo a anotação original e a gerada lado a lado na Figura 23 B. A vermelho do lado esquerdo, é possível analisar a anotação original da imagem. A azul é possível analisar as alterações de translação da anotação, corte de *slices* e redimensionamento de *slices*.




Figura 23 - Disposição espacial das anotações antes e depois do processamento.

## Capítulo 4

### Resultados

De forma a validar o sucesso do projeto foram realizadas várias comparações aos resultados antes e depois do pré-processamento gerado pela análise inovadora de imagens proposta neste projeto, com o objetivo de comparar e confirmar a melhoria da precisão do modelo através da extração de dados que o algoritmo efetua, proporcionando resultados positivos provenientes do processo de validação do modelo através comparação dos resultados fornecidos da avaliação do modelo pela framework Tensorflow. Para efeitos de validação, um script foi criado permitindo comparar as anotações que o modelo gera com a anotação original através da visualização da imagem com ambas anotações.

Finalmente uma ferramenta conceptual foi criada permitindo fazer uma previsão automática através da inserção de fotos com o formato original DICOM (.dcm) e o carregamento de um modelo proveniente do treino de imagens médicas, com o propósito de efetuar a deteção, seja ela positiva ou negativa da existência de tecido tumoral nas imagens médicas.

#### 4.1. Dados de treino, teste e validação

A divisão do conjunto de dados em treino, teste e validação desempenha um papel crucial no desenvolvimento de modelos de aprendizagem de máquina eficazes. Essa divisão permite que o modelo seja exposto a uma variedade de exemplos durante o treino, que ajuda a aprender padrões e ajustar os seus parâmetros de forma progressiva. O conjunto de validação é usado para avaliar o desempenho do modelo após o treino e para ajustar os hiperparâmetros, já que não existe uma solução única que funcione para todos os conjuntos de dados e modelos. A utilização do conjunto de validação ajuda a reduzir a probabilidade de *overfitting*, pois o modelo não é treinado exclusivamente num único conjunto de dados. O teste do modelo com o conjunto de teste é realizado para verificar se a melhoria feita no modelo após o treino se traduz num bom desempenho em dados não treinados pelo modelo.

Para este propósito, o conjunto de dados foi dividido em três conjuntos distintos: 80% para treino, 10% para teste e 10% para validação, conforme apresentado na Tabela 4 e 5. Essa divisão proporciona ao modelo uma quantidade substancial de casos para treinar, testar e validar, estabelecendo uma base sólida para a sua performance.

É crucial ressaltar que essa divisão foi realizada agrupando todas as passagens de um paciente num só único conjunto, garantindo assim uma representação mais fiel nos dados de treino mantendo a variabilidade nos dados. Esta estratégia de divisão adequada assegura que o modelo seja robusto e capaz de generalizar bem para novos dados de pacientes não anteriormente vistos, resultando em previsões mais precisas e confiáveis em cenários do mundo real. Além disso, para avaliar os resultados das diferentes técnicas de pré-processamento utilizadas, foi criado mais um *dataset* de dados pré-processados a partir do conjunto de dados original, totalizando três *datasets* de dados distintos contando com o original. Essa abordagem permite avaliar como as diferentes técnicas de pré-processamento impactam o desempenho dos modelos de aprendizagem de máquina.

Os conjuntos de dados distinguem-se pelo *dataset* original, onde os dados das anotações originais foram totalmente considerados, totalizando um conjunto de 95 267 imagens. O conjunto de dados denominado "KeepHalf", proveniente da abordagem utilizada em [3], utiliza uma função que mantém uma porção central do *dataset*, neste caso específico, 52,99% provenientes da função de funil logarítmico com os valores  $a=0,75$  e  $b=1,9625$ , valores comunicados como os que originam um melhor resultado para este *dataset*. Finalmente, a abordagem proposta neste projeto utiliza os algoritmos propostos no Capítulo 3, denominado por "ImageAnnotationEnhanced". Todas as informações gerais dos conjuntos de dados gerados estão descritas na Tabela 5.

Tabela 5 – Comparação dos datasets Original, KeepHalf e ImageAnnotationEnhanced. [Retirada de Anexo III].

|                                  | Original |        |               | KeepHalf |       |               | ImageAnnotationEnhanced |        |               |
|----------------------------------|----------|--------|---------------|----------|-------|---------------|-------------------------|--------|---------------|
|                                  | Treino   | Teste  | Valida<br>ção | Treino   | Teste | Valida<br>ção | Treino                  | Teste  | Valida<br>ção |
| Pacientes                        | 737      | 92     | 93            | 737      | 92    | 93            | 737                     | 92     | 93            |
| Média de imagens<br>por paciente | 103,33   |        |               | 54,75    |       |               | 81,98                   |        |               |
| Total de imagens                 | 95 267   |        |               | 50 479   |       |               | 75 590                  |        |               |
| Total de ficheiros               | 155 368  | 18 232 | 16 934        | 82 250   | 9 654 | 9 054         | 123 312                 | 14 416 | 13 452        |

|                                      |               |              |              |              |              |              |                |              |              |
|--------------------------------------|---------------|--------------|--------------|--------------|--------------|--------------|----------------|--------------|--------------|
| <i>Rácio do dataset original (%)</i> | 100,00%       |              |              | 52,99%       |              |              | 79,35%         |              |              |
| <i>Tamanho dos arquivos (bytes)</i>  | 1 800 713 724 | 208 77 8 646 | 200 03 0 983 | 953 46 8 465 | 110 55 4 068 | 106 67 3 961 | 1 357 74 0 662 | 156 41 0 602 | 150 61 6 341 |

## 4.2. Modelos pré-treinados

Para avaliar a eficácia dos algoritmos de pré-processamento, o mesmo modelo foi utilizado para os diferentes *datasets*. Os modelos considerados estão disponíveis no TensorFlow 2 Detection Model Zoo, biblioteca de modelos que oferece uma ampla variedade de opções para diversas aplicações e tipos de dados.

Após um processo iterativo de avaliação de diferentes modelos, foram selecionados e treinados aqueles com características mais promissoras para a tarefa em questão. Entre eles, o modelo "faster-rcnn-v2-640x640" destacou-se como o mais eficaz. Apesar de apresentar uma velocidade de inferência relativamente menor, este demonstrou superioridade na precisão e desempenho, especialmente para as dimensões das imagens médicas analisadas. A escolha foi fundamentada através de uma análise comparativa detalhada dos resultados obtidos, comprovando a robustez e adequação desse modelo à tarefa específica.

## 4.3. Parâmetros de treino

### 4.3.1. Hiperparâmetros e aprendizagem

Os hiperparâmetros selecionados foram mantidos iguais entre os diferentes conjuntos de dados, com o intuito de garantir um nível de igualdade consistente nos diferentes treinos entre *datasets*, com a exceção do número de passos (steps). Estes foram calculados de forma a resultar na mesma quantidade de epochs entre os *datasets*. Além disso, foram mantidas as dimensões batch, o número máximo de classes e o número máximo de detecções, conforme demonstrado na Tabela 6.

A decisão de manter o número máximo de detecções a uma detecção foi tomada devido às limitações existentes no *dataset* original, sendo que neste apenas foi feita uma identificação do tecido tumoral, o qual apresentava a maior dimensão e apenas essa é

anotada. Isso significa que detecções positivas corretas de tecido tumoral poderiam ser classificadas como detecções inadequadas, o que poderia prejudicar o treino e a precisão do modelo.

Tabela 6 – Hiperparâmetros e características de treino. [Retirada de Anexo III].

|                               | Original              |       |           | KeepHalf              |       |           | ImageAnnotationEnhanced |       |           |
|-------------------------------|-----------------------|-------|-----------|-----------------------|-------|-----------|-------------------------|-------|-----------|
|                               | Treino                | Teste | Validação | Treino                | Teste | Validação | Treino                  | Teste | Validação |
| Epochs                        | 84                    |       |           | 84                    |       |           | 84                      |       |           |
| Número de steps               | 505 000               |       |           | 265 000               |       |           | 400 000                 |       |           |
| Dimensão de Batch             | 16                    |       |           | 16                    |       |           | 16                      |       |           |
| Número de classes             | 1                     |       |           | 1                     |       |           | 1                       |       |           |
| Número Máximo de Detecções    | 1                     |       |           | 1                     |       |           | 1                       |       |           |
| Máxima Taxa de Aprendizagem   | 0,05                  |       |           | 0,05                  |       |           | 0,05                    |       |           |
| Função de Aprendizagem        | Decaimento de cosseno |       |           | Decaimento de cosseno |       |           | Decaimento de cosseno   |       |           |
| Função de Pontuação           | Softmax               |       |           | Softmax               |       |           | Softmax                 |       |           |
| Tempo de treino (dd:hh:mm:ss) | (01:20:55:41)         |       |           | (00:22:30:30)         |       |           | (01:10:32:10)           |       |           |

#### 4.3.2. Taxa de aprendizagem

A taxa de aprendizagem máxima foi definida como 0.05, iniciando em 0.025 e diminuindo até 0 utilizando a função decaimento de cosseno, conforme ilustrado na Figura 24. Esta estratégia permite que o modelo faça mudanças rápidas nos valores dos parâmetros no início do treino para convergir para valores ótimos mais rapidamente. Nas fases finais do treino, a taxa de aprendizagem diminui gradualmente, resultando em mudanças mais pequenas nos valores dos parâmetros para garantir uma melhor precisão.




Figura 24 – Taxa de aprendizagem ao longo dos steps com a função de aprendizagem Decaimento de cosseno aproximando um mínimo.

### 4.3.3. Data Augmentation

Além dos parâmetros destacados, foram utilizadas opções de *data augmentation* para aumentar a quantidade e a variabilidade dos dados. As opções selecionadas incluem inversão da imagem no sentido horizontal, inversão de imagem no sentido vertical e rotação de 90 graus. Cada uma dessas opções tem uma probabilidade de ocorrência de 50%. Além disso, é realizado um corte e escala aleatórios, variando a escala desde o valor 1 a 1.5, formando um quadrado com dimensões de lado de 640 pixels. Essas técnicas de *data augmentation* ajudam a diversificar o conjunto de dados de treino, tornando o modelo mais robusto e capaz de lidar com diferentes variações nos dados de entrada durante o treino do modelo.

## 4.4. Treino dos modelos

Tendo todos os parâmetros definidos, é iniciada a fase de treino do modelo para detecção de objetos. O dispositivo utilizado para o treino dos modelos denominado por *VISION* está localizado no Laboratório VISTA, Centro de Investigação da Universidade de Évora. Este é um supercomputador com grande capacidade computacional, necessário para o treino dos conjuntos de dados em questão. As especificações deste sistema estão detalhadas na Tabela 7.

Tabela 7 - Especificações do sistema *VISION* com CPUs, GPUs e detalhes de memória pertencente ao VISTA Lab, Centro de Investigação da Universidade de Évora, Portugal.

| COMPONENTES        | ESPECIFICAÇÃO                        |
|--------------------|--------------------------------------|
| CPU                | Dual AMD Rome 7742                   |
|                    | Cores: 128                           |
| MEMÓRIA DE SISTEMA | 1 TB                                 |
| GPUS               | NVIDIA A100 Tensor Core GPU          |
|                    | Número de Cores: 8                   |
|                    | Cores por GPU: 6912 (total 55296)    |
|                    | Memória por GPU: 40 GB (total 320GB) |

Durante o treino, é possível observar a saída fornecida pelo TensorFlow, que é armazenada em *logs*. O TensorFlow também fornece uma interface gráfica chamada de TensorBoard, que permite a análise em tempo real de várias variáveis de treino, como perda de classificação, perda total, taxa de aprendizagem e algumas das imagens analisadas durante o processo de treino, conforme ilustrado na Figura 25. No final do

treino, o modelo é avaliado com os dados de teste até que um resultado satisfatório seja alcançado, por meio da manipulação dos hiperparâmetros.

Após encontrar os parâmetros ideais, os conjuntos de dados restantes são treinados com essas configurações para que seja possível medir a diferença entre os algoritmos de pré-processamento. Devido à diferença na quantidade de dados a serem processados, os treinos podem levar tempos diferentes, como é possível observar na Tabela 6.




Figura 25 – TensorBoard e métricas em ao longo do tempo do treino do modelo

## 4.5. Resultados

A análise dos resultados da Tabela 8 revela uma notável melhoria na precisão dos modelos treinados com dados pré-processados, tanto utilizando a abordagem do algoritmo KeepHalf como o algoritmo ImageAnnotationEnhanced. Embora os modelos treinados com o algoritmo ImageAnnotationEnhanced apresentem pontuações menores de mAP, mRecall e Total Loss em comparação com o modelo treinado com o algoritmo KeepHalf, o ImageAnnotationEnhanced supera em todas as outras métricas de desempenho do modelo. Isso pode ocorrer devido a diferenças nos tamanhos das anotações, já que a margem de erro de uma anotação é maior quanto menor for sua dimensão. Apesar de os hiperparâmetros serem iguais para todos os modelos, pode haver casos de *overfitting* e *underfitting* em alguns, destacando a necessidade de aperfeiçoar os hiperparâmetros a ser utilizados.

Os resultados mostram que, de modo geral, os modelos treinados com os dados pré-processados obtiveram melhorias significativas na precisão do IoU (Intersection over Union) em diferentes *thresholds*, bem como um aumento notável na mAP (Mean Average Precision) em relação aos modelos treinados com os dados originais. Esses resultados indicam que o pré-processamento dos dados, seja com o algoritmo KeepHalf ou o ImageAnnotationEnhanced, contribuíram de forma positiva para o desempenho dos modelos, resultando numa melhor capacidade de generalização e detecção de objetos.

É importante observar que o *dataset* utilizado na análise não contém casos de verdadeiros negativos. Os verdadeiros negativos representam os casos em que o modelo classifica corretamente uma instância negativa como negativa. Embora possa parecer contraintuitivo, a presença de verdadeiros negativos é crucial para uma avaliação completa do modelo, pois fornece uma medida da sua capacidade de distinguir corretamente entre classes positivas e negativas. A ausência de verdadeiros negativos pode dificultar a avaliação do desempenho do modelo em situações reais e pode resultar numa análise incompleta da sua eficácia. Portanto, é importante garantir que os *datasets* utilizados na avaliação de modelos contenham uma representação equilibrada de todas as classes relevantes.

Tabela 8 - Resultados do treino dos modelos de cada algoritmo (Anexo III).

|                              | <i>Original</i> | <i>KeepHalf</i> | <i>ImageAnnotationEnhanced</i> |
|------------------------------|-----------------|-----------------|--------------------------------|
| <i>Precisão@IOU&gt;=0.5</i>  | 64,5%           | 73,1%           | 82,8%                          |
| <i>Precisão@IOU&gt;=0.75</i> | 20,4%           | 30,1%           | 37,6%                          |
| <i>mAP</i>                   | 0,0220          | 0,0681          | 0,0444                         |
| <i>mAP@IOU&gt;=0.5</i>       | 0,0920          | 0,2746          | 0,1802                         |
| <i>mIOU</i>                  | 0,2664          | 0,3494          | 0,3498                         |
| <i>mRecall</i>               | 0,0770          | 0,1356          | 0,1001                         |
| <i>Total Loss</i>            | 0,2243          | 0,2284          | 0,2529                         |

É importante ter em consideração diferentes *thresholds* de IoU durante a avaliação do desempenho do modelo. Tradicionalmente,  $\text{IoU} \geq 0.5$  é frequentemente utilizado como um limiar mínimo para considerar uma detecção como correta. No entanto, um IoU maior, como  $\text{IoU} \geq 0.75$ , é ainda mais rigoroso e indica uma detecção mais precisa, exigindo uma sobreposição mais significativa entre a região prevista e a região verdadeira do objeto.

ImageAnnotationEnhanced tem melhor desempenho em termos de precisão em ambos os limites de IOU (0,5 e 0,75) e tem o mIOU mais alto, indicando desempenho de localização superior. KeepHalf tem o melhor mAP e sensibilidade/recall, sugerindo um bom equilíbrio entre encontrar objetos e prever caixas delimitadoras precisas. O modelo com o *dataset* original tem a menor perda total, mas isso não se traduz no melhor desempenho nas principais métricas.

## 4.6. Validação de Resultados

A validação cruzada, ou *k-fold cross validation*, é uma técnica extensamente utilizada para avaliar modelos de aprendizagem máquina. Esta envolve o treino de vários modelos utilizando subconjuntos distintos do conjunto de dados como lotes de teste, com o objetivo de testar o modelo em todo o conjunto de dados e avaliar sua capacidade de aprendizagem e generalização. Os hiperparâmetros do modelo são mantidos constantes durante todo o processo de validação cruzada para garantir uma comparação justa entre os diferentes *folds*. A Figura 26 demonstra esquematicamente o processo do *10-fold cross validation*, onde o conjunto de dados é dividido em 10 *folds*, e em cada iteração, 9 *folds* são usados para treino e 1 *fold* é usado para teste, garantindo que todo o conjunto de dados seja utilizado tanto para treino quanto para teste em diferentes momentos. Essa abordagem proporciona uma avaliação mais robusta do desempenho do modelo, ajudando a evitar problemas como *overfitting* ou sub-ajuste, e fornecendo uma estimativa mais precisa da capacidade de generalização do modelo.




Figura 26 – Esquematização de 10-Fold Cross Validation. Retirado de [3]

A Tabela 9 mostra os resultados da validação cruzada com 10 folds, incluindo os resultados de cada fold, além da média e do desvio padrão para cada métrica.

Ao analisar os resultados, é possível observar uma consistência no desempenho do modelo em diferentes divisões dos dados. A *fold* 1 destaca-se por apresentar os melhores resultados em comparação com as restantes *folds*, apresentando uma precisão de previsão de 90,2%, um valor de mIoU (*mean IoU*) de 0,390 e um *mScore* de 0,274.

A média das métricas para todos os *folds* também é fornecida, permitindo uma visão geral do desempenho médio do modelo durante a validação cruzada. O desvio padrão (STD DEV) indica a dispersão dos resultados em relação à média, fornecendo insights sobre a consistência dos resultados entre os *folds*.

Em resumo, os resultados da Tabela 9 sugerem um excelente desempenho do modelo em termos de precisão em todos os *folds*, com destaque para a *fold* 1 pelos melhores resultados individuais. A uniformização das informações entre os *folds* indica uma boa capacidade de generalização do modelo em diferentes divisões dos dados.

Tabela 9 – Cross Validation de cada 10-fold.

|                    | Fold1 | Fold2 | Fold3 | Fold4 | Fold5 | Fold6 | Fold7 | Fold8 | Fold9 | Fold10 | Média | STD<br>DEV |
|--------------------|-------|-------|-------|-------|-------|-------|-------|-------|-------|--------|-------|------------|
| Precisão@IOU>=0.5  | 0,902 | 0,891 | 0,826 | 0,815 | 0,870 | 0,880 | 0,783 | 0,880 | 0,880 | 0,766  | 0,849 | ± 0,048    |
| Precisão@IOU>=0.75 | 0,500 | 0,522 | 0,370 | 0,446 | 0,446 | 0,500 | 0,402 | 0,457 | 0,467 | 0,340  | 0,445 | ± 0,059    |
| mAP                | 0,085 | 0,077 | 0,057 | 0,075 | 0,073 | 0,079 | 0,034 | 0,055 | 0,057 | 0,068  | 0,066 | ± 0,015    |
| mAP@IOU0.5         | 0,270 | 0,256 | 0,176 | 0,265 | 0,204 | 0,225 | 0,142 | 0,177 | 0,238 | 0,209  | 0,216 | ± 0,043    |
| mScore             | 0,274 | 0,269 | 0,266 | 0,220 | 0,200 | 0,245 | 0,168 | 0,164 | 0,230 | 0,227  | 0,226 | ± 0,040    |
| mIOU               | 0,390 | 0,386 | 0,351 | 0,389 | 0,372 | 0,357 | 0,325 | 0,331 | 0,373 | 0,351  | 0,362 | ± 0,023    |
| mRecall            | 0,136 | 0,133 | 0,117 | 0,153 | 0,123 | 0,135 | 0,090 | 0,098 | 0,120 | 0,119  | 0,122 | ± 0,019    |
| Total Loss         | 0,234 | 0,266 | 0,273 | 0,279 | 0,289 | 0,253 | 0,296 | 0,229 | 0,264 | 0,234  | 0,262 | ± 0,024    |

A Tabela 10 apresenta o desempenho de diferentes modelos treinados com variados conjuntos de dados, utilizando métodos de avaliação como a validação cruzada 10-fold e a execução única (One Pass). A análise desta tabela oferece uma visão comparativa da precisão e eficácia de cada modelo em contextos específicos.

É crucial notar que as comparações mais precisas devem ser feitas entre modelos treinados com o mesmo conjunto de dados, uma vez que a complexidade dos dados e as particularidades de cada dataset podem impactar significativamente o desempenho dos algoritmos. Por exemplo, o modelo Faster-RCNN, amplamente testado no conjunto de

dados DukeBC, apresentou uma variação na precisão, indo de 0,758 a 0,849, dependendo do autor e do método de avaliação utilizado. A validação cruzada 10-fold, como aplicada por A. Pinto, mostra uma melhoria clara no desempenho, com uma precisão de 0,849, em comparação com o trabalho de J. Raimundo, que obteve 0,758.

Tabela 10 – Comparação de desempenho de múltiplos algoritmos em diferentes conjuntos de dados.

| Autor / Ref.   | Modelo              | Método de Avaliação      | Dataset              | Tipo de Avaliação | Precisão           | F1 Score |
|----------------|---------------------|--------------------------|----------------------|-------------------|--------------------|----------|
| A. Pinto       | Faster RCNN         | 10-fold cross validation | DukeBC Dataset       | Paciente          | $0,849 \pm 0,0048$ | 0,366    |
| J. Raimundo[3] | Faster RCNN         | 10-fold cross validation | DukeBC Dataset       | Paciente          | $0,758 \pm 0,0032$ | -        |
| Y. Zhang[42]   | Mask RCNN           | 10-fold cross validation | Two DCE-MRI datasets | Imagem/Slice      | 0,860              | -        |
| C. Wei[43]     | Modelo proprietário | One Pass                 | Kinhua Hospital      | Imagem/Slice      | 0,946              | -        |
| A.Bilic[44]    | SegresNet           | One Pass                 | DukeBC Dataset       | Imagem/Slice      | -                  | 0,300    |

Além disso, ao observar a aplicação de modelos em diferentes datasets, como o Mask RCNN avaliado por Y. Zhang [42] nos conjuntos de dados DCE-MRI, é notável que o modelo alcançou uma precisão de 0,860 ao ser aplicado em imagens/slices de exames de ressonância magnética dinâmica. Isso demonstra que, embora alguns modelos tenham resultados promissores em certos contextos, a adaptação a outros tipos de dados, como imagens médicas, pode ser essencial para melhorar o desempenho.

O modelo proprietário de C. Wei [43] também merece destaque, tendo alcançado uma precisão de 0,946 ao ser testado no conjunto de dados do Hospital Kinhua, mostrando o potencial de modelos personalizados quando aplicados a datasets específicos. Isso sugere que a personalização de modelos pode ser um caminho para melhorar ainda mais os resultados de outros algoritmos analisados, quando aplicados em contextos semelhantes ou com ajustes de *dataset*.

Finalmente, o modelo utilizado por A. Bilic [44], o SegresNet, pode ser comparado diretamente com o modelo desenvolvido por A. Pinto, uma vez que ambos utilizam o mesmo conjunto de dados, o DukeBC Dataset. Isso permite uma comparação direta entre os modelos. Apesar disso, o modelo treinado por A. Pinto, que utiliza o Faster RCNN,

apresenta uma performance superior na detecção de tumores, com uma precisão de 0,849 e um F1 Score de 0,366, em comparação com o F1 Score de 0,300 obtido pelo SegresNet de A. Bilic.

Portanto, considerando os resultados apresentados, é fundamental comparar os modelos treinados no mesmo conjunto de dados, mas também investigar o impacto de diferentes abordagens e conjuntos de dados. O desempenho do modelo pode variar amplamente dependendo do contexto de aplicação. Uma análise comparativa mais aprofundada é necessária para identificar áreas de melhoria através da escolha de métodos de avaliação e datasets mais adequados.





## Capítulo 5

### Conclusão e desenvolvimentos futuros

Este subcapítulo apresenta uma conclusão dos desenvolvimentos efetuados no projeto, destacando os principais resultados alcançados, as contribuições significativas para o campo de estudo, ferramentas desenvolvidas e possíveis futuros desenvolvimentos que darão continuidade ao projeto.

#### 5.1. Conclusão

A tese teve como principal objetivo melhorar a precisão de um modelo de detecção de objetos na automatização da detecção do cancro da mama, e este objetivo foi alcançado com sucesso. Foi desenvolvido um algoritmo multifacetado que permite a seleção das fatias mais impactantes no treino do modelo e no ajuste da anotação. No entanto, apesar dos resultados satisfatórios obtidos com base em argumentos heurísticos, há espaço para melhorias adicionais.

De entre os algoritmos testados, o melhor obteve uma precisão média de 84,9%. Esta precisão quando comparada a projetos que utilizem o mesmo *dataset* e modelos similares, obteve uma precisão satisfatória e em alguns casos, apresentou uma melhoria considerável. Os projetos que utilizam modelos personalizados com o propósito de detecção do cancro da mama são consideravelmente mais preformantes na identificação e localização dos tumores mamários, no entanto esses mesmos projetos utilizam um *dataset* proprietário.

Os objetivos S.M.A.R.T definidos na secção 1.4.1 foram alcançados com sucesso. A solução proposta para a detecção do cancro de mama, utilizando Inteligência Artificial, demonstrou uma precisão média de 84,9% com instâncias a atingirem valores de previsão acima dos 90%, conforme estabelecido como meta mensurável. Esse resultado representa um avanço significativo em relação ao modelo anteriormente desenvolvido. Assim, a implementação deste projeto teve um impacto positivo na comunidade, ao proporcionar uma forma automática e precisa de detecção do cancro de mama.

Além disso, a ferramenta desenvolvida abrirá caminho para a anotação e detecção de novos casos de cancro da mama, contribuindo para a redução da taxa de mortalidade entre os pacientes afetados e auxiliando a construção de um *dataset* mais preciso e completo.

#### *5.1.1. Extração de Características e Melhoria da Precisão do Modelo*

A principal área de foco do projeto foi a utilização de técnicas avançadas para a extração de características dos dados médicos através da análise das imagens médicas fornecidas em conjunto com as anotações anteriormente feitas, com o objetivo de melhorar a precisão dos modelos de aprendizagem de máquina.

As técnicas e algoritmos utilizados na extração de características implementadas no projeto contribuíram significativamente para a melhoria da precisão dos modelos de aprendizagem máquina. Ao ajustar as dimensões originais para melhor representar o tecido tumoral, filtrar imagens com baixa manifestação do tecido tumoral e a divisão do *dataset*, permitiram a criação de modelos mais precisos e robustos, com uma melhor capacidade de generalização e por consequência uma melhoria na precisão geral da detecção do cancro da mama.

#### *5.1.2. Ferramenta de previsão e anonimização*

Para testar a previsão de imagens fora do *dataset* utilizado, foi desenvolvida uma ferramenta (Figura 27) para demonstrar o uso da Inteligência Artificial na detecção automática do cancro da mama, com potencial para auxiliar médicos especialistas na detecção e anotação de tecido tumoral. A ferramenta permite a leitura de imagens em formato DICOM, padrão para armazenagem e gestão de imagens médicas, facilitando sua integração com sistemas existentes. Utilizando um modelo TensorFlow anteriormente exportado, a ferramenta realiza a inferência nas imagens DICOM, identificando e anotando automaticamente possíveis regiões de tecido tumoral. Após a leitura e inferência, é gerado um arquivo “.csv” contendo os resultados das anotações, incluindo informações detalhadas sobre a localização e a confiança das previsões. As detecções são demarcadas a verde nas imagens, com uma etiqueta exibida no canto superior esquerdo, permitindo

facilmente identificar previsões feitas pelo modelo, e fazer a sua visualização por parte dos médicos especialistas. Além disso, a ferramenta permite que especialistas façam anotações temporárias diretamente sobre as imagens ao arrastar e soltar o cursor, posteriormente podendo exportar essas anotações para um arquivo “.csv” separado. Esta funcionalidade possibilita a criação de um *dataset* enriquecido com múltiplas anotações por imagem, melhorando a qualidade dos dados e o treino de futuros modelos. A ferramenta pode atuar como um assistente automatizando a detecção inicial, resultando numa maior eficiência e precisão no diagnóstico. A integração com sistemas de informação hospitalar pode facilitar o fluxo de trabalho clínico, contribuindo para uma detecção precoce mais eficiente e melhores resultados para os pacientes. Futuras melhorias podem incluir técnicas de aprendizagem ativa, onde o modelo é continuamente treinado com novos dados e anotações, além da inclusão de visualizações avançadas.




Figura 27 – Ferramenta de previsão e anotação de tecido tumoral.

## 5.2. Limitações do projeto

Embora o presente projeto tenha produzido resultados relevantes e contribuído para o avanço da detecção automática do cancro da mama, é fundamental reconhecer algumas limitações que impactarão o desempenho e a precisão de resultados. A principal limitação do projeto é a utilização exclusiva de um *dataset* que apresenta algumas limitações, na qual foi baseado os treinos do modelo. A extração e qualidade dos dados, bem como a sua abrangência podem não refletir por completo a complexidade do problema. Este limite imposto sobre os dados pode afetar o treino do modelo de generalizar bem em

diferentes cenários, além de introduzir potenciais predisposições que não foram reconhecidas no exame inicial.

No futuro, será essencial considerar a inclusão de conjuntos de dados mais amplos e diversificados para garantir que os modelos de Inteligência Artificial possam capturar uma maior diversidade de casos e disposições do problema. Dados mais abrangentes e detalhados, como a consideração de múltiplas incidências de tumor e delimitação mais robusta do mesmo, podem melhorar significativamente o desempenho dos algoritmos e fornecer resultados mais robustos e confiáveis.

As limitações computacionais são também um ponto impactante no processo de treino dos modelos. Embora o hardware facultado tenha sido suficiente para treinar os modelos utilizados, a disponibilidade de utilizar uma infraestrutura computacional mais robusta e sem partilha de recursos computacionais levariam à possibilidade de utilizar modelos mais complexos e a diminuição do tempo de treino. Os modelos de Deep Learning (DL), que exigem uma quantidade computacional elevada, beneficiariam de uma infraestrutura mais robusta pois poderia contribuir para resultados mais precisos e um melhor desempenho.

Os modelos utilizados foram fornecidos pela API TensorFlow Object Detection, que é amplamente confiável e poderosa para o desenvolvimento de soluções com DL. Ainda assim é importante destacar que os resultados poderiam ser mais apreciativos com o treino de um modelo dedicado e feito á medida para o problema em questão. Um modelo feito á medida, desenhado para as características dos dados e natureza do problema, teria uma maior apreciação da precisão, devido ao potencial de capturar características e padrões.

Essas limitações, portanto, trazem oportunidades para o desenvolvimento futuro, apontando para a necessidade de mais dados, maior capacidade computacional e modelos mais indicados ao problema. Esses avanços abrirão caminho para melhorias significativas no projeto, garantindo uma evolução contínua da solução já desenvolvida.

### 5.3. Futuros desenvolvimentos

Após a conclusão deste projeto e a análise dos resultados obtidos, fica evidente que há uma vasta oportunidade para futuros desenvolvimentos e melhorias. A aplicação de técnicas de Inteligência Artificial na detecção e análise de imagens médicas, especialmente no contexto do cancro da mama, continua a evoluir e apresenta oportunidades promissoras para melhorar a precisão e eficiência dos diagnósticos. Nesta seção, explora-se alguns potenciais desenvolvimentos para a continuação deste trabalho, abrangendo desde melhorias na precisão e desempenho dos modelos à criação de *datasets* mais ricos em casos para um treino mais abrangente e representativo. Ao considerar esses futuros desenvolvimentos, espera-se fazer uma contribuição para o campo de estudo e fornecer soluções cada vez mais eficazes para auxiliar médicos especialistas no diagnóstico precoce e preciso do cancro de mama.

#### 5.3.1. Utilização de modelos específicos ou personalizados

##### UTILIZAÇÃO DE MASK R-CNN

A aplicação de anotações do tipo máscara pode ser considerada, proporcionando detecções mais precisas e uma generalização mais fiel do tecido tumoral. O uso de máscaras pode não apenas aumentar a precisão das detecções do tecido tumoral, mas também melhorar os sistemas de classificação de tumores existentes.

É importante destacar que a marcação de anotações do tipo máscara é consideravelmente mais demorada em comparação com as anotações por pontos ou caixas de anotação, pois envolve a recolha de mais pontos de anotação. Para lidar com esse problema, pode-se aplicar uma adaptação do algoritmo teorizado no capítulo 3 ou um algoritmo com o mesmo propósito. A abordagem recomendada seria realizar as anotações de máscaras de cada tumor para algumas fatias em que o tumor seja representado na imagem e nas camadas das suas extremidades. Isso permitiria que as anotações intermediárias fossem extraídas através do algoritmo, como potencialmente ilustrado na Figura 28 e reduzir o tempo de recolha das anotações.




Figura 28 – Exemplo de aplicação do algoritmo teorizado via anotações máscara.

### UTILIZAÇÃO DE 3D R-CNN

Uma estratégia que tem demonstrado resultados positivos é a utilização de modelos convolucionais 3D, que analisam todas as *slices* de uma ressonância magnética ou outro tipo de imagens 3D. Esses modelos conseguem determinar com maior fidelidade as detecções dos tumores devido ao contexto proporcionado pela imagem 3D. No entanto, é importante notar que esses modelos são mais exigentes em termos computacionais e sofrem de uma menor possibilidade de data *augmentation* uma vez que as alterações têm de ser feitas a todas as camadas. Todos os hiperpâmetros terão de ser considerados aquando desta nova abordagem porque necessitaria de uma aprendizagem diferente da feita de um modelo 2D.

### MODELO FEITO Á MEDIDA

Além disso, pode-se desenvolver um modelo customizado que se adapte às características e à natureza específica do problema. Um modelo feito á medida, permitiria integrar de forma mais eficaz as peculiaridades das imagens analisadas e os padrões típicos do tecido tumoral. Será possível otimizar a arquitetura de rede neuronal para o tipo de dado e o contexto específico, garantindo uma maior eficiência e precisão na tarefa de detecção e posterior classificação de tumores (este último não tendo sido abordado, mas posteriormente será relevante num contexto médico de análise e detecção de tumores mamários).

Este modelo poderá incluir uma combinação de redes convolucionais 2D e 3D, permitindo que o modelo extraia características tanto a nível de detalhe (2D) quanto a

nível de contexto espacial (3D). Além disso, a adoção de mecanismos de atenção ou redes mais profundas pode ajudar o modelo a focar nas áreas mais relevantes da imagem, melhorando a generalização dos resultados sem aumentar excessivamente o poder computacional.

Por fim, a construção de um modelo personalizado oferece a flexibilidade de incorporar técnicas avançadas, como transferência de aprendizagem ou multitarefa, tornando-o mais robusto para lidar com as nuances das imagens médicas e facilitando a adaptação aos diferentes tipos de imagens médicas.

### 5.3.2. *Criação de um novo dataset*

A construção de um *dataset* mais específico, com anotações mais precisas e a inclusão de múltiplas anotações por imagem, pode levar a um aumento significativo da fidelidade do modelo treinado com este novo conjunto de dados. Além disso, ao adicionar casos de outras fontes de dados, é possível enriquecer o *dataset* com casos diversos e variados, que pode resultar numa melhoria adicional da capacidade de previsão do modelo. No entanto, é fundamental garantir que os casos adicionados sejam relevantes para o domínio e a tarefa em questão, a fim de evitar a introdução de ruído ou informações irrelevantes que possam prejudicar o desempenho do modelo. Portanto, a combinação de anotações mais precisas, múltiplas anotações por imagem e a inclusão de casos de outros *datasets* pode ser uma estratégia eficaz para melhorar a previsão e a generalização do modelo.

## Referências Bibliográficas

- [1] H. Sung *et al.*, “Global Cancer Statistics 2020: GLOBOCAN Estimates of Incidence and Mortality Worldwide for 36 Cancers in 185 Countries,” *CA Cancer J Clin*, vol. 71, no. 3, pp. 209–249, May 2021, doi: 10.3322/CAAC.21660.
- [2] S. Saeed, N. Z. Jhanjhi, M. Naqvi, M. Humyun, M. Ahmad, and L. Gaur, “Optimized Breast Cancer Premature Detection Method With Computational Segmentation: A Systematic Review Mapping,” <https://services.igi-global.com/resolvedoi/resolve.aspx?doi=10.4018/978-1-7998-8929-8.ch002>, pp. 24–51, Jan. 1AD, doi: 10.4018/978-1-7998-8929-8.CH002.
- [3] J. N. C. Raimundo, J. P. P. Fontes, L. Gonzaga Mendes Magalhães, and M. A. Guevara Lopez, “An Innovative Faster R-CNN-Based Framework for Breast Cancer Detection in MRI,” *J Imaging*, vol. 9, no. 9, Sep. 2023, doi: 10.3390/JIMAGING9090169.
- [4] L. Wang, “Early Diagnosis of Breast Cancer,” *Sensors* 2017, Vol. 17, Page 1572, vol. 17, no. 7, p. 1572, Jul. 2017, doi: 10.3390/S17071572.
- [5] H. A. Ahmad, H. J. Yu, and C. G. Miller, “Medical imaging modalities,” *Medical Imaging in Clinical Trials*, vol. 9781848827103, pp. 3–26, Jun. 2014, doi: 10.1007/978-1-84882-710-3\_1/COVER.
- [6] “Breast Cancer Overview I The American Association for Cancer Research.” Accessed: Jul. 01, 2024. [Online]. Available: <https://www.aacr.org/patients-caregivers/cancer/breast-cancer/>
- [7] “Types of Breast Cancer - National Breast Cancer Foundation.” Accessed: Jul. 01, 2024. [Online]. Available: <https://www.nationalbreastcancer.org/types-of-breast-cancer/>
- [8] “Breast Cancer Risk Factors You Can’t Change | American Cancer Society.” Accessed: Jul. 01, 2024. [Online]. Available: <https://www.cancer.org/cancer/types/breast-cancer/risk-and-prevention/breast-cancer-risk-factors-you-cannot-change.html>
- [9] “Breast cancer - Diagnosis and treatment - Mayo Clinic.” Accessed: Jul. 01, 2024. [Online]. Available: <https://www.mayoclinic.org/diseases-conditions/breast-cancer/diagnosis-treatment/drc-20352475>
- [10] J. Zhai, Y. Wu, F. Ma, V. Kaklamani, and B. Xu, “Advances in medical treatment

- of breast cancer in 2022,” *Cancer Innovation*, vol. 2, no. 1, pp. 1–17, Feb. 2023, doi: 10.1002/CAI2.46.
- [11] C. Coleman, “Early Detection and Screening for Breast Cancer,” *Semin Oncol Nurs*, vol. 33, no. 2, pp. 141–155, May 2017, doi: 10.1016/J.SONCN.2017.02.009.
- [12] E. H. Houssein, M. M. Emam, A. A. Ali, and P. N. Suganthan, “Deep and machine learning techniques for medical imaging-based breast cancer: A comprehensive review,” *Expert Syst Appl*, vol. 167, p. 114161, Apr. 2021, doi: 10.1016/J.ESWA.2020.114161.
- [13] “Breast MRI | Susan G. Komen®.” Accessed: Jul. 01, 2024. [Online]. Available: <https://www.komen.org/breast-cancer/screening/mri/>
- [14] K. Kerlikowske, D. Grady, S. M. Rubin, C. Sandrock, and V. L. Ernster, “Efficacy of Screening Mammography: A Meta-analysis,” *JAMA*, vol. 273, no. 2, pp. 149–154, Jan. 1995, doi: 10.1001/JAMA.1995.03520260071035.
- [15] “Ressonância Magnética (RM) da Mama ou Mamária - Exames de RM.” Accessed: Feb. 20, 2024. [Online]. Available: <https://www.saudebemestar.pt/pt/exame/imagiologia/rm-da-mama/>
- [16] “Exames da Mama: aumentando a eficiência Mamografia – Ultrassom – Ressonância - Hospital São Marcos.” Accessed: Feb. 20, 2024. [Online]. Available: <https://www.saomarcos.org.br/artigo/exames-da-mama-aumentando-a-eficiencia-mamografia-ultrassom-ressonancia>
- [17] “Tomografia computadorizada: Tecnologias e aplicações - Arnaldo Prata Mourão - Google Livros.” Accessed: Feb. 20, 2024. [Online]. Available: [https://books.google.pt/books?hl=pt-PT&lr=&id=ZjjnDwAAQBAJ&oi=fnd&pg=PT6&dq=tomografia+computadorizada&ots=Cf4z93kuO8&sig=ofo2xvAosT0FE8WjfMxmWRWEc3s&redir\\_esc=y#v=onepage&q=tomografia%20computadorizada&f=false](https://books.google.pt/books?hl=pt-PT&lr=&id=ZjjnDwAAQBAJ&oi=fnd&pg=PT6&dq=tomografia+computadorizada&ots=Cf4z93kuO8&sig=ofo2xvAosT0FE8WjfMxmWRWEc3s&redir_esc=y#v=onepage&q=tomografia%20computadorizada&f=false)
- [18] W. S. McCulloch and W. Pitts, “A logical calculus of the ideas immanent in nervous activity,” *Bull Math Biophys*, vol. 5, no. 4, pp. 115–133, Dec. 1943, doi: 10.1007/BF02478259/METRICS.
- [19] “Capítulo 3 - O Que São Redes Neurais Artificiais Profundas ou Deep Learning? - Deep Learning Book.” Accessed: Feb. 21, 2024. [Online]. Available: <https://www.deeplearningbook.com.br/o-que-sao-redes-neurais-artificiais-profundas/>
- [20] T. Engell, N. A. Stadnick, G. A. Aarons, and M. L. Barnett, “Common Elements

- Approaches to Implementation Research and Practice: Methods and Integration with Intervention Science,” *Global Implementation Research and Applications*, vol. 3, no. 1, pp. 1–15, Mar. 2023, doi: 10.1007/S43477-023-00077-4.
- [21] R. M. Haralick and L. G. Shapiro, “Glossary of computer vision terms,” *Pattern Recognit*, vol. 24, no. 1, pp. 69–93, Jan. 1991, doi: 10.1016/0031-3203(91)90117-N.
- [22] Danilo de Milano and Luciano Barrozo Honorato, “VISÃO COMPUTACIONAL,” 2010.
- [23] L. Deng, “The MNIST database of handwritten digit images for machine learning research,” *IEEE Signal Process Mag*, vol. 29, no. 6, pp. 141–142, 2012, doi: 10.1109/MSP.2012.2211477.
- [24] P. Viola and M. Jones, “Rapid Object Detection using a Boosted Cascade of Simple Features,” 2001.
- [25] N. Dalal and B. Triggs, “Histograms of oriented gradients for human detection,” *Proceedings - 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, CVPR 2005*, vol. 1, pp. 886–893, 2005, doi: 10.1109/CVPR.2005.177.
- [26] P. F. Felzenszwalb, R. B. Girshick, D. Mcallester, and D. Ramanan, “Object Detection with Discriminatively Trained Part Based Models”.
- [27] D. C. Moura, M. A. Guevara López, D. C. Moura, and M. A. Guevara López, “An evaluation of image descriptors combined with clinical data for breast cancer diagnosis,” *Int J CARS*, 2013, doi: 10.1007/s11548-013-0838-2.
- [28] R. Girshick, “Fast R-CNN”, Accessed: Jul. 01, 2024. [Online]. Available: <https://github.com/rbgirshick/>
- [29] S. Ren, K. He, R. Girshick, and J. Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” *IEEE Trans Pattern Anal Mach Intell*, vol. 39, no. 6, pp. 1137–1149, Jun. 2015, doi: 10.1109/TPAMI.2016.2577031.
- [30] K. He, G. Gkioxari, P. Dollár, and R. Girshick, “Mask R-CNN,” *IEEE Trans Pattern Anal Mach Intell*, vol. 42, no. 2, pp. 386–397, Mar. 2017, doi: 10.1109/TPAMI.2018.2844175.
- [31] T.-Y. Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, “Feature Pyramid Networks for Object Detection,” Dec. 2016, Accessed: Jul. 01, 2024. [Online]. Available: <https://arxiv.org/abs/1612.03144v2>
- [32] “Object Detection in 2024: The Definitive Guide - viso.ai.” Accessed: Feb. 03,

2024. [Online]. Available: <https://viso.ai/deep-learning/object-detection/>
- [33] L. Cheng and Z. Yang, "GRCNN: Graph Recognition Convolutional Neural Network for Synthesizing Programs from Flow Charts," Nov. 2020, Accessed: Jul. 01, 2024. [Online]. Available: <https://arxiv.org/abs/2011.05980v1>
- [34] J. Wang and X. Hu, "Gated Recurrent Convolution Neural Network for OCR".
- [35] C.-Y. Wang, A. Bochkovskiy, and H.-Y. M. Liao, "Scaled-YOLOv4: Scaling Cross Stage Partial Network," 2021.
- [36] R. Girshick, J. Donahue, T. Darrell, J. Malik, U. C. Berkeley, and J. Malik, "1043.0690," *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 1, p. 5000, Sep. 2014, doi: 10.1109/CVPR.2014.81.
- [37] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *IEEE Trans Pattern Anal Mach Intell*, vol. 39, no. 6, pp. 1137–1149, Jun. 2015, doi: 10.1109/TPAMI.2016.2577031.
- [38] J. Witowski *et al.*, "Improving breast cancer diagnostics with deep learning for MRI," *Sci Transl Med*, vol. 14, no. 664, p. 4802, Sep. 2022, doi: 10.1126/SCITRANSLMED.ABO4802/SUPPL\_FILE/SCITRANSLMED.ABO4802\_MDAR\_REPRODUCIBILITY\_CHECKLIST.PDF.
- [39] "Dynamic contrast-enhanced magnetic resonance images of breast cancer patients with tumor locations (Duke-Breast-Cancer-MRI) - The Cancer Imaging Archive (TCIA) Public Access - Cancer Imaging Archive Wiki." Accessed: Feb. 04, 2024. [Online]. Available: <https://wiki.cancerimagingarchive.net/pages/viewpage.action?pageId=70226903>
- [40] "MRI, Magnetic Resonance Imaging | Mayfield Brain & Spine Cincinnati, Ohio." Accessed: Feb. 05, 2024. [Online]. Available: <https://mayfieldclinic.com/pe-mri.htm>
- [41] "Calculus II - Center of Mass." Accessed: Feb. 21, 2024. [Online]. Available: <https://tutorial.math.lamar.edu/classes/calci/centerofmass.aspx>
- [42] Y. Zhang *et al.*, "Automatic Detection and Segmentation of Breast Cancer on MRI Using Mask R-CNN Trained on Non-Fat-Sat Images and Tested on Fat-Sat Images," *Acad Radiol*, vol. 29, pp. S135–S144, Jan. 2022, doi: 10.1016/j.acra.2020.12.001.
- [43] C. Wei and S. Nie, "Weakly Supervised Breast Lesions Detection in Dynamic Contrast Enhancement Magnetic Resonance Imaging," *ICSAI 2021 - 7th*

*International Conference on Systems and Informatics*, 2021, doi: 10.1109/ICSAI53574.2021.9664072.

- [44] A. Bilic and C. Chen, “BC-MRI-SEG: A Breast Cancer MRI Tumor Segmentation Benchmark,” *Proceedings - 2024 IEEE 12th International Conference on Healthcare Informatics, ICHI 2024*, pp. 674–678, Apr. 2024, doi: 10.1109/ICHI61247.2024.00107.





**POLITECNICO  
SETÚBAL**

## **Anexos**

Instituto Politécnico de Setúbal,  
Mestrado em Engenharia Informática

António Carlos Ferreira Pinto

Outubro 2024

## Anexo I

### Estrutura do ficheiro de configuração “config.ini”.

```
[Settings]
input_directory=<directoria pai de todas as imagens a processar, string>
output_directory=<directoria onde devem ser guardados resultados, string>
minimum_scale=<escala mínima da anotação inicial, valor decimal [0,1]>
execution_path=<execution_path da anotação, string opcional>
thread_number=<número de threads, número inteiro>
first_patient=<primeiro paciente a analisar, número inteiro>
last_patient=<último paciente a analisar, número inteiro>
split_dataset=<separação do dataset, número inteiro [0,1]>
fold_count=<número de folds, número inteiro>
train_ratio=<rácio de treino, decimal [0,1]>
test_ratio=<rácio de treino, decimal [0,1]>
image_annotated=<anotação na imagem, número inteiro [0,1]>
```

## Anexo II

### Anotação XML terceira passagem, “slice” 92 do paciente 001.

```
<annotation>
  <filename>id#Breast_MRI_001#_series#11.000000-ax dyn 3rd pass-
41458#_slice#092#.jpg</filename>
  <folder>data</folder>
  <path>/data/apinto/preprocessed</path>
  <size>
    <height>448</height>
    <width>448</width>
  </size>
  <source>
    <database>DukeBC</database>
  </source>
  <segmented>0</segmented>
  <object>
    <bndbox>
      <xmax>339</xmax>
      <xmin>314</xmin>
      <ymax>264</ymax>
      <ymin>235</ymin>
    </bndbox>
    <difficult>0</difficult>
    <name>tumour</name>
    <pose>Unspecified</pose>
    <truncated>0</truncated>
  </object>
</annotation>
```

## Anexo III

### Características e parâmetros de treino, teste e validação dos diferentes modelos.

|           | Original                      |                       |            | KeepHalf   |                       |            | ImageAnnotationEnhanced |                       |            |            |
|-----------|-------------------------------|-----------------------|------------|------------|-----------------------|------------|-------------------------|-----------------------|------------|------------|
| Geral     | Treino                        | Teste                 | Validação  | Treino     | Teste                 | Validação  | Treino                  | Teste                 | Validação  |            |
|           | Pacientes                     | 737                   | 92         | 93         | 737                   | 92         | 93                      | 737                   | 92         | 93         |
|           | Média de imagens por paciente |                       | 103,33     |            | 54,75                 |            |                         | 81,98                 |            |            |
|           | Total de imagens              |                       | 95 267     |            | 50 479                |            |                         | 75 590                |            |            |
|           | Total de ficheiros            | 155 368               | 18 232     | 16 934     | 82 250                | 9 654      | 9 054                   | 123 312               | 14 416     | 13 452     |
|           | Rácio do dataset original (%) |                       | 100,0%     |            | 52,99%                |            |                         | 79,35%                |            |            |
|           | Tamanho dos ficheiros (bytes) | 1 800 713 72          | 208 778 64 | 200 030 98 | 953 468 46            | 110 554 06 | 106 673 96              | 1 357 740 66          | 156 410 60 | 150 616 34 |
| Treino    |                               | 4                     | 6          | 3          | 5                     | 8          | 1                       | 2                     | 2          | 1          |
|           | Epochs                        |                       | 84         |            | 84                    |            |                         | 84                    |            |            |
|           | Número de steps               |                       | 505 000    |            | 265000                |            |                         | 400 000               |            |            |
|           | Dimensão de Batch             |                       | 16         |            | 16                    |            |                         | 16                    |            |            |
|           | Número de classes             |                       | 1          |            | 1                     |            |                         | 1                     |            |            |
|           | Número Máximo de Deteções     |                       | 1          |            | 1                     |            |                         | 1                     |            |            |
|           | Máxima Taxa de Aprendizagem   |                       | 0,05       |            | 0,05                  |            |                         | 0,05                  |            |            |
|           | Função de Aprendizagem        | Decaimento de cosseno |            |            | Decaimento de cosseno |            |                         | Decaimento de cosseno |            |            |
|           | Função de Pontuação           | Softmax               |            |            | Softmax               |            |                         | Softmax               |            |            |
|           | Tempo de treino (dd:hh:mm:ss) | (01:20:55:41)         |            |            | (00:22:30:30)         |            |                         | (01:10:32:10)         |            |            |
| Validação | Precisão IOU>=0.5             |                       | 64,5%      |            | 73,1%                 |            |                         | 82,8%                 |            |            |
|           | Precisão IOU>=0.75            |                       | 20,4%      |            | 30,1%                 |            |                         | 37,6%                 |            |            |
|           | mAP                           |                       | 0,0220     |            | 0,0681                |            |                         | 0,0444                |            |            |
|           | mAP@IOU>=0.5                  |                       | 0,0920     |            | 0,2746                |            |                         | 0,1802                |            |            |
|           | mIOU                          |                       | 0,2664     |            | 0,3494                |            |                         | 0,3498                |            |            |
|           | mRecall                       |                       | 0,0770     |            | 0,1356                |            |                         | 0,1001                |            |            |
|           | Total Loss                    |                       | 0,2243     |            | 0,2283                |            |                         | 0,2529                |            |            |

## Anexo IV

### Tabelas de valores de cada dataset pré-processado.

Tabela 11 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset original.

| Avaliação V0       | Score        |             | IoU        |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|------------|-----------|---------------------|----------------------|
| Média              | 0,0750       |             | 0,2664     |           | 0,64516129          | 0,204301075          |
| Média onde IoU > 0 | 0,1001       |             | 0,3564     |           | 0,674157303         | 0,213483146          |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 009                | 0,0008       | 0,0000      | 0,6421     | 0,1855    | 1                   | 0                    |
| 018                | 0,0017       | 0,0001      | 0,4815     | 0,2577    | 0                   | 0                    |
| 022                | 0,0006       | 0,0000      | 0,4435     | 0,1075    | 0                   | 0                    |
| 025                | 0,0003       | 0,0000      | 0,3735     | 0,0226    | 0                   | 0                    |
| 030                | 0,0435       | 0,0075      | 0,5144     | 0,2343    | 1                   | 0                    |
| 032                | 0,0204       | 0,0008      | 0,5328     | 0,1051    | 1                   | 0                    |
| 038                | 0,1030       | 0,0059      | 0,5416     | 0,2186    | 1                   | 0                    |
| 057                | 1,0000       | 0,9678      | 0,5852     | 0,4921    | 1                   | 0                    |
| 071                | 0,0050       | 0,0005      | 0,1250     | 0,0467    | 0                   | 0                    |
| 089                | 0,9707       | 0,0152      | 0,6645     | 0,1911    | 1                   | 0                    |
| 098                | 0,0001       | 0,0000      | 0,6738     | 0,1123    | 1                   | 0                    |
| 100                | 0,0032       | 0,0006      | 0,4242     | 0,2311    | 0                   | 0                    |
| 101                | 0,8833       | 0,0223      | 0,4719     | 0,3118    | 0                   | 0                    |
| 134                | 0,6796       | 0,0071      | 0,7500     | 0,1365    | 1                   | 1                    |
| 143                | 0,0001       | 0,0000      | 0,0000     | 0,0000    | 0                   | 0                    |
| 152                | 0,9999       | 0,0887      | 0,6851     | 0,3339    | 1                   | 0                    |
| 153                | 0,0033       | 0,0001      | 0,8597     | 0,2185    | 1                   | 1                    |
| 159                | 0,9865       | 0,0467      | 0,5792     | 0,2486    | 1                   | 0                    |
| 160                | 0,0043       | 0,0002      | 0,7725     | 0,2650    | 1                   | 1                    |
| 165                | 0,0009       | 0,0001      | 0,5262     | 0,2552    | 1                   | 0                    |
| 171                | 0,0005       | 0,0000      | 0,7310     | 0,4011    | 1                   | 0                    |
| 195                | 0,0004       | 0,0001      | 0,6408     | 0,1273    | 1                   | 0                    |
| 199                | 0,0012       | 0,0001      | 0,8191     | 0,2622    | 1                   | 1                    |
| 205                | 0,4376       | 0,0336      | 0,8180     | 0,3049    | 1                   | 1                    |
| 210                | 0,0014       | 0,0003      | 0,1895     | 0,1376    | 0                   | 0                    |
| 214                | 0,1408       | 0,0054      | 0,5771     | 0,3373    | 1                   | 0                    |
| 222                | 0,9978       | 0,0298      | 0,5583     | 0,2500    | 1                   | 0                    |
| 253                | 0,9999       | 0,1109      | 0,8415     | 0,4755    | 1                   | 1                    |
| 256                | 1,0000       | 0,3892      | 0,5201     | 0,3312    | 1                   | 0                    |
| 258                | 1,0000       | 0,2032      | 0,6473     | 0,4099    | 1                   | 0                    |
| 267                | 0,1262       | 0,0087      | 0,2110     | 0,1112    | 0                   | 0                    |
| 270                | 1,0000       | 0,5115      | 0,3571     | 0,2661    | 0                   | 0                    |
| 272                | 0,9913       | 0,0345      | 0,6042     | 0,2811    | 1                   | 0                    |
| 303                | 1,0000       | 0,0366      | 0,5292     | 0,1568    | 1                   | 0                    |
| 306                | 0,0407       | 0,0041      | 0,2942     | 0,1643    | 0                   | 0                    |
| 311                | 0,0130       | 0,0007      | 0,6398     | 0,3212    | 1                   | 0                    |
| 329                | 0,0002       | 0,0000      | 0,5830     | 0,2070    | 1                   | 0                    |
| 330                | 0,0012       | 0,0001      | 0,3115     | 0,0495    | 0                   | 0                    |
| 332                | 0,0182       | 0,0011      | 0,7414     | 0,3395    | 1                   | 0                    |
| 357                | 0,9988       | 0,0412      | 0,7888     | 0,3584    | 1                   | 1                    |
| 358                | 0,0055       | 0,0003      | 0,8142     | 0,4270    | 1                   | 1                    |
| 360                | 0,0001       | 0,0000      | 0,5455     | 0,1175    | 1                   | 0                    |
| 364                | 0,0004       | 0,0001      | 0,6667     | 0,1160    | 1                   | 0                    |
| 367                | 0,0331       | 0,0006      | 0,5609     | 0,0973    | 1                   | 0                    |
| 375                | 0,0038       | 0,0002      | 0,5018     | 0,2881    | 1                   | 0                    |
| 398                | 0,0183       | 0,0015      | 0,4000     | 0,1530    | 0                   | 0                    |
| 403                | 1,0000       | 0,3268      | 0,8529     | 0,6271    | 1                   | 1                    |
| 426                | 0,0023       | 0,0002      | 0,8974     | 0,1104    | 1                   | 1                    |
| 448                | 0,8627       | 0,0640      | 0,0575     | 0,0359    | 0                   | 0                    |
| 452                | 1,0000       | 0,3751      | 0,7640     | 0,5608    | 1                   | 1                    |
| 457                | 0,3346       | 0,0044      | 0,4745     | 0,1092    | 0                   | 0                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 469 | 0,9747 | 0,0491 | 0,7852 | 0,4084 | 1 | 1 |
| 488 | 0,0067 | 0,0006 | 0,0055 | 0,0003 | 0 | 0 |
| 490 | 0,0021 | 0,0003 | 0,7414 | 0,3138 | 1 | 0 |
| 506 | 0,8053 | 0,0406 | 0,2957 | 0,1090 | 0 | 0 |
| 517 | 1,0000 | 0,2318 | 0,4522 | 0,3359 | 0 | 0 |
| 521 | 0,0038 | 0,0004 | 0,3049 | 0,1313 | 0 | 0 |
| 525 | 1,0000 | 0,1499 | 0,7063 | 0,4151 | 1 | 0 |
| 540 | 0,0058 | 0,0005 | 0,1416 | 0,0485 | 0 | 0 |
| 560 | 1,0000 | 0,0937 | 0,8842 | 0,4093 | 1 | 1 |
| 580 | 0,0003 | 0,0001 | 0,0000 | 0,0000 | 0 | 0 |
| 590 | 1,0000 | 0,1134 | 0,9500 | 0,6390 | 1 | 1 |
| 593 | 0,0005 | 0,0001 | 0,4428 | 0,1379 | 0 | 0 |
| 598 | 0,4558 | 0,0112 | 0,7503 | 0,3956 | 1 | 1 |
| 609 | 1,0000 | 0,0183 | 0,8854 | 0,5162 | 1 | 1 |
| 619 | 0,0879 | 0,0051 | 0,6134 | 0,3521 | 1 | 0 |
| 622 | 0,0002 | 0,0000 | 0,4088 | 0,0236 | 0 | 0 |
| 635 | 1,0000 | 0,1736 | 0,5686 | 0,3052 | 1 | 0 |
| 637 | 0,0028 | 0,0003 | 0,6071 | 0,1427 | 1 | 0 |
| 663 | 0,1200 | 0,0066 | 0,4296 | 0,2235 | 0 | 0 |
| 664 | 0,0006 | 0,0000 | 0,3767 | 0,0080 | 0 | 0 |
| 680 | 0,0140 | 0,0008 | 0,0000 | 0,0000 | 0 | 0 |
| 689 | 1,0000 | 0,2093 | 0,6264 | 0,3300 | 1 | 0 |
| 709 | 0,0014 | 0,0002 | 0,5829 | 0,1998 | 1 | 0 |
| 755 | 0,0139 | 0,0008 | 0,5143 | 0,1730 | 1 | 0 |
| 768 | 0,0094 | 0,0003 | 0,6944 | 0,1567 | 1 | 0 |
| 770 | 0,0023 | 0,0001 | 0,6667 | 0,2385 | 1 | 0 |
| 775 | 0,0031 | 0,0002 | 0,2586 | 0,0416 | 0 | 0 |
| 779 | 0,0005 | 0,0000 | 0,1890 | 0,0122 | 0 | 0 |
| 790 | 0,8482 | 0,0421 | 0,8253 | 0,3487 | 1 | 1 |
| 818 | 0,6130 | 0,0252 | 0,7145 | 0,4192 | 1 | 0 |
| 828 | 0,0244 | 0,0024 | 0,5926 | 0,0984 | 1 | 0 |
| 833 | 0,0672 | 0,0013 | 0,7105 | 0,3051 | 1 | 0 |
| 836 | 0,0000 | 0,0000 | 0,6727 | 0,0436 | 1 | 0 |
| 842 | 0,0485 | 0,0011 | 0,2982 | 0,0563 | 0 | 0 |
| 845 | 0,0558 | 0,0089 | 0,1397 | 0,0776 | 0 | 0 |
| 852 | 0,9994 | 0,1142 | 0,8932 | 0,6008 | 1 | 1 |
| 855 | 0,0002 | 0,0000 | 0,0000 | 0,0000 | 0 | 0 |
| 876 | 0,0000 | 0,0000 | 0,4516 | 0,1117 | 0 | 0 |
| 879 | 0,1317 | 0,0011 | 0,6863 | 0,1524 | 1 | 0 |
| 907 | 1,0000 | 0,2230 | 0,9248 | 0,6803 | 1 | 1 |
| 909 | 0,0017 | 0,0002 | 0,6687 | 0,2817 | 1 | 0 |
| 913 | 0,2569 | 0,0257 | 0,3793 | 0,0534 | 0 | 0 |

Tabela 12 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo KeepHalf.

| Avaliação KeepHalf | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média              | 0,291519588  |             | 0,346629371 |           | 0,741935484         | 0,311827957          |
| Média onde IoU > 0 | 0,335405875  |             | 0,407666282 |           | 0,758241758         | 0,318681319          |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 009                | 0,23809      | 0,02147     | 0,16488     | 0,09184   | 0                   | 0                    |
| 018                | 0,99991      | 0,21797     | 0,74993     | 0,37068   | 1                   | 0                    |
| 022                | 1,00000      | 0,37408     | 0,69680     | 0,35941   | 1                   | 0                    |
| 025                | 0,00013      | 0,00003     | 0,62302     | 0,05501   | 1                   | 0                    |
| 030                | 0,00576      | 0,00130     | 0,71777     | 0,39367   | 1                   | 0                    |
| 032                | 0,99970      | 0,11448     | 0,36094     | 0,19719   | 0                   | 0                    |
| 038                | 0,99980      | 0,11933     | 0,88608     | 0,48579   | 1                   | 1                    |
| 057                | 1,00000      | 0,65933     | 0,65061     | 0,45263   | 1                   | 0                    |
| 071                | 0,00373      | 0,00052     | 0,70833     | 0,10141   | 1                   | 0                    |
| 089                | 1,00000      | 0,11288     | 0,58829     | 0,28695   | 1                   | 0                    |
| 098                | 0,99959      | 0,04800     | 0,58071     | 0,11772   | 1                   | 0                    |
| 100                | 0,99860      | 0,35584     | 0,80783     | 0,55636   | 1                   | 1                    |
| 101                | 0,77087      | 0,02321     | 0,60958     | 0,28288   | 1                   | 0                    |
| 134                | 0,98141      | 0,09631     | 0,57403     | 0,29172   | 1                   | 0                    |
| 143                | 0,00000      | 0,00000     | 0,00558     | 0,00046   | 0                   | 0                    |
| 152                | 0,99999      | 0,49417     | 0,77355     | 0,51089   | 1                   | 1                    |
| 153                | 1,00000      | 0,74875     | 0,97143     | 0,84034   | 1                   | 1                    |
| 159                | 1,00000      | 0,47561     | 0,63480     | 0,42017   | 1                   | 0                    |
| 160                | 0,99987      | 0,04461     | 0,71642     | 0,34063   | 1                   | 0                    |
| 165                | 0,03018      | 0,00500     | 0,68421     | 0,25148   | 1                   | 0                    |
| 171                | 0,19900      | 0,00772     | 0,71250     | 0,39917   | 1                   | 0                    |
| 195                | 0,18082      | 0,01390     | 0,65504     | 0,34237   | 1                   | 0                    |
| 199                | 0,35747      | 0,06329     | 0,86548     | 0,43873   | 1                   | 1                    |
| 205                | 1,00000      | 0,62786     | 0,82393     | 0,59148   | 1                   | 1                    |
| 210                | 0,86029      | 0,15003     | 0,28929     | 0,22972   | 0                   | 0                    |
| 214                | 0,99990      | 0,13596     | 0,79726     | 0,55646   | 1                   | 1                    |
| 222                | 0,99999      | 0,11022     | 0,43198     | 0,15675   | 0                   | 0                    |
| 253                | 0,99996      | 0,96772     | 0,86634     | 0,79202   | 1                   | 1                    |
| 256                | 0,01768      | 0,00337     | 0,81379     | 0,35386   | 1                   | 1                    |
| 258                | 1,00000      | 0,12627     | 0,74634     | 0,23796   | 1                   | 0                    |
| 267                | 0,98721      | 0,02941     | 0,14595     | 0,08453   | 0                   | 0                    |
| 270                | 0,99964      | 0,50425     | 0,54945     | 0,34582   | 1                   | 0                    |
| 272                | 1,00000      | 0,75968     | 0,77885     | 0,58685   | 1                   | 1                    |
| 303                | 0,99994      | 0,30874     | 0,82609     | 0,60763   | 1                   | 1                    |
| 306                | 0,79891      | 0,14013     | 0,68807     | 0,25488   | 1                   | 0                    |
| 311                | 0,99698      | 0,10706     | 0,48328     | 0,25060   | 0                   | 0                    |
| 329                | 0,02740      | 0,00406     | 0,26626     | 0,10320   | 0                   | 0                    |
| 330                | 0,91297      | 0,03908     | 0,23660     | 0,13136   | 0                   | 0                    |
| 332                | 1,00000      | 0,89879     | 0,87692     | 0,74461   | 1                   | 1                    |
| 357                | 0,99990      | 0,28518     | 0,61139     | 0,21852   | 1                   | 0                    |
| 358                | 0,38491      | 0,04226     | 0,64442     | 0,38417   | 1                   | 0                    |
| 360                | 0,00006      | 0,00001     | 0,01825     | 0,00091   | 0                   | 0                    |
| 364                | 0,00352      | 0,00122     | 0,71429     | 0,43663   | 1                   | 0                    |
| 367                | 1,00000      | 0,24321     | 0,63371     | 0,18887   | 1                   | 0                    |
| 375                | 0,99994      | 0,40170     | 0,40889     | 0,24186   | 0                   | 0                    |
| 398                | 0,53825      | 0,02781     | 0,73082     | 0,46343   | 1                   | 0                    |
| 403                | 1,00000      | 0,97415     | 0,83529     | 0,74588   | 1                   | 1                    |
| 426                | 0,99995      | 0,17433     | 0,74250     | 0,38668   | 1                   | 0                    |
| 448                | 0,61167      | 0,07038     | 0,48750     | 0,04724   | 0                   | 0                    |
| 452                | 1,00000      | 0,38283     | 0,68886     | 0,48224   | 1                   | 0                    |
| 457                | 0,99999      | 0,49789     | 0,66667     | 0,03119   | 1                   | 0                    |
| 469                | 0,99974      | 0,30104     | 0,82612     | 0,58641   | 1                   | 1                    |
| 488                | 0,00008      | 0,00001     | 0,35417     | 0,03381   | 0                   | 0                    |
| 490                | 0,01779      | 0,00252     | 0,50323     | 0,24428   | 1                   | 0                    |
| 506                | 0,99850      | 0,28132     | 0,21592     | 0,11456   | 0                   | 0                    |
| 517                | 0,21941      | 0,02305     | 0,66610     | 0,19951   | 1                   | 0                    |

|     |         |         |         |         |   |   |
|-----|---------|---------|---------|---------|---|---|
| 521 | 0,95952 | 0,01545 | 0,55710 | 0,09545 | 1 | 0 |
| 525 | 1,00000 | 0,99311 | 0,88095 | 0,72787 | 1 | 1 |
| 540 | 0,62335 | 0,10522 | 0,15245 | 0,09383 | 0 | 0 |
| 560 | 1,00000 | 0,74224 | 0,83901 | 0,68725 | 1 | 1 |
| 580 | 0,00001 | 0,00000 | 0,18182 | 0,08763 | 0 | 0 |
| 590 | 1,00000 | 0,80455 | 0,91232 | 0,74324 | 1 | 1 |
| 593 | 0,69729 | 0,05028 | 0,66310 | 0,27924 | 1 | 0 |
| 598 | 0,92639 | 0,06097 | 0,70149 | 0,19443 | 1 | 0 |
| 609 | 0,99994 | 0,56784 | 0,80426 | 0,57955 | 1 | 1 |
| 619 | 0,99998 | 0,86851 | 0,65476 | 0,55719 | 1 | 0 |
| 622 | 0,00007 | 0,00002 | 0,03382 | 0,01322 | 0 | 0 |
| 635 | 1,00000 | 0,75133 | 0,90550 | 0,65116 | 1 | 1 |
| 637 | 0,99221 | 0,12488 | 0,58065 | 0,18443 | 1 | 0 |
| 663 | 1,00000 | 0,54654 | 0,93946 | 0,51356 | 1 | 1 |
| 664 | 0,22796 | 0,01026 | 0,56460 | 0,01718 | 1 | 0 |
| 680 | 0,00578 | 0,00091 | 0,00000 | 0,00000 | 0 | 0 |
| 689 | 1,00000 | 0,45554 | 0,48317 | 0,27663 | 0 | 0 |
| 709 | 0,04336 | 0,00464 | 0,58491 | 0,18129 | 1 | 0 |
| 755 | 0,02374 | 0,00285 | 0,77005 | 0,39697 | 1 | 1 |
| 768 | 0,88927 | 0,09887 | 0,72468 | 0,27198 | 1 | 0 |
| 770 | 0,99996 | 0,57178 | 0,55072 | 0,35651 | 1 | 0 |
| 775 | 0,94156 | 0,03213 | 0,45425 | 0,06675 | 0 | 0 |
| 779 | 0,04611 | 0,00208 | 0,27068 | 0,07882 | 0 | 0 |
| 790 | 0,50445 | 0,04396 | 0,76744 | 0,26146 | 1 | 1 |
| 818 | 0,99993 | 0,45593 | 0,77778 | 0,47035 | 1 | 1 |
| 828 | 0,99967 | 0,65240 | 0,78261 | 0,62913 | 1 | 1 |
| 833 | 1,00000 | 0,61970 | 0,81818 | 0,62040 | 1 | 1 |
| 836 | 0,00121 | 0,00016 | 0,06754 | 0,00450 | 0 | 0 |
| 842 | 0,99997 | 0,06555 | 0,51309 | 0,21384 | 1 | 0 |
| 845 | 0,00264 | 0,00030 | 0,13492 | 0,09962 | 0 | 0 |
| 852 | 0,99997 | 0,27398 | 0,89114 | 0,55710 | 1 | 1 |
| 855 | 0,00024 | 0,00005 | 0,00000 | 0,00000 | 0 | 0 |
| 876 | 0,00377 | 0,00099 | 0,73171 | 0,34518 | 1 | 0 |
| 879 | 0,69371 | 0,01698 | 0,77174 | 0,05022 | 1 | 1 |
| 907 | 1,00000 | 0,98019 | 0,88732 | 0,81620 | 1 | 1 |
| 909 | 0,99998 | 0,54993 | 0,75286 | 0,57671 | 1 | 1 |
| 913 | 0,38849 | 0,02957 | 0,61697 | 0,18001 | 1 | 0 |

Tabela 13 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced.

| Avaliação<br>ImageAnnotationEnhanced | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média                                | 0,166566506  |             | 0,34982871  |           | 0,827956989         | 0,376344086          |
| Média onde IoU > 0                   | 0,186546127  |             | 0,399414005 |           | 0,846153846         | 0,384615385          |
| Paciente ID                          | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 009                                  | 0,0106       | 0,0003      | 0,8301      | 0,1806    | 1                   | 1                    |
| 018                                  | 1,0000       | 0,1168      | 0,8525      | 0,4382    | 1                   | 1                    |
| 022                                  | 0,9991       | 0,0732      | 0,7903      | 0,4256    | 1                   | 1                    |
| 025                                  | 0,0002       | 0,0000      | 0,6365      | 0,1948    | 1                   | 0                    |
| 030                                  | 0,9878       | 0,2125      | 0,6712      | 0,4063    | 1                   | 0                    |
| 032                                  | 0,0091       | 0,0013      | 0,3694      | 0,1562    | 0                   | 0                    |
| 038                                  | 1,0000       | 0,4911      | 0,8367      | 0,5756    | 1                   | 1                    |
| 057                                  | 1,0000       | 0,6264      | 0,7101      | 0,4590    | 1                   | 0                    |
| 071                                  | 0,0007       | 0,0000      | 0,4808      | 0,0759    | 0                   | 0                    |
| 089                                  | 0,9996       | 0,0323      | 0,5958      | 0,1896    | 1                   | 0                    |
| 098                                  | 0,0004       | 0,0000      | 0,3391      | 0,0428    | 0                   | 0                    |
| 100                                  | 0,9969       | 0,3519      | 0,6182      | 0,3725    | 1                   | 0                    |
| 101                                  | 0,9779       | 0,0612      | 0,6256      | 0,3266    | 1                   | 0                    |
| 134                                  | 0,1748       | 0,0081      | 0,6438      | 0,1617    | 1                   | 0                    |
| 143                                  | 0,0001       | 0,0000      | 0,6590      | 0,1056    | 1                   | 0                    |
| 152                                  | 1,0000       | 0,3806      | 0,7245      | 0,4202    | 1                   | 0                    |
| 153                                  | 0,9995       | 0,3367      | 0,8421      | 0,6625    | 1                   | 1                    |
| 159                                  | 0,9996       | 0,1678      | 0,8594      | 0,3700    | 1                   | 1                    |
| 160                                  | 0,0047       | 0,0003      | 0,7367      | 0,2008    | 1                   | 0                    |
| 165                                  | 0,0146       | 0,0012      | 0,5058      | 0,0794    | 1                   | 0                    |
| 171                                  | 0,9837       | 0,0937      | 0,6929      | 0,3493    | 1                   | 0                    |
| 195                                  | 0,0008       | 0,0000      | 0,7225      | 0,3093    | 1                   | 0                    |
| 199                                  | 0,9993       | 0,1519      | 0,8661      | 0,4225    | 1                   | 1                    |
| 205                                  | 1,0000       | 0,3272      | 0,7598      | 0,3949    | 1                   | 1                    |
| 210                                  | 0,0019       | 0,0006      | 0,5833      | 0,3620    | 1                   | 0                    |
| 214                                  | 0,0800       | 0,0028      | 0,7845      | 0,4630    | 1                   | 1                    |
| 222                                  | 0,6998       | 0,0060      | 0,7137      | 0,2784    | 1                   | 0                    |
| 253                                  | 1,0000       | 0,6998      | 0,9333      | 0,7194    | 1                   | 1                    |
| 256                                  | 0,0597       | 0,0060      | 0,9643      | 0,5652    | 1                   | 1                    |
| 258                                  | 0,9999       | 0,0680      | 0,8371      | 0,4175    | 1                   | 1                    |
| 267                                  | 0,0878       | 0,0067      | 0,3247      | 0,0799    | 0                   | 0                    |
| 270                                  | 0,9999       | 0,3332      | 0,4941      | 0,1985    | 0                   | 0                    |
| 272                                  | 1,0000       | 0,5259      | 0,8329      | 0,5204    | 1                   | 1                    |
| 303                                  | 1,0000       | 0,1741      | 0,7606      | 0,4163    | 1                   | 1                    |
| 306                                  | 0,9999       | 0,1392      | 0,8947      | 0,3765    | 1                   | 1                    |
| 311                                  | 0,9988       | 0,1677      | 0,4327      | 0,2134    | 0                   | 0                    |
| 329                                  | 0,0030       | 0,0003      | 0,5319      | 0,1130    | 1                   | 0                    |
| 330                                  | 0,9867       | 0,0627      | 0,8667      | 0,4135    | 1                   | 1                    |
| 332                                  | 1,0000       | 0,4935      | 0,8786      | 0,6030    | 1                   | 1                    |
| 357                                  | 0,9994       | 0,1578      | 0,6517      | 0,2876    | 1                   | 0                    |
| 358                                  | 1,0000       | 0,8324      | 0,4939      | 0,2301    | 0                   | 0                    |
| 360                                  | 0,0002       | 0,0000      | 0,6840      | 0,0759    | 1                   | 0                    |
| 364                                  | 0,0586       | 0,0041      | 0,6027      | 0,3032    | 1                   | 0                    |
| 367                                  | 1,0000       | 0,1673      | 0,6643      | 0,2157    | 1                   | 0                    |
| 375                                  | 0,9991       | 0,1221      | 0,5603      | 0,2870    | 1                   | 0                    |
| 398                                  | 0,9219       | 0,1680      | 0,6893      | 0,4919    | 1                   | 0                    |
| 403                                  | 1,0000       | 0,4989      | 0,8679      | 0,6946    | 1                   | 1                    |
| 426                                  | 0,4067       | 0,0230      | 0,6087      | 0,2152    | 1                   | 0                    |
| 448                                  | 0,9815       | 0,0848      | 0,7175      | 0,0924    | 1                   | 0                    |
| 452                                  | 0,9995       | 0,2098      | 0,8232      | 0,4364    | 1                   | 1                    |
| 457                                  | 0,9902       | 0,4152      | 0,8516      | 0,6024    | 1                   | 1                    |
| 469                                  | 0,9999       | 0,0845      | 0,8006      | 0,3796    | 1                   | 1                    |
| 488                                  | 0,0008       | 0,0001      | 0,5792      | 0,1801    | 1                   | 0                    |
| 490                                  | 0,0618       | 0,0069      | 0,6477      | 0,3446    | 1                   | 0                    |
| 506                                  | 0,9966       | 0,0845      | 0,7232      | 0,1266    | 1                   | 0                    |
| 517                                  | 0,9637       | 0,0485      | 0,8568      | 0,4672    | 1                   | 1                    |
| 521                                  | 0,0134       | 0,0008      | 0,5024      | 0,1061    | 1                   | 0                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 525 | 1,0000 | 0,3288 | 0,8555 | 0,5620 | 1 | 1 |
| 540 | 0,0071 | 0,0012 | 0,2422 | 0,0773 | 0 | 0 |
| 560 | 1,0000 | 0,5311 | 0,8855 | 0,6478 | 1 | 1 |
| 580 | 0,0000 | 0,0000 | 0,1447 | 0,0467 | 0 | 0 |
| 590 | 1,0000 | 0,1613 | 0,9241 | 0,6134 | 1 | 1 |
| 593 | 0,9264 | 0,0498 | 0,8108 | 0,2478 | 1 | 1 |
| 598 | 0,5595 | 0,0183 | 0,5965 | 0,1730 | 1 | 0 |
| 609 | 0,9999 | 0,1136 | 0,9297 | 0,5713 | 1 | 1 |
| 619 | 1,0000 | 0,6297 | 0,7287 | 0,5272 | 1 | 0 |
| 622 | 0,0014 | 0,0003 | 0,3615 | 0,0655 | 0 | 0 |
| 635 | 1,0000 | 0,3325 | 0,9378 | 0,6594 | 1 | 1 |
| 637 | 0,9988 | 0,1408 | 0,6835 | 0,2909 | 1 | 0 |
| 663 | 0,9994 | 0,1445 | 0,8959 | 0,5993 | 1 | 1 |
| 664 | 0,0008 | 0,0000 | 0,7407 | 0,0919 | 1 | 0 |
| 680 | 0,9960 | 0,3016 | 0,0000 | 0,0000 | 0 | 0 |
| 689 | 0,9998 | 0,1515 | 0,5608 | 0,2611 | 1 | 0 |
| 709 | 0,0024 | 0,0002 | 0,5333 | 0,1651 | 1 | 0 |
| 755 | 0,0080 | 0,0009 | 0,4709 | 0,2547 | 0 | 0 |
| 768 | 0,1123 | 0,0033 | 0,1655 | 0,0951 | 0 | 0 |
| 770 | 0,0132 | 0,0022 | 0,6959 | 0,3061 | 1 | 0 |
| 775 | 0,9998 | 0,1489 | 0,6724 | 0,1127 | 1 | 0 |
| 779 | 0,0260 | 0,0007 | 0,5112 | 0,0800 | 1 | 0 |
| 790 | 1,0000 | 0,2353 | 0,8676 | 0,3974 | 1 | 1 |
| 818 | 1,0000 | 0,1171 | 0,7846 | 0,4730 | 1 | 1 |
| 828 | 0,1505 | 0,0180 | 0,5778 | 0,3221 | 1 | 0 |
| 833 | 1,0000 | 0,2823 | 0,7500 | 0,4285 | 1 | 1 |
| 836 | 0,0051 | 0,0006 | 0,5564 | 0,1162 | 1 | 0 |
| 842 | 0,6170 | 0,0207 | 0,7240 | 0,2277 | 1 | 0 |
| 845 | 0,0031 | 0,0002 | 0,5800 | 0,2751 | 1 | 0 |
| 852 | 1,0000 | 0,2771 | 0,8957 | 0,5416 | 1 | 1 |
| 855 | 0,0001 | 0,0000 | 0,0000 | 0,0000 | 0 | 0 |
| 876 | 0,2905 | 0,0368 | 0,3421 | 0,2207 | 0 | 0 |
| 879 | 0,1494 | 0,0033 | 0,7928 | 0,2353 | 1 | 1 |
| 907 | 1,0000 | 0,7029 | 0,9354 | 0,7097 | 1 | 1 |
| 909 | 1,0000 | 0,2165 | 0,6968 | 0,4431 | 1 | 0 |
| 913 | 0,0199 | 0,0032 | 0,3254 | 0,1270 | 0 | 0 |

## Anexo V

### Tabelas de valores de cada 10-fold cross Validation.

Tabela 14 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced, referente a fold 1.

| Fold 1             | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média              | 0,274322802  |             | 0,389997495 |           | 0,902173913         | 0,5                  |
| Média onde IoU > 0 | 0,304046742  |             | 0,435384089 |           | 0,902173913         | 0,5                  |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 004                | 0,9860       | 0,0701      | 0,5180      | 0,1336    | 1                   | 0                    |
| 016                | 1,0000       | 0,4545      | 0,7352      | 0,4127    | 1                   | 0                    |
| 028                | 1,0000       | 0,9258      | 0,9299      | 0,7464    | 1                   | 1                    |
| 046                | 0,9939       | 0,0828      | 0,9259      | 0,3121    | 1                   | 1                    |
| 054                | 0,9686       | 0,0303      | 0,5992      | 0,3825    | 1                   | 0                    |
| 062                | 0,9841       | 0,1166      | 0,7037      | 0,2342    | 1                   | 0                    |
| 085                | 1,0000       | 0,7339      | 0,7321      | 0,4491    | 1                   | 0                    |
| 087                | 0,9737       | 0,1060      | 0,7857      | 0,3519    | 1                   | 1                    |
| 092                | 1,0000       | 0,7878      | 0,6219      | 0,4842    | 1                   | 0                    |
| 103                | 0,0024       | 0,0004      | 0,4816      | 0,2538    | 0                   | 0                    |
| 104                | 0,9977       | 0,0771      | 0,8353      | 0,3677    | 1                   | 1                    |
| 110                | 0,0076       | 0,0007      | 0,7500      | 0,3039    | 1                   | 1                    |
| 122                | 1,0000       | 0,1020      | 0,7012      | 0,2774    | 1                   | 0                    |
| 158                | 1,0000       | 0,2645      | 0,8625      | 0,4250    | 1                   | 1                    |
| 161                | 0,9167       | 0,0226      | 0,7294      | 0,2815    | 1                   | 0                    |
| 172                | 0,9998       | 0,0715      | 0,5941      | 0,2842    | 1                   | 0                    |
| 196                | 0,0415       | 0,0038      | 0,5138      | 0,2049    | 1                   | 0                    |
| 223                | 0,9995       | 0,2842      | 0,6429      | 0,3705    | 1                   | 0                    |
| 244                | 0,9982       | 0,0661      | 0,8865      | 0,2772    | 1                   | 1                    |
| 251                | 0,4612       | 0,0111      | 0,4147      | 0,0180    | 0                   | 0                    |
| 274                | 0,9293       | 0,0205      | 0,4858      | 0,0583    | 0                   | 0                    |
| 279                | 0,7683       | 0,0793      | 0,7619      | 0,3850    | 1                   | 1                    |
| 283                | 0,9884       | 0,1568      | 0,8754      | 0,2022    | 1                   | 1                    |
| 319                | 0,9776       | 0,0477      | 0,7447      | 0,1941    | 1                   | 0                    |
| 323                | 1,0000       | 0,9427      | 0,8081      | 0,7039    | 1                   | 1                    |
| 328                | 1,0000       | 0,6252      | 0,9744      | 0,6606    | 1                   | 1                    |
| 346                | 1,0000       | 0,1579      | 0,7611      | 0,3570    | 1                   | 1                    |
| 352                | 0,9081       | 0,0949      | 0,7742      | 0,3220    | 1                   | 1                    |
| 374                | 0,0002       | 0,0001      | 0,1103      | 0,0473    | 0                   | 0                    |
| 382                | 1,0000       | 0,6337      | 0,7995      | 0,5895    | 1                   | 1                    |
| 383                | 1,0000       | 0,4584      | 0,8491      | 0,6278    | 1                   | 1                    |
| 384                | 0,9486       | 0,1809      | 0,7671      | 0,2060    | 1                   | 1                    |
| 402                | 1,0000       | 0,3415      | 0,7931      | 0,5088    | 1                   | 1                    |
| 410                | 1,0000       | 0,3864      | 0,9480      | 0,6721    | 1                   | 1                    |
| 423                | 0,0232       | 0,0024      | 0,5091      | 0,1511    | 1                   | 0                    |
| 425                | 0,0193       | 0,0029      | 0,5093      | 0,2586    | 1                   | 0                    |
| 440                | 0,0268       | 0,0019      | 0,7345      | 0,3514    | 1                   | 0                    |
| 447                | 0,5379       | 0,0208      | 0,6133      | 0,2752    | 1                   | 0                    |
| 451                | 0,9800       | 0,0172      | 0,7954      | 0,2045    | 1                   | 1                    |
| 468                | 0,9957       | 0,1090      | 0,6502      | 0,3082    | 1                   | 0                    |
| 473                | 0,7358       | 0,0885      | 0,8892      | 0,3232    | 1                   | 1                    |
| 477                | 0,0523       | 0,0103      | 0,7938      | 0,2279    | 1                   | 1                    |
| 483                | 1,0000       | 0,8472      | 0,9412      | 0,7192    | 1                   | 1                    |
| 519                | 0,9663       | 0,1455      | 0,6204      | 0,3886    | 1                   | 0                    |
| 524                | 1,0000       | 0,3325      | 0,8976      | 0,5509    | 1                   | 1                    |
| 533                | 1,0000       | 0,8750      | 0,9242      | 0,7244    | 1                   | 1                    |
| 544                | 0,9989       | 0,1970      | 0,5300      | 0,3604    | 1                   | 0                    |
| 547                | 1,0000       | 0,2316      | 0,6594      | 0,3074    | 1                   | 0                    |
| 575                | 1,0000       | 0,0975      | 0,8185      | 0,3047    | 1                   | 1                    |
| 581                | 1,0000       | 0,6593      | 0,7333      | 0,4658    | 1                   | 0                    |
| 596                | 1,0000       | 0,5298      | 0,8161      | 0,4822    | 1                   | 1                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 601 | 1,0000 | 0,8539 | 0,7074 | 0,3625 | 1 | 0 |
| 606 | 0,9968 | 0,0397 | 0,8882 | 0,2916 | 1 | 1 |
| 615 | 1,0000 | 0,3491 | 0,7456 | 0,4033 | 1 | 0 |
| 618 | 1,0000 | 0,8796 | 0,8273 | 0,6419 | 1 | 1 |
| 631 | 0,0280 | 0,0057 | 0,7341 | 0,3420 | 1 | 0 |
| 636 | 1,0000 | 0,3693 | 0,7598 | 0,4259 | 1 | 1 |
| 651 | 0,0006 | 0,0001 | 0,5647 | 0,1794 | 1 | 0 |
| 656 | 0,0825 | 0,0053 | 0,5368 | 0,2406 | 1 | 0 |
| 665 | 0,0509 | 0,0044 | 0,7604 | 0,2055 | 1 | 1 |
| 674 | 1,0000 | 0,3060 | 0,8085 | 0,4607 | 1 | 1 |
| 677 | 0,9738 | 0,0711 | 0,8654 | 0,3402 | 1 | 1 |
| 684 | 0,0031 | 0,0004 | 0,0347 | 0,0008 | 0 | 0 |
| 688 | 0,2025 | 0,0100 | 0,4296 | 0,1357 | 0 | 0 |
| 708 | 0,9998 | 0,2150 | 0,9238 | 0,3015 | 1 | 1 |
| 711 | 0,9998 | 0,1526 | 0,6733 | 0,4215 | 1 | 0 |
| 714 | 1,0000 | 0,6039 | 0,7222 | 0,3632 | 1 | 0 |
| 719 | 0,0005 | 0,0001 | 0,7808 | 0,2636 | 1 | 1 |
| 734 | 1,0000 | 0,4365 | 0,8116 | 0,4707 | 1 | 1 |
| 760 | 1,0000 | 0,4983 | 0,7883 | 0,3395 | 1 | 1 |
| 763 | 0,0124 | 0,0017 | 0,6541 | 0,2829 | 1 | 0 |
| 769 | 0,4629 | 0,0326 | 0,7102 | 0,4319 | 1 | 0 |
| 782 | 0,8903 | 0,2025 | 0,8235 | 0,3959 | 1 | 1 |
| 795 | 0,9999 | 0,1137 | 0,8403 | 0,3014 | 1 | 1 |
| 811 | 0,0212 | 0,0013 | 0,9394 | 0,3316 | 1 | 1 |
| 812 | 0,9998 | 0,1598 | 0,7429 | 0,3326 | 1 | 0 |
| 819 | 0,9977 | 0,0469 | 0,6375 | 0,2767 | 1 | 0 |
| 850 | 0,9999 | 0,1708 | 0,7505 | 0,3603 | 1 | 1 |
| 851 | 1,0000 | 0,5965 | 0,9235 | 0,6862 | 1 | 1 |
| 857 | 0,9922 | 0,0424 | 0,8919 | 0,6180 | 1 | 1 |
| 862 | 0,7056 | 0,0809 | 0,8276 | 0,3550 | 1 | 1 |
| 863 | 1,0000 | 0,6243 | 0,6767 | 0,3698 | 1 | 0 |
| 866 | 0,9720 | 0,1478 | 0,7378 | 0,4660 | 1 | 0 |
| 868 | 0,0006 | 0,0001 | 0,3671 | 0,0871 | 0 | 0 |
| 877 | 0,9989 | 0,1583 | 0,6888 | 0,2976 | 1 | 0 |
| 889 | 0,0070 | 0,0010 | 0,1117 | 0,0600 | 0 | 0 |
| 894 | 0,9967 | 0,2077 | 0,6154 | 0,4061 | 1 | 0 |
| 896 | 1,0000 | 0,2199 | 0,8939 | 0,3179 | 1 | 1 |
| 911 | 0,9953 | 0,2933 | 0,7301 | 0,4269 | 1 | 0 |
| 915 | 1,0000 | 0,3389 | 0,8708 | 0,3825 | 1 | 1 |
| 918 | 1,0000 | 0,7345 | 0,8514 | 0,6701 | 1 | 1 |
| 920 | 1,0000 | 0,3691 | 0,2046 | 0,1441 | 0 | 0 |

Tabela 15 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced, referente a fold 2.

| Fold 2             | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média              | 0,26878621   |             | 0,386064244 |           | 0,891304348         | 0,52173913           |
| Média onde IoU > 0 | 0,294150188  |             | 0,423746023 |           | 0,891304348         | 0,52173913           |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 001                | 0,0141       | 0,0006      | 0,8122      | 0,2250    | 1                   | 1                    |
| 003                | 0,7473       | 0,1164      | 0,7026      | 0,2798    | 1                   | 0                    |
| 043                | 1,0000       | 0,8726      | 0,3929      | 0,2974    | 0                   | 0                    |
| 067                | 0,6517       | 0,0995      | 0,6265      | 0,3428    | 1                   | 0                    |
| 082                | 1,0000       | 0,9563      | 0,8571      | 0,6137    | 1                   | 1                    |
| 107                | 1,0000       | 0,1907      | 0,8383      | 0,4670    | 1                   | 1                    |
| 119                | 1,0000       | 0,1489      | 0,7719      | 0,3084    | 1                   | 1                    |
| 130                | 0,0023       | 0,0001      | 0,7992      | 0,1804    | 1                   | 1                    |
| 141                | 1,0000       | 0,7213      | 0,9630      | 0,7623    | 1                   | 1                    |
| 145                | 0,9999       | 0,6271      | 0,6080      | 0,4220    | 1                   | 0                    |
| 151                | 0,9999       | 0,1435      | 0,7819      | 0,3371    | 1                   | 1                    |
| 164                | 0,0675       | 0,0239      | 0,8182      | 0,5654    | 1                   | 1                    |
| 168                | 1,0000       | 0,2032      | 0,5392      | 0,3934    | 1                   | 0                    |
| 184                | 0,0301       | 0,0017      | 0,1803      | 0,0613    | 0                   | 0                    |
| 189                | 1,0000       | 0,1072      | 0,8600      | 0,4460    | 1                   | 1                    |
| 191                | 0,4128       | 0,0361      | 0,7624      | 0,3459    | 1                   | 1                    |
| 198                | 1,0000       | 0,5117      | 0,8234      | 0,4892    | 1                   | 1                    |
| 201                | 0,9990       | 0,3185      | 0,7532      | 0,4666    | 1                   | 1                    |
| 204                | 0,0316       | 0,0030      | 0,4094      | 0,2137    | 0                   | 0                    |
| 216                | 0,6033       | 0,0346      | 0,7469      | 0,3190    | 1                   | 0                    |
| 219                | 0,9886       | 0,0991      | 0,6540      | 0,2695    | 1                   | 0                    |
| 221                | 1,0000       | 0,7153      | 0,7879      | 0,5545    | 1                   | 1                    |
| 229                | 0,9374       | 0,1379      | 0,7248      | 0,4781    | 1                   | 0                    |
| 232                | 1,0000       | 0,0634      | 0,6519      | 0,1266    | 1                   | 0                    |
| 239                | 1,0000       | 0,3732      | 0,8295      | 0,5211    | 1                   | 1                    |
| 241                | 1,0000       | 0,4623      | 0,5799      | 0,3804    | 1                   | 0                    |
| 304                | 0,9999       | 0,0476      | 0,7346      | 0,2397    | 1                   | 0                    |
| 316                | 0,0029       | 0,0002      | 0,8333      | 0,3091    | 1                   | 1                    |
| 318                | 0,5343       | 0,0885      | 0,5833      | 0,2557    | 1                   | 0                    |
| 333                | 0,9999       | 0,0656      | 0,7979      | 0,3411    | 1                   | 1                    |
| 337                | 0,9965       | 0,4610      | 0,8992      | 0,4890    | 1                   | 1                    |
| 338                | 1,0000       | 0,5769      | 0,8383      | 0,5635    | 1                   | 1                    |
| 354                | 0,7997       | 0,2099      | 0,4169      | 0,1559    | 0                   | 0                    |
| 365                | 0,0482       | 0,0020      | 0,8421      | 0,4040    | 1                   | 1                    |
| 368                | 1,0000       | 0,5771      | 0,7401      | 0,4626    | 1                   | 0                    |
| 400                | 1,0000       | 0,5950      | 0,8843      | 0,5831    | 1                   | 1                    |
| 416                | 0,9999       | 0,3349      | 0,6978      | 0,3090    | 1                   | 0                    |
| 420                | 0,8604       | 0,0419      | 0,8846      | 0,5492    | 1                   | 1                    |
| 424                | 1,0000       | 0,3225      | 0,7383      | 0,3735    | 1                   | 0                    |
| 427                | 0,0497       | 0,0019      | 0,5361      | 0,0597    | 1                   | 0                    |
| 446                | 0,0120       | 0,0044      | 0,3423      | 0,1786    | 0                   | 0                    |
| 464                | 1,0000       | 0,6393      | 0,8515      | 0,6302    | 1                   | 1                    |
| 471                | 0,1180       | 0,0275      | 0,6643      | 0,3135    | 1                   | 0                    |
| 478                | 0,7548       | 0,0292      | 0,4274      | 0,1715    | 0                   | 0                    |
| 480                | 1,0000       | 0,2803      | 0,7019      | 0,3234    | 1                   | 0                    |
| 482                | 0,9984       | 0,2781      | 0,3210      | 0,1806    | 0                   | 0                    |
| 485                | 1,0000       | 0,5984      | 0,9080      | 0,7391    | 1                   | 1                    |
| 491                | 1,0000       | 0,5016      | 0,8488      | 0,5946    | 1                   | 1                    |
| 500                | 0,9535       | 0,1917      | 0,8459      | 0,4559    | 1                   | 1                    |
| 501                | 0,9969       | 0,0623      | 0,8820      | 0,5006    | 1                   | 1                    |
| 520                | 1,0000       | 0,2357      | 0,9109      | 0,4298    | 1                   | 1                    |
| 534                | 1,0000       | 0,4028      | 0,5897      | 0,3800    | 1                   | 0                    |
| 541                | 1,0000       | 0,7812      | 0,8777      | 0,6979    | 1                   | 1                    |
| 553                | 1,0000       | 0,2861      | 0,9643      | 0,4335    | 1                   | 1                    |
| 567                | 1,0000       | 0,6043      | 0,8442      | 0,5596    | 1                   | 1                    |
| 587                | 0,0013       | 0,0002      | 0,7321      | 0,1642    | 1                   | 0                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 588 | 0,9991 | 0,3292 | 0,9000 | 0,5882 | 1 | 1 |
| 592 | 1,0000 | 0,3470 | 0,7933 | 0,3715 | 1 | 1 |
| 604 | 0,6990 | 0,0352 | 0,4975 | 0,1179 | 0 | 0 |
| 610 | 0,0025 | 0,0003 | 0,4867 | 0,1047 | 0 | 0 |
| 628 | 0,9356 | 0,2574 | 0,7826 | 0,5307 | 1 | 1 |
| 642 | 1,0000 | 0,1039 | 0,5783 | 0,1516 | 1 | 0 |
| 643 | 1,0000 | 0,2082 | 0,7509 | 0,3971 | 1 | 1 |
| 646 | 0,0457 | 0,0019 | 0,7293 | 0,3316 | 1 | 0 |
| 653 | 0,9997 | 0,1213 | 0,9524 | 0,3258 | 1 | 1 |
| 667 | 1,0000 | 0,5768 | 0,8371 | 0,6411 | 1 | 1 |
| 671 | 0,0009 | 0,0001 | 0,6050 | 0,0721 | 1 | 0 |
| 672 | 0,9994 | 0,3889 | 0,7712 | 0,4615 | 1 | 1 |
| 683 | 1,0000 | 0,6069 | 0,8714 | 0,6815 | 1 | 1 |
| 696 | 0,0788 | 0,0043 | 0,6008 | 0,2367 | 1 | 0 |
| 697 | 0,9960 | 0,1349 | 0,5639 | 0,2079 | 1 | 0 |
| 704 | 1,0000 | 0,1129 | 0,8326 | 0,3734 | 1 | 1 |
| 712 | 0,2760 | 0,0308 | 0,7059 | 0,3286 | 1 | 0 |
| 713 | 0,0051 | 0,0006 | 0,5749 | 0,2564 | 1 | 0 |
| 721 | 0,0010 | 0,0001 | 0,7333 | 0,1126 | 1 | 0 |
| 736 | 1,0000 | 0,4501 | 0,7632 | 0,4699 | 1 | 1 |
| 742 | 0,9983 | 0,2392 | 0,2608 | 0,0388 | 0 | 0 |
| 745 | 1,0000 | 0,7714 | 0,8457 | 0,6243 | 1 | 1 |
| 748 | 1,0000 | 0,2038 | 0,7683 | 0,2492 | 1 | 1 |
| 757 | 1,0000 | 0,5730 | 0,8723 | 0,6009 | 1 | 1 |
| 766 | 0,8151 | 0,0620 | 0,8309 | 0,2796 | 1 | 1 |
| 789 | 1,0000 | 0,4423 | 0,8578 | 0,4874 | 1 | 1 |
| 798 | 0,9939 | 0,2139 | 0,6933 | 0,2729 | 1 | 0 |
| 800 | 0,5374 | 0,0168 | 0,5361 | 0,1291 | 1 | 0 |
| 813 | 0,9977 | 0,0270 | 0,6538 | 0,2651 | 1 | 0 |
| 834 | 0,5680 | 0,0151 | 0,7021 | 0,2901 | 1 | 0 |
| 848 | 0,9965 | 0,0933 | 0,8051 | 0,2385 | 1 | 1 |
| 860 | 0,9962 | 0,3705 | 0,6740 | 0,4783 | 1 | 0 |
| 869 | 0,9973 | 0,0476 | 0,8177 | 0,3525 | 1 | 1 |
| 874 | 0,9994 | 0,0668 | 0,7457 | 0,2762 | 1 | 0 |
| 887 | 0,9994 | 0,2095 | 0,5842 | 0,1864 | 1 | 0 |
| 904 | 0,9308 | 0,0099 | 0,8681 | 0,2115 | 1 | 1 |

Tabela 16 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced, referente a fold 3.

| Fold 3             | Score        |             | IoU        |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|------------|-----------|---------------------|----------------------|
| Média              | 0,266296629  |             | 0,35068284 |           | 0,826086957         | 0,369565217          |
| Média onde IoU > 0 | 0,300564127  |             | 0,39733218 |           | 0,835164835         | 0,373626374          |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 011                | 1,0000       | 0,4580      | 0,7349     | 0,3647    | 1                   | 0                    |
| 021                | 0,0630       | 0,0027      | 0,7138     | 0,2054    | 1                   | 0                    |
| 024                | 0,0593       | 0,0211      | 0,4242     | 0,2275    | 0                   | 0                    |
| 040                | 1,0000       | 0,1819      | 0,6198     | 0,2376    | 1                   | 0                    |
| 045                | 1,0000       | 0,8138      | 0,8315     | 0,5745    | 1                   | 1                    |
| 050                | 0,9948       | 0,0931      | 0,4800     | 0,1663    | 0                   | 0                    |
| 069                | 0,9367       | 0,0324      | 0,6667     | 0,3446    | 1                   | 0                    |
| 081                | 0,0528       | 0,0024      | 0,8526     | 0,4370    | 1                   | 1                    |
| 096                | 0,0291       | 0,0005      | 0,4064     | 0,0357    | 0                   | 0                    |
| 112                | 1,0000       | 0,8012      | 0,7087     | 0,5523    | 1                   | 0                    |
| 118                | 0,2966       | 0,0323      | 0,8136     | 0,2879    | 1                   | 1                    |
| 123                | 1,0000       | 0,4093      | 0,5877     | 0,3538    | 1                   | 0                    |
| 137                | 1,0000       | 0,7439      | 0,5783     | 0,3693    | 1                   | 0                    |
| 140                | 1,0000       | 0,5267      | 0,8539     | 0,5715    | 1                   | 1                    |
| 142                | 0,0001       | 0,0000      | 0,5000     | 0,0998    | 1                   | 0                    |
| 154                | 0,9409       | 0,3351      | 0,6006     | 0,4186    | 1                   | 0                    |
| 157                | 1,0000       | 0,5438      | 0,8720     | 0,6423    | 1                   | 1                    |
| 162                | 0,9998       | 0,2238      | 0,5543     | 0,1950    | 1                   | 0                    |
| 166                | 0,0005       | 0,0001      | 0,7273     | 0,1855    | 1                   | 0                    |
| 178                | 0,9640       | 0,1217      | 0,8395     | 0,3809    | 1                   | 1                    |
| 179                | 0,9999       | 0,2117      | 0,7077     | 0,2243    | 1                   | 0                    |
| 192                | 0,9996       | 0,1068      | 0,6778     | 0,2391    | 1                   | 0                    |
| 213                | 1,0000       | 0,3449      | 0,8881     | 0,5730    | 1                   | 1                    |
| 226                | 0,9583       | 0,0295      | 0,6625     | 0,2544    | 1                   | 0                    |
| 246                | 0,9996       | 0,2719      | 0,6490     | 0,2810    | 1                   | 0                    |
| 248                | 0,0001       | 0,0000      | 0,1139     | 0,0747    | 0                   | 0                    |
| 257                | 1,0000       | 0,3905      | 0,8343     | 0,5787    | 1                   | 1                    |
| 294                | 0,0479       | 0,0033      | 0,1143     | 0,0393    | 0                   | 0                    |
| 295                | 0,9998       | 0,2793      | 0,7557     | 0,3679    | 1                   | 1                    |
| 297                | 1,0000       | 0,8576      | 0,8966     | 0,7308    | 1                   | 1                    |
| 300                | 0,0154       | 0,0007      | 0,7834     | 0,1435    | 1                   | 1                    |
| 305                | 0,0009       | 0,0001      | 0,7074     | 0,1404    | 1                   | 0                    |
| 312                | 0,2516       | 0,0184      | 0,6613     | 0,1601    | 1                   | 0                    |
| 345                | 1,0000       | 0,6869      | 0,8257     | 0,5757    | 1                   | 1                    |
| 355                | 0,9566       | 0,0673      | 0,6055     | 0,2670    | 1                   | 0                    |
| 356                | 0,9967       | 0,0606      | 0,7496     | 0,1604    | 1                   | 0                    |
| 363                | 0,2027       | 0,0151      | 0,6573     | 0,3093    | 1                   | 0                    |
| 366                | 0,9945       | 0,0374      | 0,6980     | 0,2691    | 1                   | 0                    |
| 379                | 0,4078       | 0,0620      | 0,4186     | 0,3168    | 0                   | 0                    |
| 386                | 1,0000       | 0,2827      | 0,8103     | 0,4073    | 1                   | 1                    |
| 395                | 1,0000       | 0,1466      | 0,5974     | 0,1832    | 1                   | 0                    |
| 412                | 1,0000       | 0,0873      | 0,8536     | 0,4548    | 1                   | 1                    |
| 415                | 1,0000       | 0,9725      | 0,7112     | 0,4270    | 1                   | 0                    |
| 422                | 0,9975       | 0,1020      | 0,7589     | 0,3090    | 1                   | 1                    |
| 476                | 1,0000       | 0,6828      | 0,9137     | 0,6618    | 1                   | 1                    |
| 486                | 1,0000       | 0,0680      | 0,7632     | 0,2748    | 1                   | 1                    |
| 499                | 1,0000       | 0,6874      | 0,9030     | 0,3709    | 1                   | 1                    |
| 515                | 0,9991       | 0,1015      | 0,9147     | 0,2409    | 1                   | 1                    |
| 532                | 0,9829       | 0,1588      | 0,6085     | 0,2712    | 1                   | 0                    |
| 537                | 1,0000       | 0,8507      | 0,6257     | 0,4621    | 1                   | 0                    |
| 538                | 0,9954       | 0,2212      | 0,7172     | 0,3502    | 1                   | 0                    |
| 568                | 0,9893       | 0,0691      | 0,8250     | 0,2512    | 1                   | 1                    |
| 572                | 0,0547       | 0,0085      | 0,4962     | 0,2560    | 0                   | 0                    |
| 591                | 0,0025       | 0,0004      | 0,7362     | 0,2366    | 1                   | 0                    |
| 595                | 1,0000       | 0,3646      | 0,9545     | 0,5285    | 1                   | 1                    |
| 603                | 0,2907       | 0,0182      | 0,5419     | 0,1998    | 1                   | 0                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 640 | 0,9992 | 0,1068 | 0,8559 | 0,3384 | 1 | 1 |
| 681 | 0,9997 | 0,0585 | 0,7246 | 0,2048 | 1 | 0 |
| 687 | 0,9975 | 0,0797 | 0,5232 | 0,2068 | 1 | 0 |
| 692 | 0,9763 | 0,0487 | 0,9714 | 0,4710 | 1 | 1 |
| 693 | 1,0000 | 0,4004 | 0,4107 | 0,1906 | 0 | 0 |
| 694 | 1,0000 | 0,0943 | 0,7756 | 0,2038 | 1 | 1 |
| 701 | 0,9992 | 0,0704 | 0,9130 | 0,3644 | 1 | 1 |
| 715 | 0,0000 | 0,0000 | 0,0000 | 0,0000 | 0 | 0 |
| 723 | 1,0000 | 0,5409 | 0,4988 | 0,1531 | 0 | 0 |
| 729 | 0,5550 | 0,0058 | 0,8526 | 0,4697 | 1 | 1 |
| 733 | 1,0000 | 0,2101 | 0,8040 | 0,2945 | 1 | 1 |
| 741 | 0,8387 | 0,1766 | 0,7440 | 0,5848 | 1 | 0 |
| 743 | 0,9997 | 0,2241 | 0,7049 | 0,4139 | 1 | 0 |
| 747 | 1,0000 | 0,3561 | 0,6724 | 0,4458 | 1 | 0 |
| 756 | 1,0000 | 0,8043 | 0,7037 | 0,5675 | 1 | 0 |
| 761 | 0,0001 | 0,0000 | 0,5435 | 0,0711 | 1 | 0 |
| 774 | 0,0001 | 0,0000 | 0,7401 | 0,1954 | 1 | 0 |
| 776 | 1,0000 | 0,3226 | 0,9420 | 0,6711 | 1 | 1 |
| 786 | 0,9999 | 0,1516 | 0,9422 | 0,2444 | 1 | 1 |
| 808 | 0,7624 | 0,0105 | 0,6988 | 0,2328 | 1 | 0 |
| 810 | 1,0000 | 0,7903 | 0,8203 | 0,3547 | 1 | 1 |
| 817 | 0,9998 | 0,0523 | 0,6683 | 0,3447 | 1 | 0 |
| 823 | 1,0000 | 0,3142 | 0,7455 | 0,4159 | 1 | 0 |
| 844 | 0,8185 | 0,2948 | 0,3657 | 0,2405 | 0 | 0 |
| 846 | 0,0022 | 0,0003 | 0,6040 | 0,1427 | 1 | 0 |
| 859 | 1,0000 | 0,3835 | 0,4780 | 0,2387 | 0 | 0 |
| 870 | 0,9753 | 0,2491 | 0,8864 | 0,5052 | 1 | 1 |
| 872 | 0,0491 | 0,0069 | 0,3077 | 0,0206 | 0 | 0 |
| 873 | 1,0000 | 0,8028 | 0,8022 | 0,6999 | 1 | 1 |
| 884 | 1,0000 | 0,7204 | 0,8644 | 0,6422 | 1 | 1 |
| 891 | 0,9999 | 0,1770 | 0,2998 | 0,1202 | 0 | 0 |
| 902 | 0,0249 | 0,0035 | 0,4515 | 0,2278 | 0 | 0 |
| 903 | 0,8804 | 0,0381 | 0,7112 | 0,1226 | 1 | 0 |
| 906 | 0,9953 | 0,1964 | 0,6164 | 0,4380 | 1 | 0 |
| 908 | 0,0006 | 0,0001 | 0,1428 | 0,0097 | 0 | 0 |
| 921 | 0,0017 | 0,0001 | 0,8341 | 0,0545 | 1 | 1 |

Tabela 17 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced, referente a fold 4.

| Fold 4             | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média              | 0,219774456  |             | 0,38930602  |           | 0,815217391         | 0,445652174          |
| Média onde IoU > 0 | 0,250173262  |             | 0,450477734 |           | 0,815217391         | 0,445652174          |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 006                | 0,0015       | 0,0003      | 0,6147      | 0,1967    | 1                   | 0                    |
| 042                | 1,0000       | 0,0753      | 0,7243      | 0,3679    | 1                   | 0                    |
| 048                | 0,0015       | 0,0001      | 0,4795      | 0,1068    | 0                   | 0                    |
| 053                | 1,0000       | 0,7848      | 0,8262      | 0,6150    | 1                   | 1                    |
| 059                | 0,0502       | 0,0067      | 0,5934      | 0,2784    | 1                   | 0                    |
| 065                | 1,0000       | 0,2154      | 0,8685      | 0,4306    | 1                   | 1                    |
| 074                | 0,9991       | 0,0598      | 0,6973      | 0,2493    | 1                   | 0                    |
| 091                | 0,0679       | 0,0014      | 0,8347      | 0,5390    | 1                   | 1                    |
| 099                | 1,0000       | 0,7486      | 0,7953      | 0,4279    | 1                   | 1                    |
| 102                | 0,2682       | 0,0160      | 0,6136      | 0,2685    | 1                   | 0                    |
| 117                | 0,4537       | 0,0376      | 0,8619      | 0,3425    | 1                   | 1                    |
| 124                | 0,0214       | 0,0012      | 0,8089      | 0,3462    | 1                   | 1                    |
| 126                | 0,0370       | 0,0042      | 0,6119      | 0,1880    | 1                   | 0                    |
| 135                | 0,9999       | 0,6834      | 0,9535      | 0,7232    | 1                   | 1                    |
| 148                | 1,0000       | 0,4138      | 0,8757      | 0,5753    | 1                   | 1                    |
| 155                | 1,0000       | 0,1298      | 0,6425      | 0,2304    | 1                   | 0                    |
| 169                | 0,0061       | 0,0007      | 0,4578      | 0,1418    | 0                   | 0                    |
| 173                | 0,9655       | 0,0194      | 0,6788      | 0,1639    | 1                   | 0                    |
| 181                | 0,0005       | 0,0002      | 0,4881      | 0,2689    | 0                   | 0                    |
| 200                | 0,3379       | 0,0075      | 0,8853      | 0,4711    | 1                   | 1                    |
| 206                | 0,0028       | 0,0002      | 0,4759      | 0,1294    | 0                   | 0                    |
| 207                | 0,0004       | 0,0001      | 0,2022      | 0,0245    | 0                   | 0                    |
| 215                | 0,0028       | 0,0004      | 0,6627      | 0,2700    | 1                   | 0                    |
| 224                | 0,2851       | 0,0124      | 0,9259      | 0,5950    | 1                   | 1                    |
| 225                | 0,2726       | 0,0037      | 0,9247      | 0,4431    | 1                   | 1                    |
| 230                | 0,7813       | 0,0167      | 0,8475      | 0,3360    | 1                   | 1                    |
| 240                | 0,0276       | 0,0033      | 0,5648      | 0,1562    | 1                   | 0                    |
| 242                | 0,9987       | 0,3377      | 0,6710      | 0,4003    | 1                   | 0                    |
| 249                | 0,0015       | 0,0001      | 0,7131      | 0,2554    | 1                   | 0                    |
| 254                | 0,9998       | 0,3772      | 0,6831      | 0,3795    | 1                   | 0                    |
| 263                | 0,0106       | 0,0022      | 0,6875      | 0,4374    | 1                   | 0                    |
| 266                | 1,0000       | 0,5260      | 0,8626      | 0,6523    | 1                   | 1                    |
| 273                | 0,0702       | 0,0122      | 0,4451      | 0,2200    | 0                   | 0                    |
| 275                | 0,1313       | 0,0140      | 0,7536      | 0,3582    | 1                   | 1                    |
| 285                | 0,2892       | 0,0059      | 0,6286      | 0,1285    | 1                   | 0                    |
| 290                | 0,0606       | 0,0052      | 0,3750      | 0,0256    | 0                   | 0                    |
| 292                | 1,0000       | 0,4745      | 0,8857      | 0,5456    | 1                   | 1                    |
| 302                | 0,9791       | 0,1473      | 0,7544      | 0,4488    | 1                   | 1                    |
| 324                | 1,0000       | 0,1536      | 0,8993      | 0,5146    | 1                   | 1                    |
| 325                | 0,0012       | 0,0001      | 0,6129      | 0,0808    | 1                   | 0                    |
| 326                | 0,9188       | 0,1975      | 0,8333      | 0,4486    | 1                   | 1                    |
| 340                | 0,9876       | 0,2138      | 0,7499      | 0,3407    | 1                   | 0                    |
| 349                | 1,0000       | 0,6614      | 0,8889      | 0,6451    | 1                   | 1                    |
| 362                | 1,0000       | 0,4238      | 0,9756      | 0,6229    | 1                   | 1                    |
| 388                | 0,0064       | 0,0004      | 0,7778      | 0,3154    | 1                   | 1                    |
| 389                | 0,1757       | 0,0070      | 0,6452      | 0,1851    | 1                   | 0                    |
| 407                | 0,9990       | 0,0160      | 0,6523      | 0,1361    | 1                   | 0                    |
| 414                | 1,0000       | 0,5965      | 0,6928      | 0,3471    | 1                   | 0                    |
| 417                | 0,0471       | 0,0063      | 0,7456      | 0,5285    | 1                   | 0                    |
| 435                | 1,0000       | 0,3831      | 0,8880      | 0,6085    | 1                   | 1                    |
| 438                | 1,0000       | 0,3764      | 0,5870      | 0,1750    | 1                   | 0                    |
| 444                | 0,9317       | 0,0181      | 0,8621      | 0,4280    | 1                   | 1                    |
| 445                | 0,0055       | 0,0009      | 0,5068      | 0,0761    | 1                   | 0                    |
| 455                | 0,4349       | 0,0466      | 0,7640      | 0,1787    | 1                   | 1                    |
| 474                | 0,4285       | 0,0144      | 0,8120      | 0,3529    | 1                   | 1                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 503 | 0,0344 | 0,0042 | 0,7511 | 0,2916 | 1 | 1 |
| 507 | 1,0000 | 0,4316 | 0,8605 | 0,5941 | 1 | 1 |
| 509 | 1,0000 | 0,5675 | 0,8954 | 0,5647 | 1 | 1 |
| 513 | 0,1336 | 0,0059 | 0,5137 | 0,1528 | 1 | 0 |
| 523 | 0,0224 | 0,0020 | 0,7115 | 0,0492 | 1 | 0 |
| 526 | 0,0112 | 0,0006 | 0,5031 | 0,1306 | 1 | 0 |
| 550 | 0,9883 | 0,1007 | 0,4590 | 0,2267 | 0 | 0 |
| 554 | 0,9992 | 0,0591 | 0,6684 | 0,3709 | 1 | 0 |
| 556 | 0,1455 | 0,0085 | 0,5699 | 0,2485 | 1 | 0 |
| 557 | 0,0033 | 0,0002 | 0,7524 | 0,2390 | 1 | 1 |
| 561 | 0,0057 | 0,0005 | 0,3824 | 0,1123 | 0 | 0 |
| 566 | 0,0066 | 0,0008 | 0,3956 | 0,0851 | 0 | 0 |
| 576 | 0,0014 | 0,0004 | 0,5882 | 0,3225 | 1 | 0 |
| 612 | 0,9999 | 0,5497 | 0,7775 | 0,3988 | 1 | 1 |
| 633 | 1,0000 | 0,5971 | 0,9569 | 0,6414 | 1 | 1 |
| 634 | 0,0032 | 0,0004 | 0,3447 | 0,0849 | 0 | 0 |
| 652 | 0,0065 | 0,0005 | 0,7251 | 0,2519 | 1 | 0 |
| 654 | 0,3678 | 0,0352 | 0,1021 | 0,0141 | 0 | 0 |
| 673 | 0,0060 | 0,0007 | 0,7346 | 0,2377 | 1 | 0 |
| 678 | 0,0174 | 0,0016 | 0,6096 | 0,2005 | 1 | 0 |
| 706 | 1,0000 | 0,8396 | 0,7840 | 0,5534 | 1 | 1 |
| 716 | 0,1037 | 0,0159 | 0,6826 | 0,3106 | 1 | 0 |
| 717 | 1,0000 | 0,2962 | 0,7340 | 0,5060 | 1 | 0 |
| 728 | 0,0035 | 0,0008 | 0,4474 | 0,1509 | 0 | 0 |
| 739 | 1,0000 | 0,4807 | 0,7679 | 0,3880 | 1 | 1 |
| 746 | 0,0089 | 0,0004 | 0,0668 | 0,0054 | 0 | 0 |
| 758 | 0,0303 | 0,0029 | 0,4961 | 0,2688 | 0 | 0 |
| 773 | 0,9982 | 0,1860 | 0,7873 | 0,4290 | 1 | 1 |
| 791 | 0,8105 | 0,3809 | 0,1048 | 0,0673 | 0 | 0 |
| 809 | 1,0000 | 0,9097 | 0,8807 | 0,7741 | 1 | 1 |
| 831 | 1,0000 | 0,0608 | 0,9135 | 0,5410 | 1 | 1 |
| 849 | 0,0002 | 0,0001 | 0,4963 | 0,0574 | 0 | 0 |
| 854 | 1,0000 | 0,7472 | 0,8377 | 0,5579 | 1 | 1 |
| 880 | 1,0000 | 0,4595 | 0,8295 | 0,4917 | 1 | 1 |
| 886 | 0,9965 | 0,1213 | 0,7944 | 0,4101 | 1 | 1 |
| 899 | 1,0000 | 0,1456 | 0,8912 | 0,4488 | 1 | 1 |
| 917 | 1,0000 | 0,1155 | 0,8913 | 0,5241 | 1 | 1 |

Tabela 18 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced, referente a fold 5.

| Fold 5             | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média              | 0,199999878  |             | 0,371909758 |           | 0,869565217         | 0,445652174          |
| Média onde IoU > 0 | 0,218344728  |             | 0,410984906 |           | 0,879120879         | 0,450549451          |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 013                | 0,0393       | 0,0020      | 0,7986      | 0,1905    | 1                   | 1                    |
| 017                | 0,0166       | 0,0016      | 0,6190      | 0,2615    | 1                   | 0                    |
| 020                | 0,8867       | 0,0938      | 0,8670      | 0,5065    | 1                   | 1                    |
| 027                | 0,9939       | 0,1187      | 0,8643      | 0,3761    | 1                   | 1                    |
| 035                | 0,9999       | 0,0960      | 0,6593      | 0,2451    | 1                   | 0                    |
| 039                | 0,0981       | 0,0077      | 0,5220      | 0,2504    | 1                   | 0                    |
| 078                | 1,0000       | 0,5278      | 0,8242      | 0,4452    | 1                   | 1                    |
| 084                | 0,0737       | 0,0118      | 0,6180      | 0,1999    | 1                   | 0                    |
| 088                | 0,7748       | 0,0276      | 0,5161      | 0,1429    | 1                   | 0                    |
| 093                | 0,5012       | 0,0287      | 0,7778      | 0,3640    | 1                   | 1                    |
| 097                | 1,0000       | 0,5947      | 0,9169      | 0,6811    | 1                   | 1                    |
| 113                | 0,0010       | 0,0001      | 0,6429      | 0,2781    | 1                   | 0                    |
| 115                | 1,0000       | 0,2233      | 0,7589      | 0,3460    | 1                   | 1                    |
| 120                | 0,9796       | 0,0743      | 0,7681      | 0,3242    | 1                   | 1                    |
| 121                | 0,0008       | 0,0003      | 0,5816      | 0,0802    | 1                   | 0                    |
| 129                | 0,9997       | 0,4299      | 0,5735      | 0,2505    | 1                   | 0                    |
| 136                | 0,0305       | 0,0042      | 0,7392      | 0,4493    | 1                   | 0                    |
| 163                | 1,0000       | 0,7113      | 0,9384      | 0,7587    | 1                   | 1                    |
| 180                | 1,0000       | 0,1101      | 0,7621      | 0,4991    | 1                   | 1                    |
| 186                | 1,0000       | 0,3014      | 0,6630      | 0,2978    | 1                   | 0                    |
| 209                | 0,0144       | 0,0034      | 0,6439      | 0,2281    | 1                   | 0                    |
| 211                | 1,0000       | 0,5882      | 0,8601      | 0,5547    | 1                   | 1                    |
| 220                | 0,0013       | 0,0001      | 0,6044      | 0,2055    | 1                   | 0                    |
| 231                | 0,0787       | 0,0245      | 0,5231      | 0,2883    | 1                   | 0                    |
| 235                | 0,9993       | 0,1082      | 0,7048      | 0,3373    | 1                   | 0                    |
| 307                | 1,0000       | 0,2484      | 0,8089      | 0,5604    | 1                   | 1                    |
| 309                | 0,0012       | 0,0002      | 0,3582      | 0,0599    | 0                   | 0                    |
| 313                | 1,0000       | 0,8972      | 0,6552      | 0,4893    | 1                   | 0                    |
| 321                | 1,0000       | 0,2496      | 0,6757      | 0,4526    | 1                   | 0                    |
| 339                | 0,5627       | 0,0317      | 0,5200      | 0,1609    | 1                   | 0                    |
| 343                | 0,0036       | 0,0005      | 0,6170      | 0,2148    | 1                   | 0                    |
| 344                | 1,0000       | 0,4785      | 0,9342      | 0,6009    | 1                   | 1                    |
| 351                | 0,0038       | 0,0004      | 0,2891      | 0,1504    | 0                   | 0                    |
| 361                | 0,2950       | 0,0055      | 0,7442      | 0,2833    | 1                   | 0                    |
| 369                | 0,1080       | 0,0159      | 0,6000      | 0,1504    | 1                   | 0                    |
| 376                | 0,9999       | 0,2776      | 0,4160      | 0,2920    | 0                   | 0                    |
| 392                | 1,0000       | 0,0403      | 0,9041      | 0,3613    | 1                   | 1                    |
| 393                | 0,0495       | 0,0054      | 0,8000      | 0,2751    | 1                   | 1                    |
| 399                | 0,9999       | 0,5858      | 0,6978      | 0,2673    | 1                   | 0                    |
| 404                | 0,3738       | 0,0161      | 0,7246      | 0,1701    | 1                   | 0                    |
| 406                | 0,0775       | 0,0027      | 0,6936      | 0,2128    | 1                   | 0                    |
| 421                | 0,9999       | 0,0504      | 0,8566      | 0,2472    | 1                   | 1                    |
| 428                | 0,0620       | 0,0063      | 0,7476      | 0,4391    | 1                   | 0                    |
| 429                | 0,9998       | 0,4247      | 0,7681      | 0,5157    | 1                   | 1                    |
| 430                | 1,0000       | 0,6013      | 0,7004      | 0,5084    | 1                   | 0                    |
| 434                | 0,9999       | 0,0611      | 0,3483      | 0,1289    | 0                   | 0                    |
| 437                | 1,0000       | 0,1794      | 0,8400      | 0,5204    | 1                   | 1                    |
| 441                | 0,9933       | 0,0100      | 0,9450      | 0,2580    | 1                   | 1                    |
| 442                | 1,0000       | 0,4329      | 0,8071      | 0,4876    | 1                   | 1                    |
| 453                | 1,0000       | 0,3491      | 0,8789      | 0,4409    | 1                   | 1                    |
| 466                | 1,0000       | 0,4674      | 0,9226      | 0,3687    | 1                   | 1                    |
| 470                | 0,4253       | 0,0076      | 0,9147      | 0,3621    | 1                   | 1                    |
| 493                | 0,0039       | 0,0009      | 0,4444      | 0,0859    | 0                   | 0                    |
| 495                | 0,0149       | 0,0026      | 0,5893      | 0,3436    | 1                   | 0                    |
| 528                | 0,0516       | 0,0084      | 0,5443      | 0,2757    | 1                   | 0                    |
| 535                | 1,0000       | 0,0525      | 0,9199      | 0,4220    | 1                   | 1                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 539 | 1,0000 | 0,0407 | 0,6027 | 0,3168 | 1 | 0 |
| 574 | 0,9981 | 0,1337 | 0,7636 | 0,3299 | 1 | 1 |
| 594 | 1,0000 | 0,0834 | 0,7653 | 0,4590 | 1 | 1 |
| 597 | 1,0000 | 0,7319 | 0,8607 | 0,6563 | 1 | 1 |
| 599 | 0,9996 | 0,2242 | 0,8420 | 0,4524 | 1 | 1 |
| 600 | 1,0000 | 0,3401 | 0,9180 | 0,5684 | 1 | 1 |
| 624 | 0,0974 | 0,0075 | 0,3250 | 0,1564 | 0 | 0 |
| 657 | 0,9666 | 0,1170 | 0,8519 | 0,4332 | 1 | 1 |
| 659 | 0,9999 | 0,1234 | 0,8226 | 0,3204 | 1 | 1 |
| 668 | 0,4483 | 0,0244 | 0,8736 | 0,3707 | 1 | 1 |
| 675 | 1,0000 | 0,5819 | 0,9628 | 0,6739 | 1 | 1 |
| 676 | 0,9997 | 0,2310 | 0,8696 | 0,4955 | 1 | 1 |
| 699 | 1,0000 | 0,0484 | 0,7001 | 0,2393 | 1 | 0 |
| 700 | 0,9529 | 0,0928 | 0,8308 | 0,4799 | 1 | 1 |
| 730 | 0,0956 | 0,0034 | 0,5732 | 0,1955 | 1 | 0 |
| 731 | 0,6016 | 0,0373 | 0,6000 | 0,2521 | 1 | 0 |
| 751 | 1,0000 | 0,1181 | 0,9270 | 0,4280 | 1 | 1 |
| 762 | 1,0000 | 0,0968 | 0,6541 | 0,4532 | 1 | 0 |
| 777 | 0,0489 | 0,0096 | 0,4894 | 0,2041 | 0 | 0 |
| 785 | 0,9999 | 0,3962 | 0,3737 | 0,1228 | 0 | 0 |
| 787 | 0,0006 | 0,0001 | 0,0000 | 0,0000 | 0 | 0 |
| 815 | 0,0676 | 0,0025 | 0,5122 | 0,2331 | 1 | 0 |
| 816 | 0,6735 | 0,0950 | 0,7576 | 0,4284 | 1 | 1 |
| 820 | 1,0000 | 0,1331 | 0,6919 | 0,2509 | 1 | 0 |
| 821 | 0,6335 | 0,0610 | 0,2100 | 0,0803 | 0 | 0 |
| 822 | 1,0000 | 0,0628 | 0,7209 | 0,2088 | 1 | 0 |
| 840 | 1,0000 | 0,1302 | 0,7163 | 0,3506 | 1 | 0 |
| 858 | 0,9559 | 0,0538 | 0,4965 | 0,1945 | 0 | 0 |
| 861 | 0,4888 | 0,0051 | 0,5737 | 0,1175 | 1 | 0 |
| 864 | 0,0279 | 0,0074 | 0,7209 | 0,3369 | 1 | 0 |
| 882 | 0,9999 | 0,3320 | 0,8028 | 0,4698 | 1 | 1 |
| 883 | 1,0000 | 0,8837 | 0,8972 | 0,7541 | 1 | 1 |
| 895 | 0,1246 | 0,0080 | 0,6598 | 0,1759 | 1 | 0 |
| 897 | 0,6650 | 0,0364 | 0,2292 | 0,0959 | 0 | 0 |
| 901 | 0,9998 | 0,2322 | 0,7590 | 0,4680 | 1 | 1 |
| 914 | 1,0000 | 0,8049 | 0,9071 | 0,7250 | 1 | 1 |

Tabela 19 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced, referente a fold 6.

| Fold 6             | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média              | 0,24549155   |             | 0,356868215 |           | 0,880434783         | 0,5                  |
| Média onde IoU > 0 | 0,270914708  |             | 0,399023126 |           | 0,89010989          | 0,505494505          |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 008                | 0,0559       | 0,0042      | 0,7264      | 0,2463    | 1                   | 0                    |
| 031                | 0,0307       | 0,0014      | 0,7485      | 0,1676    | 1                   | 0                    |
| 033                | 1,0000       | 0,4031      | 0,5939      | 0,3141    | 1                   | 0                    |
| 034                | 0,9797       | 0,1214      | 0,7434      | 0,1522    | 1                   | 0                    |
| 037                | 0,0018       | 0,0009      | 0,5172      | 0,1115    | 1                   | 0                    |
| 044                | 0,0344       | 0,0036      | 0,9487      | 0,3145    | 1                   | 1                    |
| 049                | 1,0000       | 0,6037      | 0,4441      | 0,1477    | 0                   | 0                    |
| 060                | 1,0000       | 0,6863      | 0,9608      | 0,7596    | 1                   | 1                    |
| 073                | 0,2700       | 0,0137      | 0,8000      | 0,3259    | 1                   | 1                    |
| 075                | 0,0011       | 0,0001      | 0,6829      | 0,1556    | 1                   | 0                    |
| 079                | 1,0000       | 0,2494      | 0,8898      | 0,4191    | 1                   | 1                    |
| 083                | 1,0000       | 0,1141      | 0,7613      | 0,2065    | 1                   | 1                    |
| 086                | 0,9995       | 0,1517      | 0,8381      | 0,1658    | 1                   | 1                    |
| 095                | 0,0002       | 0,0000      | 0,8238      | 0,3140    | 1                   | 1                    |
| 106                | 0,9560       | 0,1080      | 0,8519      | 0,4106    | 1                   | 1                    |
| 109                | 0,9808       | 0,2076      | 0,5442      | 0,2973    | 1                   | 0                    |
| 125                | 0,9887       | 0,0528      | 0,6875      | 0,1819    | 1                   | 0                    |
| 127                | 0,1116       | 0,0175      | 0,7682      | 0,4436    | 1                   | 1                    |
| 128                | 1,0000       | 0,1821      | 0,9643      | 0,4333    | 1                   | 1                    |
| 139                | 1,0000       | 0,7310      | 0,9328      | 0,7574    | 1                   | 1                    |
| 149                | 0,2788       | 0,0097      | 0,4709      | 0,2113    | 0                   | 0                    |
| 177                | 0,7170       | 0,0961      | 0,5393      | 0,2609    | 1                   | 0                    |
| 183                | 0,9999       | 0,2436      | 0,8601      | 0,4630    | 1                   | 1                    |
| 185                | 0,9997       | 0,2291      | 0,5394      | 0,1315    | 1                   | 0                    |
| 203                | 0,2237       | 0,0107      | 0,4116      | 0,1529    | 0                   | 0                    |
| 208                | 1,0000       | 0,9393      | 0,8214      | 0,6403    | 1                   | 1                    |
| 237                | 1,0000       | 0,4379      | 0,8925      | 0,6580    | 1                   | 1                    |
| 238                | 0,9865       | 0,2576      | 0,7808      | 0,4249    | 1                   | 1                    |
| 247                | 0,2903       | 0,0080      | 0,7031      | 0,2664    | 1                   | 0                    |
| 262                | 0,8584       | 0,0543      | 0,8294      | 0,5418    | 1                   | 1                    |
| 268                | 1,0000       | 0,7814      | 0,9737      | 0,7554    | 1                   | 1                    |
| 281                | 0,9989       | 0,1466      | 0,9443      | 0,6525    | 1                   | 1                    |
| 284                | 0,6421       | 0,0350      | 0,9429      | 0,4527    | 1                   | 1                    |
| 287                | 0,6617       | 0,0248      | 0,8458      | 0,2060    | 1                   | 1                    |
| 289                | 0,0009       | 0,0001      | 0,8707      | 0,2750    | 1                   | 1                    |
| 310                | 0,0008       | 0,0000      | 0,6901      | 0,0337    | 1                   | 0                    |
| 322                | 1,0000       | 0,7724      | 0,7531      | 0,5425    | 1                   | 1                    |
| 378                | 1,0000       | 0,5005      | 0,8730      | 0,5630    | 1                   | 1                    |
| 381                | 0,0992       | 0,0047      | 0,6000      | 0,2800    | 1                   | 0                    |
| 390                | 0,8411       | 0,0597      | 0,9195      | 0,3364    | 1                   | 1                    |
| 394                | 0,0024       | 0,0009      | 0,4592      | 0,0732    | 0                   | 0                    |
| 411                | 0,8203       | 0,0977      | 0,7920      | 0,3153    | 1                   | 1                    |
| 431                | 0,0010       | 0,0001      | 0,7880      | 0,2262    | 1                   | 1                    |
| 450                | 0,6970       | 0,1197      | 0,5824      | 0,1826    | 1                   | 0                    |
| 456                | 0,9992       | 0,6336      | 0,4895      | 0,3115    | 0                   | 0                    |
| 459                | 0,9998       | 0,2812      | 0,5979      | 0,1895    | 1                   | 0                    |
| 472                | 0,0489       | 0,0024      | 0,6402      | 0,2234    | 1                   | 0                    |
| 475                | 1,0000       | 0,2217      | 0,5614      | 0,2888    | 1                   | 0                    |
| 487                | 0,9110       | 0,3244      | 0,9545      | 0,6379    | 1                   | 1                    |
| 508                | 1,0000       | 0,3871      | 0,8613      | 0,4320    | 1                   | 1                    |
| 527                | 0,1519       | 0,0024      | 0,7474      | 0,2258    | 1                   | 0                    |
| 529                | 1,0000       | 0,4872      | 0,5874      | 0,4558    | 1                   | 0                    |
| 531                | 0,9999       | 0,4162      | 0,6541      | 0,3855    | 1                   | 0                    |
| 546                | 1,0000       | 0,6059      | 0,8880      | 0,5841    | 1                   | 1                    |
| 555                | 0,0380       | 0,0059      | 0,6234      | 0,1797    | 1                   | 0                    |
| 558                | 0,9047       | 0,0907      | 0,7815      | 0,3687    | 1                   | 1                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 570 | 0,0002 | 0,0001 | 0,2573 | 0,1413 | 0 | 0 |
| 585 | 1,0000 | 0,6105 | 0,9070 | 0,5540 | 1 | 1 |
| 607 | 1,0000 | 0,9868 | 0,9730 | 0,8340 | 1 | 1 |
| 614 | 1,0000 | 0,5912 | 0,8800 | 0,6096 | 1 | 1 |
| 626 | 0,9999 | 0,1144 | 0,6538 | 0,3852 | 1 | 0 |
| 638 | 0,8873 | 0,0596 | 0,3353 | 0,1856 | 0 | 0 |
| 650 | 1,0000 | 0,7768 | 0,6356 | 0,4508 | 1 | 0 |
| 670 | 1,0000 | 0,3613 | 0,6530 | 0,3268 | 1 | 0 |
| 685 | 1,0000 | 0,3420 | 0,9477 | 0,5226 | 1 | 1 |
| 686 | 0,9961 | 0,0877 | 0,6914 | 0,2325 | 1 | 0 |
| 691 | 1,0000 | 0,1681 | 0,6282 | 0,1680 | 1 | 0 |
| 698 | 0,0003 | 0,0001 | 0,0000 | 0,0000 | 0 | 0 |
| 710 | 1,0000 | 0,1187 | 0,8116 | 0,3968 | 1 | 1 |
| 722 | 0,0571 | 0,0065 | 0,7220 | 0,3560 | 1 | 0 |
| 724 | 1,0000 | 0,9604 | 0,9565 | 0,7597 | 1 | 1 |
| 727 | 0,0953 | 0,0063 | 0,8381 | 0,2255 | 1 | 1 |
| 744 | 0,6443 | 0,0377 | 0,7138 | 0,2089 | 1 | 0 |
| 749 | 1,0000 | 0,4548 | 0,7295 | 0,5321 | 1 | 0 |
| 754 | 0,4070 | 0,0647 | 0,6060 | 0,3391 | 1 | 0 |
| 759 | 0,0071 | 0,0009 | 0,5729 | 0,4333 | 1 | 0 |
| 764 | 0,9063 | 0,2220 | 0,7181 | 0,4217 | 1 | 0 |
| 794 | 0,9946 | 0,2629 | 0,4857 | 0,0229 | 0 | 0 |
| 824 | 1,0000 | 0,6642 | 0,8704 | 0,6585 | 1 | 1 |
| 825 | 0,5371 | 0,0888 | 0,7850 | 0,2823 | 1 | 1 |
| 830 | 1,0000 | 0,5533 | 0,9756 | 0,6814 | 1 | 1 |
| 837 | 0,0112 | 0,0015 | 0,7647 | 0,3746 | 1 | 1 |
| 847 | 0,9773 | 0,1534 | 0,7649 | 0,5242 | 1 | 1 |
| 853 | 0,9963 | 0,5983 | 0,8408 | 0,5816 | 1 | 1 |
| 865 | 0,9999 | 0,1054 | 0,8286 | 0,2605 | 1 | 1 |
| 871 | 0,6930 | 0,1028 | 0,8058 | 0,5160 | 1 | 1 |
| 875 | 0,9971 | 0,4938 | 0,8644 | 0,5614 | 1 | 1 |
| 890 | 0,1052 | 0,0067 | 0,4678 | 0,2420 | 0 | 0 |
| 892 | 0,5849 | 0,0155 | 0,2690 | 0,0254 | 0 | 0 |
| 900 | 0,9556 | 0,2348 | 0,7107 | 0,4057 | 1 | 0 |
| 912 | 0,8749 | 0,0811 | 0,7018 | 0,3656 | 1 | 0 |
| 922 | 0,0226 | 0,0028 | 0,6908 | 0,4343 | 1 | 0 |

Tabela 20 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced, referente a fold 7.

| Fold 7             | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média              | 0,167566395  |             | 0,324648332 |           | 0,782608696         | 0,402173913          |
| Média onde IoU > 0 | 0,193205655  |             | 0,378000448 |           | 0,8                 | 0,411111111          |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 002                | 0,0034       | 0,0007      | 0,4691      | 0,1684    | 0                   | 0                    |
| 041                | 1,0000       | 0,2416      | 0,8109      | 0,4864    | 1                   | 1                    |
| 047                | 0,9985       | 0,1229      | 0,8381      | 0,2912    | 1                   | 1                    |
| 063                | 1,0000       | 0,1938      | 0,8406      | 0,4362    | 1                   | 1                    |
| 068                | 1,0000       | 0,2341      | 0,7877      | 0,1422    | 1                   | 1                    |
| 070                | 0,8858       | 0,0635      | 0,5172      | 0,0192    | 1                   | 0                    |
| 072                | 0,9956       | 0,0901      | 0,8929      | 0,4958    | 1                   | 1                    |
| 076                | 1,0000       | 0,6661      | 0,9474      | 0,6141    | 1                   | 1                    |
| 090                | 0,9915       | 0,0206      | 0,8577      | 0,4067    | 1                   | 1                    |
| 114                | 1,0000       | 0,4950      | 0,4588      | 0,2469    | 0                   | 0                    |
| 116                | 1,0000       | 0,4814      | 0,6151      | 0,4907    | 1                   | 0                    |
| 138                | 1,0000       | 0,2288      | 0,0549      | 0,0280    | 0                   | 0                    |
| 170                | 1,0000       | 0,4018      | 0,9347      | 0,4945    | 1                   | 1                    |
| 175                | 0,9995       | 0,1261      | 0,6922      | 0,3361    | 1                   | 0                    |
| 176                | 0,9997       | 0,2152      | 0,6066      | 0,2865    | 1                   | 0                    |
| 182                | 0,0015       | 0,0001      | 0,3571      | 0,0373    | 0                   | 0                    |
| 187                | 0,0309       | 0,0011      | 0,5092      | 0,0361    | 1                   | 0                    |
| 190                | 0,9744       | 0,0593      | 0,7564      | 0,5012    | 1                   | 1                    |
| 197                | 1,0000       | 0,3421      | 0,6855      | 0,2595    | 1                   | 0                    |
| 202                | 0,0194       | 0,0009      | 0,7044      | 0,1503    | 1                   | 0                    |
| 218                | 1,0000       | 0,6935      | 0,7500      | 0,5304    | 1                   | 1                    |
| 228                | 1,0000       | 0,5884      | 0,8763      | 0,6321    | 1                   | 1                    |
| 233                | 0,0032       | 0,0006      | 0,6452      | 0,3603    | 1                   | 0                    |
| 234                | 0,0041       | 0,0003      | 0,6639      | 0,2308    | 1                   | 0                    |
| 252                | 0,7950       | 0,0048      | 0,5533      | 0,0691    | 1                   | 0                    |
| 260                | 0,0306       | 0,0016      | 0,6543      | 0,2082    | 1                   | 0                    |
| 271                | 0,9998       | 0,1790      | 0,8750      | 0,4412    | 1                   | 1                    |
| 278                | 0,0002       | 0,0001      | 0,5281      | 0,2149    | 1                   | 0                    |
| 282                | 0,0031       | 0,0010      | 0,5174      | 0,3271    | 1                   | 0                    |
| 288                | 0,0652       | 0,0054      | 0,8225      | 0,3876    | 1                   | 1                    |
| 308                | 0,9986       | 0,3944      | 0,6903      | 0,4447    | 1                   | 0                    |
| 336                | 0,0007       | 0,0002      | 0,2059      | 0,0481    | 0                   | 0                    |
| 342                | 0,0009       | 0,0001      | 0,5169      | 0,1911    | 1                   | 0                    |
| 347                | 1,0000       | 0,1060      | 0,8125      | 0,2645    | 1                   | 1                    |
| 359                | 1,0000       | 0,2200      | 0,7469      | 0,1918    | 1                   | 0                    |
| 370                | 0,0230       | 0,0020      | 0,4791      | 0,1759    | 0                   | 0                    |
| 377                | 1,0000       | 0,5526      | 0,6179      | 0,3399    | 1                   | 0                    |
| 397                | 0,9879       | 0,0799      | 0,5902      | 0,2048    | 1                   | 0                    |
| 401                | 1,0000       | 0,5546      | 0,8805      | 0,5889    | 1                   | 1                    |
| 408                | 0,0095       | 0,0010      | 0,2342      | 0,0376    | 0                   | 0                    |
| 413                | 0,9999       | 0,1278      | 0,7083      | 0,3120    | 1                   | 0                    |
| 432                | 0,9957       | 0,3460      | 0,8519      | 0,5958    | 1                   | 1                    |
| 439                | 0,0623       | 0,0042      | 0,7271      | 0,0838    | 1                   | 0                    |
| 449                | 1,0000       | 0,2647      | 0,6643      | 0,4943    | 1                   | 0                    |
| 454                | 1,0000       | 0,7675      | 0,8675      | 0,6509    | 1                   | 1                    |
| 467                | 0,9585       | 0,0349      | 0,9123      | 0,3597    | 1                   | 1                    |
| 496                | 0,1810       | 0,0182      | 0,3557      | 0,1783    | 0                   | 0                    |
| 497                | 0,0074       | 0,0005      | 0,6880      | 0,2260    | 1                   | 0                    |
| 502                | 0,1055       | 0,0058      | 0,6910      | 0,3867    | 1                   | 0                    |
| 504                | 1,0000       | 0,4271      | 0,7774      | 0,4029    | 1                   | 1                    |
| 522                | 0,0028       | 0,0002      | 0,4558      | 0,1431    | 0                   | 0                    |
| 530                | 0,9997       | 0,0378      | 0,7945      | 0,2042    | 1                   | 1                    |
| 536                | 1,0000       | 0,2869      | 0,8331      | 0,5526    | 1                   | 1                    |
| 542                | 0,1086       | 0,0030      | 0,4974      | 0,1591    | 0                   | 0                    |
| 545                | 0,0010       | 0,0001      | 0,0312      | 0,0083    | 0                   | 0                    |
| 552                | 0,2341       | 0,0111      | 0,6057      | 0,3448    | 1                   | 0                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 559 | 1,0000 | 0,8121 | 0,7612 | 0,5598 | 1 | 1 |
| 562 | 1,0000 | 0,1573 | 0,7453 | 0,2153 | 1 | 0 |
| 563 | 1,0000 | 0,0115 | 0,8325 | 0,4683 | 1 | 1 |
| 565 | 0,0022 | 0,0004 | 0,8182 | 0,1364 | 1 | 1 |
| 571 | 0,9994 | 0,2099 | 0,8707 | 0,4751 | 1 | 1 |
| 577 | 0,9976 | 0,0432 | 0,7844 | 0,3596 | 1 | 1 |
| 583 | 1,0000 | 0,0636 | 0,9397 | 0,3085 | 1 | 1 |
| 586 | 1,0000 | 0,1204 | 0,8630 | 0,5076 | 1 | 1 |
| 605 | 0,9999 | 0,3284 | 0,8680 | 0,5807 | 1 | 1 |
| 620 | 1,0000 | 0,4620 | 0,8403 | 0,6064 | 1 | 1 |
| 623 | 0,0016 | 0,0003 | 0,0407 | 0,0176 | 0 | 0 |
| 625 | 1,0000 | 0,2598 | 0,8090 | 0,4824 | 1 | 1 |
| 627 | 0,0031 | 0,0003 | 0,5789 | 0,1381 | 1 | 0 |
| 629 | 0,8649 | 0,0948 | 0,5109 | 0,1659 | 1 | 0 |
| 632 | 0,0041 | 0,0001 | 0,7915 | 0,1956 | 1 | 1 |
| 644 | 0,0139 | 0,0038 | 0,3087 | 0,1777 | 0 | 0 |
| 655 | 0,1998 | 0,0168 | 0,5904 | 0,2205 | 1 | 0 |
| 682 | 0,0558 | 0,0027 | 0,8494 | 0,2707 | 1 | 1 |
| 690 | 0,9999 | 0,2203 | 0,4366 | 0,2335 | 0 | 0 |
| 705 | 1,0000 | 0,8728 | 0,7122 | 0,4212 | 1 | 0 |
| 726 | 0,9977 | 0,0418 | 0,7393 | 0,3510 | 1 | 0 |
| 767 | 0,0012 | 0,0001 | 0,7784 | 0,2712 | 1 | 1 |
| 772 | 0,6336 | 0,0247 | 0,7793 | 0,3606 | 1 | 1 |
| 781 | 0,0002 | 0,0000 | 0,0000 | 0,0000 | 0 | 0 |
| 801 | 1,0000 | 0,2410 | 0,8915 | 0,4785 | 1 | 1 |
| 802 | 0,0133 | 0,0018 | 0,6904 | 0,3281 | 1 | 0 |
| 803 | 0,0011 | 0,0002 | 0,3504 | 0,0109 | 0 | 0 |
| 806 | 0,0060 | 0,0005 | 0,5522 | 0,1604 | 1 | 0 |
| 856 | 0,0090 | 0,0006 | 0,4000 | 0,0259 | 0 | 0 |
| 867 | 0,4434 | 0,0111 | 0,6410 | 0,1893 | 1 | 0 |
| 878 | 0,0005 | 0,0000 | 0,2037 | 0,0296 | 0 | 0 |
| 888 | 0,9857 | 0,0319 | 0,3539 | 0,1977 | 0 | 0 |
| 893 | 0,0001 | 0,0000 | 0,0000 | 0,0000 | 0 | 0 |
| 898 | 0,0014 | 0,0003 | 0,5123 | 0,2379 | 1 | 0 |
| 910 | 0,0014 | 0,0002 | 0,7007 | 0,0704 | 1 | 0 |
| 919 | 0,8185 | 0,0454 | 0,8025 | 0,4423 | 1 | 1 |

Tabela 21 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced, referente a fold 8.

| Fold 8             | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média              | 0,164316369  |             | 0,331236311 |           | 0,880434783         | 0,456521739          |
| Média onde IoU > 0 | 0,188113469  |             | 0,380610322 |           | 0,880434783         | 0,456521739          |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 005                | 1,0000       | 0,5596      | 0,8571      | 0,6709    | 1                   | 1                    |
| 010                | 1,0000       | 0,7234      | 0,8846      | 0,7024    | 1                   | 1                    |
| 012                | 0,0832       | 0,0025      | 0,8874      | 0,4325    | 1                   | 1                    |
| 015                | 1,0000       | 0,9477      | 0,7193      | 0,5959    | 1                   | 0                    |
| 019                | 1,0000       | 0,5464      | 0,7727      | 0,4722    | 1                   | 1                    |
| 029                | 0,0800       | 0,0189      | 0,5357      | 0,2672    | 1                   | 0                    |
| 056                | 0,0116       | 0,0003      | 0,6083      | 0,1437    | 1                   | 0                    |
| 058                | 1,0000       | 0,4357      | 0,8520      | 0,5361    | 1                   | 1                    |
| 061                | 0,9999       | 0,1141      | 0,8221      | 0,4406    | 1                   | 1                    |
| 064                | 0,9998       | 0,3240      | 0,6180      | 0,3135    | 1                   | 0                    |
| 077                | 1,0000       | 0,3648      | 0,8330      | 0,5401    | 1                   | 1                    |
| 080                | 0,9995       | 0,2396      | 0,8873      | 0,5139    | 1                   | 1                    |
| 108                | 1,0000       | 0,1521      | 0,7296      | 0,3167    | 1                   | 0                    |
| 111                | 0,0755       | 0,0059      | 0,3492      | 0,0644    | 0                   | 0                    |
| 131                | 0,0017       | 0,0001      | 0,5729      | 0,0783    | 1                   | 0                    |
| 133                | 0,2074       | 0,0132      | 0,8532      | 0,2836    | 1                   | 1                    |
| 144                | 0,0359       | 0,0016      | 0,5807      | 0,1703    | 1                   | 0                    |
| 147                | 0,9383       | 0,1177      | 0,8394      | 0,5140    | 1                   | 1                    |
| 150                | 0,0596       | 0,0029      | 0,5780      | 0,1040    | 1                   | 0                    |
| 167                | 0,0358       | 0,0058      | 0,6320      | 0,1024    | 1                   | 0                    |
| 174                | 0,0001       | 0,0000      | 0,9026      | 0,1697    | 1                   | 1                    |
| 188                | 0,0359       | 0,0064      | 0,5319      | 0,3131    | 1                   | 0                    |
| 193                | 0,0123       | 0,0009      | 0,3939      | 0,1116    | 0                   | 0                    |
| 212                | 1,0000       | 0,1970      | 0,6961      | 0,3744    | 1                   | 0                    |
| 236                | 0,0301       | 0,0013      | 0,7509      | 0,1970    | 1                   | 1                    |
| 243                | 0,0049       | 0,0004      | 0,4615      | 0,0259    | 0                   | 0                    |
| 261                | 0,8763       | 0,0095      | 0,8161      | 0,2152    | 1                   | 1                    |
| 264                | 0,0097       | 0,0007      | 0,5606      | 0,0171    | 1                   | 0                    |
| 269                | 0,9991       | 0,0285      | 0,8047      | 0,2503    | 1                   | 1                    |
| 280                | 1,0000       | 0,7115      | 0,7955      | 0,4772    | 1                   | 1                    |
| 293                | 0,9998       | 0,0641      | 0,8257      | 0,5548    | 1                   | 1                    |
| 299                | 0,9759       | 0,1493      | 0,7533      | 0,3891    | 1                   | 1                    |
| 301                | 0,9973       | 0,2593      | 0,7241      | 0,2082    | 1                   | 0                    |
| 314                | 0,9978       | 0,0297      | 0,8237      | 0,3533    | 1                   | 1                    |
| 335                | 0,0239       | 0,0038      | 0,7594      | 0,2099    | 1                   | 1                    |
| 341                | 0,2353       | 0,0121      | 0,5867      | 0,2381    | 1                   | 0                    |
| 348                | 0,0023       | 0,0003      | 0,7865      | 0,1816    | 1                   | 1                    |
| 371                | 0,0089       | 0,0008      | 0,5333      | 0,1594    | 1                   | 0                    |
| 372                | 0,0039       | 0,0011      | 0,5107      | 0,2810    | 1                   | 0                    |
| 373                | 1,0000       | 0,6486      | 0,7415      | 0,4242    | 1                   | 0                    |
| 380                | 0,8863       | 0,0594      | 0,8575      | 0,5073    | 1                   | 1                    |
| 396                | 0,0104       | 0,0024      | 0,0737      | 0,0533    | 0                   | 0                    |
| 405                | 0,0506       | 0,0056      | 0,5669      | 0,2874    | 1                   | 0                    |
| 409                | 0,9999       | 0,0850      | 0,8141      | 0,3880    | 1                   | 1                    |
| 443                | 1,0000       | 0,4848      | 0,8372      | 0,5711    | 1                   | 1                    |
| 460                | 1,0000       | 0,4332      | 0,8456      | 0,4369    | 1                   | 1                    |
| 461                | 1,0000       | 0,5062      | 0,8473      | 0,5290    | 1                   | 1                    |
| 462                | 0,9994       | 0,1411      | 0,7293      | 0,3005    | 1                   | 0                    |
| 463                | 0,1556       | 0,0252      | 0,4539      | 0,2429    | 0                   | 0                    |
| 481                | 0,0133       | 0,0006      | 0,5002      | 0,0739    | 1                   | 0                    |
| 492                | 0,9927       | 0,0403      | 0,7811      | 0,3541    | 1                   | 1                    |
| 494                | 0,9998       | 0,2829      | 0,6656      | 0,2918    | 1                   | 0                    |
| 510                | 0,9999       | 0,2352      | 0,8929      | 0,6038    | 1                   | 1                    |
| 511                | 0,0012       | 0,0003      | 0,6047      | 0,1287    | 1                   | 0                    |
| 516                | 0,7090       | 0,0080      | 0,7775      | 0,2913    | 1                   | 1                    |
| 549                | 0,0166       | 0,0043      | 0,3818      | 0,2336    | 0                   | 0                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 573 | 0,0056 | 0,0004 | 0,6154 | 0,0611 | 1 | 0 |
| 578 | 0,9321 | 0,2522 | 0,6809 | 0,3347 | 1 | 0 |
| 579 | 0,9999 | 0,2518 | 0,5069 | 0,2590 | 1 | 0 |
| 584 | 0,9994 | 0,1061 | 0,7256 | 0,3216 | 1 | 0 |
| 602 | 0,9134 | 0,1166 | 0,6102 | 0,2368 | 1 | 0 |
| 611 | 0,5726 | 0,0155 | 0,4745 | 0,2119 | 0 | 0 |
| 617 | 0,0536 | 0,0022 | 0,5510 | 0,2487 | 1 | 0 |
| 621 | 0,5290 | 0,0122 | 0,6232 | 0,2291 | 1 | 0 |
| 630 | 1,0000 | 0,3374 | 0,8261 | 0,4381 | 1 | 1 |
| 645 | 1,0000 | 0,1606 | 0,8451 | 0,5387 | 1 | 1 |
| 648 | 0,2712 | 0,0076 | 0,5175 | 0,1388 | 1 | 0 |
| 649 | 0,9069 | 0,0824 | 0,6338 | 0,4183 | 1 | 0 |
| 658 | 0,7259 | 0,0184 | 0,8000 | 0,4066 | 1 | 1 |
| 660 | 1,0000 | 0,3201 | 0,9297 | 0,4910 | 1 | 1 |
| 666 | 1,0000 | 0,4394 | 0,9137 | 0,6230 | 1 | 1 |
| 669 | 0,0004 | 0,0001 | 0,0673 | 0,0275 | 0 | 0 |
| 679 | 0,0846 | 0,0066 | 0,7940 | 0,2048 | 1 | 1 |
| 703 | 0,0521 | 0,0011 | 0,8651 | 0,2092 | 1 | 1 |
| 725 | 0,9977 | 0,1192 | 0,6657 | 0,2434 | 1 | 0 |
| 732 | 0,9973 | 0,1607 | 0,7277 | 0,4169 | 1 | 0 |
| 735 | 1,0000 | 0,2347 | 0,5594 | 0,3142 | 1 | 0 |
| 740 | 0,0022 | 0,0008 | 0,2321 | 0,0861 | 0 | 0 |
| 750 | 0,9999 | 0,0637 | 0,6941 | 0,2708 | 1 | 0 |
| 752 | 0,9988 | 0,1812 | 0,7627 | 0,4832 | 1 | 1 |
| 753 | 1,0000 | 0,4710 | 0,9231 | 0,4925 | 1 | 1 |
| 771 | 0,0079 | 0,0008 | 0,3810 | 0,0875 | 0 | 0 |
| 783 | 0,0093 | 0,0018 | 0,6574 | 0,4696 | 1 | 0 |
| 792 | 0,7438 | 0,0182 | 0,7904 | 0,2225 | 1 | 1 |
| 796 | 1,0000 | 0,9298 | 0,9353 | 0,7926 | 1 | 1 |
| 799 | 0,9997 | 0,1751 | 0,8438 | 0,4691 | 1 | 1 |
| 804 | 0,8223 | 0,0326 | 0,7235 | 0,3522 | 1 | 0 |
| 805 | 0,0148 | 0,0022 | 0,8265 | 0,2933 | 1 | 1 |
| 839 | 0,9788 | 0,0417 | 0,7038 | 0,2596 | 1 | 0 |
| 881 | 0,0073 | 0,0006 | 0,4987 | 0,1852 | 0 | 0 |
| 885 | 0,9884 | 0,1413 | 0,5140 | 0,2089 | 1 | 0 |
| 916 | 1,0000 | 0,9280 | 0,8492 | 0,6675 | 1 | 1 |

Tabela 22 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced, referente a fold 9.

| Fold 9             | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média              | 0,230125155  |             | 0,373163557 |           | 0,880434783         | 0,467391304          |
| Média onde IoU > 0 | 0,255308281  |             | 0,415514521 |           | 0,880434783         | 0,467391304          |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 007                | 1,0000       | 0,5548      | 0,5818      | 0,4104    | 1                   | 0                    |
| 014                | 0,9013       | 0,1043      | 0,5238      | 0,3268    | 1                   | 0                    |
| 023                | 1,0000       | 0,8915      | 0,8743      | 0,6670    | 1                   | 1                    |
| 026                | 0,9869       | 0,3379      | 0,8858      | 0,6997    | 1                   | 1                    |
| 036                | 0,9793       | 0,0951      | 0,8294      | 0,4154    | 1                   | 1                    |
| 051                | 0,0015       | 0,0001      | 0,2759      | 0,0946    | 0                   | 0                    |
| 052                | 1,0000       | 0,6526      | 0,5658      | 0,3945    | 1                   | 0                    |
| 055                | 0,5828       | 0,0250      | 0,7256      | 0,2593    | 1                   | 0                    |
| 066                | 0,9966       | 0,1909      | 0,7607      | 0,3411    | 1                   | 1                    |
| 094                | 1,0000       | 0,2406      | 0,6945      | 0,3275    | 1                   | 0                    |
| 105                | 1,0000       | 0,1221      | 0,8838      | 0,3421    | 1                   | 1                    |
| 132                | 0,9993       | 0,4135      | 0,8824      | 0,5995    | 1                   | 1                    |
| 146                | 0,9853       | 0,0728      | 0,6192      | 0,2945    | 1                   | 0                    |
| 156                | 0,0079       | 0,0001      | 0,4756      | 0,0614    | 0                   | 0                    |
| 194                | 0,0249       | 0,0007      | 0,5360      | 0,0297    | 1                   | 0                    |
| 217                | 1,0000       | 0,4027      | 0,9109      | 0,5660    | 1                   | 1                    |
| 227                | 1,0000       | 0,3349      | 0,7567      | 0,4095    | 1                   | 1                    |
| 245                | 0,9622       | 0,0562      | 0,8237      | 0,2048    | 1                   | 1                    |
| 250                | 0,9994       | 0,1201      | 0,6220      | 0,1427    | 1                   | 0                    |
| 255                | 0,9977       | 0,1372      | 0,8508      | 0,4641    | 1                   | 1                    |
| 259                | 0,6688       | 0,0188      | 0,4422      | 0,1101    | 0                   | 0                    |
| 265                | 0,9999       | 0,1343      | 0,9135      | 0,5551    | 1                   | 1                    |
| 276                | 0,4049       | 0,0080      | 0,7826      | 0,2369    | 1                   | 1                    |
| 277                | 0,0287       | 0,0045      | 0,4476      | 0,1460    | 0                   | 0                    |
| 286                | 0,0118       | 0,0006      | 0,6827      | 0,1919    | 1                   | 0                    |
| 291                | 0,5614       | 0,0207      | 0,8212      | 0,4416    | 1                   | 1                    |
| 296                | 0,0466       | 0,0052      | 0,6205      | 0,3044    | 1                   | 0                    |
| 298                | 1,0000       | 0,1083      | 0,7814      | 0,1489    | 1                   | 1                    |
| 315                | 0,9947       | 0,1720      | 0,6668      | 0,4367    | 1                   | 0                    |
| 317                | 1,0000       | 0,5642      | 0,8149      | 0,5391    | 1                   | 1                    |
| 320                | 1,0000       | 0,1562      | 0,6378      | 0,1554    | 1                   | 0                    |
| 327                | 0,0294       | 0,0023      | 0,7467      | 0,2522    | 1                   | 0                    |
| 331                | 0,9970       | 0,1773      | 0,7665      | 0,3295    | 1                   | 1                    |
| 334                | 1,0000       | 0,8022      | 0,7419      | 0,5494    | 1                   | 0                    |
| 350                | 1,0000       | 0,8609      | 0,7432      | 0,5371    | 1                   | 0                    |
| 353                | 0,9913       | 0,0877      | 0,6685      | 0,2442    | 1                   | 0                    |
| 385                | 0,6863       | 0,0054      | 0,7922      | 0,3922    | 1                   | 1                    |
| 387                | 1,0000       | 0,1826      | 0,7340      | 0,4954    | 1                   | 0                    |
| 391                | 0,9973       | 0,0743      | 0,6849      | 0,2461    | 1                   | 0                    |
| 418                | 1,0000       | 0,6103      | 0,6933      | 0,3975    | 1                   | 0                    |
| 419                | 0,9854       | 0,1216      | 0,6900      | 0,2424    | 1                   | 0                    |
| 433                | 0,9999       | 0,2241      | 0,8877      | 0,2934    | 1                   | 1                    |
| 436                | 1,0000       | 0,9101      | 0,7337      | 0,6073    | 1                   | 0                    |
| 458                | 0,0632       | 0,0023      | 0,6788      | 0,1585    | 1                   | 0                    |
| 465                | 1,0000       | 0,9822      | 0,0728      | 0,0627    | 0                   | 0                    |
| 479                | 0,9993       | 0,0358      | 0,6835      | 0,2761    | 1                   | 0                    |
| 484                | 0,9997       | 0,5765      | 0,6110      | 0,4958    | 1                   | 0                    |
| 489                | 1,0000       | 0,1264      | 0,7368      | 0,2551    | 1                   | 0                    |
| 498                | 0,9889       | 0,0721      | 0,7425      | 0,4250    | 1                   | 0                    |
| 505                | 0,0002       | 0,0000      | 0,2380      | 0,0400    | 0                   | 0                    |
| 512                | 1,0000       | 0,6789      | 0,7734      | 0,6347    | 1                   | 1                    |
| 514                | 0,9999       | 0,3142      | 0,8750      | 0,5420    | 1                   | 1                    |
| 518                | 1,0000       | 0,1895      | 0,6467      | 0,3504    | 1                   | 0                    |
| 543                | 1,0000       | 0,2195      | 0,7786      | 0,3865    | 1                   | 1                    |
| 548                | 0,0004       | 0,0001      | 0,3009      | 0,0338    | 0                   | 0                    |
| 551                | 0,9993       | 0,2893      | 0,8670      | 0,4858    | 1                   | 1                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 564 | 0,2044 | 0,0122 | 0,6176 | 0,3120 | 1 | 0 |
| 569 | 0,0198 | 0,0050 | 0,3314 | 0,1236 | 0 | 0 |
| 582 | 1,0000 | 0,3761 | 0,8127 | 0,4788 | 1 | 1 |
| 589 | 0,1807 | 0,0074 | 0,7717 | 0,4673 | 1 | 1 |
| 608 | 1,0000 | 0,1909 | 0,9073 | 0,3555 | 1 | 1 |
| 613 | 0,1771 | 0,0339 | 0,4297 | 0,2527 | 0 | 0 |
| 616 | 1,0000 | 0,2424 | 0,9494 | 0,5794 | 1 | 1 |
| 641 | 0,9989 | 0,3883 | 0,6549 | 0,4483 | 1 | 0 |
| 647 | 0,9988 | 0,2516 | 0,8510 | 0,3578 | 1 | 1 |
| 661 | 1,0000 | 0,3966 | 0,7273 | 0,5076 | 1 | 0 |
| 662 | 0,9989 | 0,2692 | 0,8459 | 0,4839 | 1 | 1 |
| 695 | 1,0000 | 0,2539 | 0,7672 | 0,4544 | 1 | 1 |
| 702 | 0,0058 | 0,0008 | 0,6868 | 0,2230 | 1 | 0 |
| 707 | 0,9998 | 0,6298 | 0,5600 | 0,3955 | 1 | 0 |
| 718 | 0,9965 | 0,0510 | 0,5809 | 0,0764 | 1 | 0 |
| 720 | 1,0000 | 0,5664 | 0,8684 | 0,4645 | 1 | 1 |
| 737 | 0,9999 | 0,3636 | 0,8037 | 0,3976 | 1 | 1 |
| 738 | 0,9953 | 0,1077 | 0,8130 | 0,3044 | 1 | 1 |
| 765 | 1,0000 | 0,5815 | 0,9370 | 0,7146 | 1 | 1 |
| 778 | 1,0000 | 0,4227 | 0,8639 | 0,5370 | 1 | 1 |
| 780 | 0,9998 | 0,4032 | 0,7113 | 0,4312 | 1 | 0 |
| 784 | 0,9938 | 0,1068 | 0,6797 | 0,3036 | 1 | 0 |
| 788 | 0,0003 | 0,0000 | 0,6667 | 0,1625 | 1 | 0 |
| 793 | 0,9999 | 0,2518 | 0,7605 | 0,5069 | 1 | 1 |
| 797 | 0,9999 | 0,2617 | 0,8625 | 0,4506 | 1 | 1 |
| 807 | 0,9887 | 0,0364 | 0,3778 | 0,1607 | 0 | 0 |
| 814 | 1,0000 | 0,1201 | 0,6340 | 0,2427 | 1 | 0 |
| 826 | 1,0000 | 0,3237 | 0,8644 | 0,3637 | 1 | 1 |
| 827 | 0,9990 | 0,2257 | 0,8136 | 0,3954 | 1 | 1 |
| 829 | 0,0030 | 0,0002 | 0,3702 | 0,0345 | 0 | 0 |
| 832 | 1,0000 | 0,6686 | 0,9091 | 0,7032 | 1 | 1 |
| 835 | 1,0000 | 0,4573 | 0,7714 | 0,4978 | 1 | 1 |
| 838 | 0,8987 | 0,0842 | 0,7664 | 0,3025 | 1 | 1 |
| 841 | 0,2554 | 0,0087 | 0,7867 | 0,2733 | 1 | 1 |
| 843 | 1,0000 | 0,4723 | 0,7296 | 0,5526 | 1 | 0 |
| 905 | 0,9999 | 0,0447 | 0,7507 | 0,2626 | 1 | 1 |

Tabela 23 - Médias e Máximos de Iou e Score de cada paciente de validação proveniente da detecção de imagens do dataset que fez uso do algoritmo ImageAnnotationEnhanced, referente a fold 10.

| Fold 10            | Score        |             | IoU         |           | Precisão IoU >= 0.5 | Precisão IoU >= 0.75 |
|--------------------|--------------|-------------|-------------|-----------|---------------------|----------------------|
| Média              | 0,227213299  |             | 0,350628322 |           | 0,765957447         | 0,340425532          |
| Média onde IoU > 0 | 0,255029584  |             | 0,405395394 |           | 0,782608696         | 0,347826087          |
| Paciente ID        | Score Máximo | Score Médio | Iou Máximo  | Iou Médio | Deteção IoU >= 0.5  | Deteção IoU >= 0.75  |
| 009                | 0,2999       | 0,0403      | 0,2764      | 0,0574    | 0                   | 0                    |
| 018                | 0,5067       | 0,0468      | 0,7338      | 0,3142    | 1                   | 0                    |
| 022                | 1,0000       | 0,1394      | 0,7867      | 0,3318    | 1                   | 1                    |
| 025                | 0,0029       | 0,0003      | 0,6042      | 0,1460    | 1                   | 0                    |
| 030                | 0,9736       | 0,1167      | 0,6346      | 0,3085    | 1                   | 0                    |
| 032                | 0,8607       | 0,0548      | 0,4909      | 0,2859    | 0                   | 0                    |
| 038                | 0,9910       | 0,3383      | 0,8074      | 0,5207    | 1                   | 1                    |
| 057                | 1,0000       | 0,4076      | 0,7229      | 0,4412    | 1                   | 0                    |
| 071                | 0,0013       | 0,0001      | 0,4444      | 0,0663    | 0                   | 0                    |
| 089                | 0,3374       | 0,0127      | 0,5223      | 0,1373    | 1                   | 0                    |
| 098                | 0,0414       | 0,0016      | 0,3663      | 0,0634    | 0                   | 0                    |
| 100                | 1,0000       | 0,8472      | 0,6061      | 0,4328    | 1                   | 0                    |
| 101                | 0,8131       | 0,0376      | 0,4665      | 0,2988    | 0                   | 0                    |
| 134                | 0,9993       | 0,1808      | 0,7073      | 0,2670    | 1                   | 0                    |
| 143                | 0,0001       | 0,0000      | 0,0301      | 0,0021    | 0                   | 0                    |
| 152                | 0,9992       | 0,1216      | 0,7129      | 0,3783    | 1                   | 0                    |
| 153                | 1,0000       | 0,6952      | 0,9167      | 0,7384    | 1                   | 1                    |
| 159                | 1,0000       | 0,1701      | 0,8667      | 0,4333    | 1                   | 1                    |
| 160                | 0,4057       | 0,0054      | 0,7982      | 0,3657    | 1                   | 1                    |
| 165                | 0,0412       | 0,0059      | 0,5944      | 0,2270    | 1                   | 0                    |
| 171                | 0,9901       | 0,0788      | 0,6600      | 0,4415    | 1                   | 0                    |
| 195                | 0,9992       | 0,1135      | 0,7647      | 0,4144    | 1                   | 1                    |
| 199                | 1,0000       | 0,2484      | 0,9412      | 0,5047    | 1                   | 1                    |
| 205                | 1,0000       | 0,6353      | 0,8617      | 0,4971    | 1                   | 1                    |
| 210                | 0,0065       | 0,0011      | 0,2487      | 0,0797    | 0                   | 0                    |
| 214                | 1,0000       | 0,4870      | 0,7216      | 0,5754    | 1                   | 0                    |
| 222                | 0,9997       | 0,0840      | 0,6484      | 0,3925    | 1                   | 0                    |
| 253                | 0,9999       | 0,6607      | 0,9615      | 0,7034    | 1                   | 1                    |
| 256                | 1,0000       | 0,6954      | 0,7623      | 0,4562    | 1                   | 1                    |
| 258                | 0,9507       | 0,1438      | 0,8070      | 0,4355    | 1                   | 1                    |
| 267                | 0,0532       | 0,0054      | 0,5496      | 0,1378    | 1                   | 0                    |
| 270                | 1,0000       | 0,8416      | 0,4211      | 0,2716    | 0                   | 0                    |
| 272                | 0,9999       | 0,2641      | 0,7728      | 0,4466    | 1                   | 1                    |
| 303                | 0,9999       | 0,1028      | 0,7590      | 0,4247    | 1                   | 1                    |
| 306                | 0,4725       | 0,0403      | 0,4815      | 0,2492    | 0                   | 0                    |
| 311                | 0,5490       | 0,0708      | 0,4281      | 0,1773    | 0                   | 0                    |
| 329                | 0,3064       | 0,0209      | 0,3982      | 0,1622    | 0                   | 0                    |
| 330                | 0,9999       | 0,0765      | 0,7813      | 0,2568    | 1                   | 1                    |
| 332                | 1,0000       | 0,7682      | 0,8357      | 0,6474    | 1                   | 1                    |
| 357                | 1,0000       | 0,3361      | 0,6656      | 0,3338    | 1                   | 0                    |
| 358                | 0,9816       | 0,3752      | 0,4331      | 0,2535    | 0                   | 0                    |
| 360                | 0,0037       | 0,0004      | 0,4963      | 0,0399    | 0                   | 0                    |
| 364                | 0,0097       | 0,0015      | 0,5954      | 0,2514    | 1                   | 0                    |
| 367                | 0,1728       | 0,0101      | 0,7258      | 0,1902    | 1                   | 0                    |
| 375                | 0,9999       | 0,1251      | 0,5081      | 0,1331    | 1                   | 0                    |
| 398                | 0,9756       | 0,1062      | 0,6752      | 0,3698    | 1                   | 0                    |
| 403                | 1,0000       | 0,4772      | 0,8777      | 0,6749    | 1                   | 1                    |
| 426                | 0,9966       | 0,0421      | 0,6923      | 0,2264    | 1                   | 0                    |
| 448                | 1,0000       | 0,5190      | 0,0793      | 0,0549    | 0                   | 0                    |
| 452                | 1,0000       | 0,4197      | 0,8706      | 0,5586    | 1                   | 1                    |
| 457                | 0,5047       | 0,0743      | 0,6903      | 0,3444    | 1                   | 0                    |
| 469                | 1,0000       | 0,1635      | 0,8447      | 0,4452    | 1                   | 1                    |
| 488                | 0,0004       | 0,0001      | 0,6216      | 0,1638    | 1                   | 0                    |
| 490                | 0,0579       | 0,0062      | 0,6149      | 0,2530    | 1                   | 0                    |
| 506                | 0,9976       | 0,0313      | 0,8678      | 0,3398    | 1                   | 1                    |
| 517                | 0,9976       | 0,4565      | 0,7632      | 0,4408    | 1                   | 1                    |

|     |        |        |        |        |   |   |
|-----|--------|--------|--------|--------|---|---|
| 521 | 0,0068 | 0,0004 | 0,6684 | 0,2525 | 1 | 0 |
| 525 | 1,0000 | 0,7725 | 0,8314 | 0,6741 | 1 | 1 |
| 540 | 0,0118 | 0,0010 | 0,1198 | 0,0308 | 0 | 0 |
| 560 | 1,0000 | 0,5901 | 0,8515 | 0,6166 | 1 | 1 |
| 580 | 0,0000 | 0,0000 | 0,0000 | 0,0000 | 0 | 0 |
| 590 | 1,0000 | 0,6774 | 0,9267 | 0,7203 | 1 | 1 |
| 593 | 0,3368 | 0,0406 | 0,5562 | 0,1389 | 1 | 0 |
| 598 | 1,0000 | 0,3116 | 0,6081 | 0,1377 | 1 | 0 |
| 609 | 0,5638 | 0,0186 | 0,8344 | 0,4401 | 1 | 1 |
| 619 | 1,0000 | 0,6935 | 0,7006 | 0,5250 | 1 | 0 |
| 622 | 0,3283 | 0,0243 | 0,7071 | 0,4036 | 1 | 0 |
| 635 | 1,0000 | 0,5621 | 0,9400 | 0,6299 | 1 | 1 |
| 637 | 0,9997 | 0,1117 | 0,4498 | 0,1479 | 0 | 0 |
| 639 | 0,9970 | 0,0283 | 0,6410 | 0,1656 | 1 | 0 |
| 663 | 1,0000 | 0,2548 | 0,9183 | 0,6096 | 1 | 1 |
| 664 | 0,0818 | 0,0018 | 0,7589 | 0,1389 | 1 | 1 |
| 680 | 0,9333 | 0,2061 | 0,0000 | 0,0000 | 0 | 0 |
| 689 | 0,9996 | 0,1482 | 0,7813 | 0,3530 | 1 | 1 |
| 709 | 0,1426 | 0,0052 | 0,6121 | 0,2392 | 1 | 0 |
| 755 | 0,5564 | 0,0427 | 0,6877 | 0,2517 | 1 | 0 |
| 768 | 0,0152 | 0,0010 | 0,7429 | 0,1933 | 1 | 0 |
| 770 | 0,9935 | 0,1203 | 0,6786 | 0,3481 | 1 | 0 |
| 775 | 0,0771 | 0,0019 | 0,5143 | 0,1128 | 1 | 0 |
| 779 | 0,0185 | 0,0010 | 0,2867 | 0,0345 | 0 | 0 |
| 790 | 0,2732 | 0,0090 | 0,5794 | 0,0753 | 1 | 0 |
| 818 | 1,0000 | 0,3516 | 0,6640 | 0,4364 | 1 | 0 |
| 828 | 0,2630 | 0,0396 | 0,6137 | 0,3112 | 1 | 0 |
| 833 | 1,0000 | 0,4791 | 0,7520 | 0,5040 | 1 | 1 |
| 836 | 0,0765 | 0,0043 | 0,6018 | 0,1693 | 1 | 0 |
| 842 | 0,8703 | 0,0521 | 0,6154 | 0,2098 | 1 | 0 |
| 845 | 0,0068 | 0,0014 | 0,2563 | 0,1157 | 0 | 0 |
| 852 | 0,9950 | 0,1204 | 0,8739 | 0,4598 | 1 | 1 |
| 855 | 0,0006 | 0,0002 | 0,0915 | 0,0223 | 0 | 0 |
| 876 | 0,0605 | 0,0076 | 0,7368 | 0,2427 | 1 | 0 |
| 879 | 0,9744 | 0,0391 | 0,8096 | 0,1811 | 1 | 1 |
| 907 | 1,0000 | 0,8943 | 0,9423 | 0,7535 | 1 | 1 |
| 909 | 1,0000 | 0,2962 | 0,6776 | 0,3795 | 1 | 0 |
| 913 | 1,0000 | 0,0333 | 0,4114 | 0,0927 | 0 | 0 |