

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Luís Fabrício de Freitas Souza

**Uma Eficaz Abordagem para Segmentação Pulmonar em TCs
Usando Redes Neurais Convolucionais Baseadas em Máscaras de
Regiões**

Fortaleza – CE

8 de Outubro de 2020

Luís Fabrício de Freitas Souza

Uma Eficaz Abordagem para Segmentação Pulmonar em TCs Usando Redes Neurais Convolucionais Baseadas em Máscaras de Regiões

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Processamento Digitais de Sinais e Imagens

Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

8 de Outubro de 2020

Dados Internacionais de Catalogação na Publicação
Instituto Federal do Ceará - IFCE
Sistema de Bibliotecas - SIBI
Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

SOUZA, LUÍS FABRÍCIO DE.

Uma Eficaz Abordagem para Segmentação Pulmonar em TCs Usando Redes Neurais Convolucionais Baseadas em Máscaras de Regiões / LUÍS FABRÍCIO DE SOUZA. - 2021.
92 f. : il. color.

Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Ciência da Computação, Campus Fortaleza, 2021.

Orientação: Prof. Dr. PEDRO PEDROSA REBOUÇAS FILHO.

1. Segmentação de imagem pulmonar. 2. Mask R-CNN. 3. Aprendizado de máquina. I. Título.
CDD 004



Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)
Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)
Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Luís Fabrício de Freitas Souza

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação, sendo aprovada pela Coordenação do Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará e pela banca examinadora:

**Orientador: Prof. Dr. Pedro Pedrosa Rebouças
Filho**

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

**Prof. Dr. Carlos Maurício Jaborandy de Mattos
Dourado Junior**

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE), Brasil.

Prof. Dr. Antonio Carlos da Silva Barros

Universidade da Integração Internacional da Lusofonia
Afro-Brasileira (UNILAB), Brasil.

Fortaleza – CE
8 de Outubro de 2020

Agradecimentos

Acima de tudo, agradeço a Deus pelo dom da vida, pelos caminhos trilhados e oportunos que concedeste a mim, pois sem Jesus nada seria possível e realizado durante toda minha vida na qual sempre esteve presente.

Agradeço a minha mãe, Maria de Fátima de Freitas Souza, pelo amor, carinho e dedicação, sendo um exemplo de mulher guerreira, que lutou toda sua vida por sua família.

Agradeço ao meu pai, Luiz Antônio Marçal de Souza, que Deus me dê a graça de ser pelo menos metade do pai que o senhor é para meu irmão e eu.

Agradeço a minha linda esposa, Camila Maria Cunha de Souza Feitas, pelo seu amor, por sua dedicação, seu apoio, amizade e companheirismo. Sou grato pelos momentos que sempre esteve do meu lado, desde momentos difíceis a momentos de alegrias, que possamos continuar a viver a cada dia nossa vida, nossa história, nossos sonhos e felicidades.

Agradeço ao meu irmão Luiz Fabiano de Freitas Souza, pela amizade e companheirismo. Agradecer a todos os familiares e amigos pelo apoio.

Agradeço ao meu Orientador Prof. Dr. Pedro Pedrosa Rebouças Filho, não só por sua paciência, incentivo e generosidade durante o período acadêmico, mas por todo apoio no momento mais difícil da minha vida e de minha família.

Aos meus amigos de laboratório; Solon, Gabriel Bandeira, Aldísio, Hércules, Shara, Marcos, Adriell e Iagson pelas trocas de ideias e experiência na qual assim como meu Orientador Profº Dr. Pedro Pedrosa, contribuíram para minha formação acadêmica.

Agradecer finalmente ao Laboratório de Processamento de Imagens, Sinais e Computação Aplicada (LAPISCO) - especialmente a todos os membros, pelas trocas de experiência de vida, vida acadêmica, profissional e fraternal que nos trouxe e continua a proporcionar muitas conquistas.

*“Mas graças a Deus, que sempre nos conduz vitoriosamente em Cristo e por nosso
intermédio exala em todo lugar a fragrância do seu conhecimento!”*

1 Coríntios 15:57

Resumo

A segmentação de imagens médicas é um grande desafio para técnicas de visão computacional e consecutivamente para área da medicina, se tratando de pulmão o desafio se dá pela diversidade de doenças pulmonares bem como as diferentes dimensões do pulmão em imagens de Tomografias Computadorizadas (TCs). A TC é uma ferramenta de auxílio para diagnóstico clínico, diversos sistemas baseados em Diagnóstico Assistido por Computador (CAD) são desenvolvidos ou aprimorados a partir de imagens de TC combinadas a métodos computacionais. Os sistemas de visão computacional possuem inúmeras ferramentas para auxílio em diversas áreas médicas, principalmente no diagnóstico por imagens. A tomografia computadorizada é o principal método por imagem utilizado para auxiliar no diagnóstico de doenças como; fraturas ósseas, câncer de pulmão, doenças cardíacas, enfisema, dentre outras. As doenças pulmonares são responsáveis pela morte de mais de 3 milhões de pessoas a cada ano, cerca de 65 milhões de pessoas são afetadas pelas consequências de diferentes tipos de doenças relacionadas ao pulmão, como câncer de pulmão que já está entre as quatro principais causas de morte no mundo por doença. As regiões pulmonares em imagens (TC) são marcadas visualmente e demarcadas manualmente por um especialista para diagnósticos clínicos tradicionais. A etapa inicial de segmentação é uma etapa fundamental para as técnicas de visão computacional e seu treinamento. Uma vez definidas, as regiões pulmonares são segmentadas automaticamente com o intuito de auxiliar no diagnóstico clínico. Este trabalho propõe uma nova abordagem para segmentação automática dos pulmões em imagens de Tomografia Computadorizada (TC), usando a rede *Mask R-CNN* para criação de mapeamento de regiões pulmonares, combinada a métodos de aprendizado de máquina supervisionado e não supervisionado (*Bayes*, *SVM*, *Kmeans* e *GMMs*). Nossa abordagem usando a *Mask R-CNN* combinado ao *kernel K-means* produziu os melhores resultados para a segmentação pulmonar por meio de *fine-tuning*, atingindo excelentes valores de *accuracy* com $97,68 \pm 3,42\%$ e um tempo de execução médio de 11,2 segundos. Comparamos os resultados do modelo proposto a outros trabalhos relacionados a fim de validar o método deste estudo, a abordagem obteve a mais alta *accuracy* sendo mais rápida do que alguns métodos já consolidados na literatura.

Palavras-chave: Segmentação de imagem pulmonar, *Mask R-CNN*, Aprendizado de máquina.

Abstract

The segmentation of medical images is a great challenge for computer vision techniques and consecutively for the area of medicine, in the case of lungs, the challenge is due to the diversity of lung diseases as well as the different dimensions of the lung in computed tomography (CT) images. CT is an aid tool for clinical diagnosis; several systems based on Computer Assisted Diagnosis (CAD) are developed or improved from CT images combined with computational methods. Computer vision systems have numerous tools to aid in various medical areas, mainly in imaging diagnostics. Computed tomography is the main imaging method used to assist in the diagnosis of diseases such as; bone fractures, lung cancer, heart disease, emphysema, among others. Lung diseases are responsible for the death of more than 3 million people each year; about 65 million people are affected by the consequences of different types of lung-related diseases like lung cancer, which is already the four leading causes of death in the world by disease. The pulmonary regions in images (CT) are visually marked and manually marked by a specialist for traditional clinical diagnoses. The initial segmentation stage is a fundamental stage for computer vision techniques and their training. Once defined, the pulmonary regions are automatically segmented in order to assist the clinical diagnosis. This work proposes a new approach for automatic segmentation of the lungs in Computed Tomography (CT) images, using the *Mask R-CNN* to create pulmonary region mapping, combined with supervised and unsupervised machine learning methods (Bayes, SVM, Kmeans and GMMs). Our approach using Mask R-CNN combined with kernel K-means produced the best results for lung segmentation through fine-tuning, reaching excellent values of accuracy with $97.68 \pm 3.42\%$ and an average run time of 11.2 seconds. We compared our results to other related works in order to validate our method; our approach obtained the highest accuracy being faster than some methods already consolidated in the literature.

Keywords: Image Segmentation lung, Mask R-CNN, Machine Learning.

Lista de ilustrações

Figura 1 – Diferentes características topológicas de crescimento da região do Pulmão, em imagem de Tomografias Computadorizadas (TC).	29
Figura 2 – Diferentes características patológicas, em imagem de Tomografias Computadorizadas (TC).	29
Figura 3 – (A)- Ilustração da ligação(conexão) entre as camadas de uma rede CNN. (B)- Representação de 3 neurônios da camada oculta interligados ao mesmo Mapa de Características. Fonte: O próprio autor.	39
Figura 4 – Ilustração do processo de camadas convolucionais. Fonte: < http://deeplearning.net/tutorial/lenet.html >	40
Figura 5 – Ilustração de diferentes camadas encarregadas em um processo de convolucional. Fonte:< http://deeplearning.net/tutorial/lenet.html >	41
Figura 6 – Imagem adaptada de (HE et al., 2017). Estrutura da <i>Mask R-CNN</i> para segmentação de instância (máscaras de segmentação).	41
Figura 7 – Representação da intensidade entre pixels em uma imagem. A imagem (A) representa a imagem original, a imagem (B) representa as diferentes intensidades de níveis de cinza representadas por seu valores correspondentes, na imagem (C) é extraída a imagem para simples representação dos valores dos níveis. Imagem adaptada de (YAMASHITA et al., 2018).	43
Figura 8 – Fluxograma da Mask R-CNN. Fonte: O próprio autor.	45
Figura 9 – Bayes - Ilustração da base de dados com suas respectivas amostras e rótulos. Imagem Adptada de: https://www.globalsoftwaresupport.com/	47
Figura 10 – Bayes - Ilustração do processo probabilistico bayesiano. Imagem Adaptado de: https://www.globalsoftwaresupport.com/	48
Figura 11 – SVM - O hiperplano da margem máxima. Fonte: O próprio autor	48
Figura 12 – Apresenta etapas do método K-Means. Fonte: Müller, Guido et al. (2016)	49
Figura 13 – De (REBOUÇAS FILHO et al., 2014) Método Balão e sua evolução com inicialização no centro do objeto de interesse (Pulmão), até a evolução com inicialização próxima da área das bordas do pulmão	52
Figura 14 – Resultado da segmetação gerado por (REBOUÇAS FILHO et al., 2014) (Método Balão), com contorno do pulmão esquerdo na imagem de TC.	53
Figura 15 – Resultado da segmetação gerada pelo método Gradient Vector Flow - GVF em imagens de pulmão de TC.	54
Figura 16 – Resultado da segmentação gerada pelo método Vector Field Convoluti-onal - VFC em imagens de pulmão de TC.	55
Figura 17 – Ciclos do método Crisp Adaptativo - CRAD (REBOUÇAS FILHO, 2013), baseado em Energias adaptativas.	57

Figura 18 – A imagem ilustra a inicialização do modelo OPS até o ponto de segmentação final, delineado pelas margens de cor azul. Fonte: Adaptado de Barros (2016).	58
Figura 19 – Resultado gerado pelo método SISDEP, com o objetivo de segmentar o pulmão em TC. Fonte: Imagem adaptada de Felix et al. (2009)	60
Figura 20 – Fluxograma do novo método para segmentação automática do pulmão em imagens de TC, utilizando a Mask R-CNN com um kernel para mapear a extração de características usando métodos supervisionados e não supervisionados de aprendizado de máquina. Fonte: O próprio Autor. 65	
Figura 21 – Resultados da comparação entre os modelos de nossa metodologia utilizando <i>deep learning</i> para gerar mapas dos pulmões com os <i>kernels</i> criados. a) imagem de entrada, b) Mask+Bayes, c) Mask+SVM, d) Mask+MMGs e) Mask+K-means	70
Figura 22 – Uma representação de plotagem da Tabela 1. Pos-Position Adjustment, Int-Intensity Adjustment, Size - Size Adjustment, DC - Dice, Acc - Accuracy, Sens-Sensitivity and Spec-Specificity.	71
Figura 23 – Apresenta a região de barreira referente a parede do pulmão (contorno) em 3D utilizando nosso melhor modelo, Mask R-CNN + K-means por meio de fine-tuning.	72
Figura 24 – Modelo Proposto e métodos utilizados por (FILHO et al., 2019), baseados na literatura para comparação entre modelos (GVF, VFC, SISDEP, OPS, CRAD). Métrica Coeficiente de Dados (<i>Dice's coefficient.</i>)	74
Figura 25 – Comparação do Modelo Proposto com o melhor resultado de (FILHO et al., 2019) métrica de avaliação DC.	75

Lista de tabelas

Tabela 1	– Métricas de avaliação de segmentação usando o Mask R-CNN, com métodos de aprendizado de máquina supervisionados e não supervisionados, com seus respectivos kernels.	71
Tabela 2	– Resultados do método Balão adaptativo (REBOUÇAS FILHO et al., 2014) sobre as 36 imagens utilizadas no trabalho de (REBOUÇAS FILHO et al., 2014) e seus respectivos resultados de métricas.	73
Tabela 3	– Modelo Proposto em comparação aos modelos (GVF, VFC, SISDEP, OPS, CRAD) usado no trabalho de (FILHO et al., 2019).	73
Tabela 4	– Comparação entre o Modelo Proposto e a melhor abordagem e (FILHO et al., 2019) em imagens de TC de pulmão agrupadas por Normal, DPOC e Fibrose.	74
Tabela 5	– Trabalhos relacionados ao uso da Mask R-CNN em conjunto com o número de imagens usadas no treinamento por diferentes métodos. . .	76

Lista de abreviaturas e siglas

AB	Balão adaptativo (<i>Adaptive Balloon</i>)
ACM	Métodos de Contorno Ativo (<i>Active Contours Methods</i>)
ADP	Análise de Densidade Pulmonar
AHTD	Análise da Densidade do Tecido Humano (<i>Analysis Human Tissue Density</i>)
CAD	Diagnóstico Auxiliado por Computador (<i>Computer-Aided Diagnosis</i>)
CNN	Rede Neural Convolucional (<i>Convolutional Neural Network</i>)
COMEPE	Comitê de Ética em Pesquisa
CRAD	Crisp Adaptativo
DC	Coefficiente dos dados (<i>Dice's Coefficient</i>)
DICOM	<i>Digital Imaging and Communications in Medicine</i>
DPI	Doença Pulmonar Intersticial
DPM	Densidade Pulmonar Média
DPOC	Doença Pulmonar Obstrutiva Crônica
EM	Expectativa - Maximização (<i>Expectation – Maximization</i>)
GB	Gigabyte
GHz	GIGA-HERTZ
GMMs	Modelos de Mistura Gaussiana
GPU	Unidade de Processamento Gráfico (<i>Graphics Processing Unit</i>)
GVF	Fluxo de Vetor Gradiente (<i>Gradient Vector Flow</i>)
MCA	Método de Contorno Ativo
Mask R-CNN	Redes Neurais Convolucionais baseadas em Regiões com Máscara
MLP	Rede Perceptron Multicamadas
OMS	Organização Mundial da Saúde

OPF	Floresta de Caminho Ideal (<i>Optimum-Path Forest</i>)
OPS	<i>Optimum Path Snake</i>
PDI	Processamento Digital de Imagens
PPV	Valor Preditivo Positivo
RAM	Memória de Acesso Aleatório (<i>Random Access Memory</i>)
RBF	Função de Base Inicial (<i>Radial Basis Function</i>)
R-CNN	Redes Neurais Convolucionais baseadas em Regiões
RPN	Rede de Propostas de Região
RNAs	Redes Neurais Artificiais
RM	Ressonância Magnética
Sen	Sensibilidade
SISDEP	Sistema para a Detecção e a Quantificação de Enfisema Pulmonar
Spe	Especificidade
SSE	Soma do Erro Quadrático (<i>Sum of Squared Error</i>)
SVM	Máquina de Vetores de Suporte (<i>Support Vector Machine</i>)
TC	Tomografia Computadorizada
TCAR	Tomografia Computadorizada de Alta Resolução
UFC	Universidade Federal do Ceará
UH	Unidade Hounsfield
VFC	Convolução de Campo de Vetor (<i>Vector Field Convolution</i>)

Lista de símbolos

Π	Letra grega Pi Maiúscula, denominado Produto ou Produtório, no conceito matemático refere-se a multiplicação.
Φ	Letra grega Fi, equivale ao conjunto de parâmetros definidos pela i-ésima componenteda mistura.
Θ	Letra grega Teta, na representa a medida de um determinado Vetor, sendo um conjunto de parâmetros da mistura,
θ	Letra grega teta, referência ao ângulo.
Σ	Notação Sigma, somatório ou somatória, significa a soma de termos.
π	Símbolo Pi, representa uma proporção numérica definida pela relação entre o perímetro de uma circunferência e seu diâmetro.
ϕ	Letra grega Fi, (variante). correspondete a uma função de densidade Gaussiana.
α	Letra grega Alpha, conotação angular de início ou inicialização.
β	Letra grega Beta, conotação ponderação ao ângulo.
$\int$	Símbolo Integral, no qual representa um sinal que indica a integração e o resultado de integrar uma diferencial ou derivada.
μ	Letra grega Mi (Pronúncia: Miú), refere-se ao peso específico de uma coeficiente.
∂	Símbolo "del", usado para distinguir derivadas parciais das derivadas ordinárias de uma variável.
$\cap$	Símbolo Intersecção, corresponde a Intersecção entre conjuntos.
ω	Letra grega Ômega minúsculo, indica o mínimo local.
Ω	Letra grega Ômega maiúsculo, indica a composição do mínimo com o máximo local.
ν	Letra grega Nu, indica o limiar da força balão.
∇	Símbolo grego Nabla, denomina o operador diferencial.
$\in$	Símbolo que indica a relação de pertinência.

Sumário

1	INTRODUÇÃO	25
1.1	Motivação para a Dissertação	28
1.2	Descrição do problema	28
1.3	Objetivo Geral e Específicos	30
1.4	Produção científica	30
1.5	Estrutura da Dissertação	32
2	TRABALHOS RELACIONADOS	33
3	FUNDAMENTAÇÃO TEÓRICA	37
3.1	Aprendizagem de Máquina	37
3.2	Deep Learning	38
3.2.1	Convolutional Neural Network - CNN	38
3.2.2	Mask R-CNN	41
3.3	Conceito - Métodos Supervisionados e Não Supervisionados.	46
3.3.1	Classificadores - Supervisionados	46
3.3.2	Classificadores - Não Supervisionados	49
3.4	Modelos de Segmentação Pulmonar	51
3.4.1	Balão	51
3.4.2	<i>Gradient Vector Flow</i> (GVF)	53
3.4.3	<i>Vector Field Convolutional</i> (VFC)	55
3.4.4	Crisp Adaptativo (CRAD)	56
3.4.5	<i>Optimum path Snakes</i> (OPS)	58
3.4.6	SISDEP	59
3.5	Métricas de Avaliação	60
3.5.1	Ajuste de posição - (<i>Position adjustment</i>)	60
3.5.2	Ajuste de intensidade - (<i>Intensity adjustment</i>)	61
3.5.3	Ajuste de tamanho - (<i>Size adjustment</i>)	61
3.5.4	Coeficiente dos dados - (<i>Dice's coefficient</i>)	61
3.5.5	Sensibilidade e Especificidade - (<i>Sensitivity and Specificity</i>)	61
3.5.6	Precisão - (<i>Accuracy</i>)	62
4	MÉTODO PROPOSTO	63
4.1	Conjunto de Dados	63
4.2	Metodologia	63
4.3	Metodologia - Modelo Supervisionado e Não-Supervisionado	66

4.3.1	Método - Modelo Supervisionado	66
4.3.2	Método - Modelo Não-Supervisionado	67
5	RESULTADOS E DISCUSSÃO	69
5.1	Configuração e Experimento	69
5.2	Discussão	70
6	CONCLUSÃO	79
7	ANEXO A	82
	REFERÊNCIAS	83

1 Introdução

Diversas patologias podem afetar o bom funcionamento dos pulmões, inúmeras doenças respiratórias como pneumonia e câncer de pulmão são classificadas como graves segundo a (OMS) Organização Mundial da Saúde (TRAVIS et al., 2015). As doenças respiratórias são de fato um problema de saúde pública (GUAN et al., 2016), tanto no que se refere às doenças originadas pelo próprio comportamento do indivíduo como; tabagismo, exposição em áreas de risco pela profissão, quanto às doenças adquiridas pelo sistema imunológico através da poluição da atmosfera ou incidentes como; incêndio e queimadas, responsáveis pelas causas de inalação de fumaça por meio das vias aéreas respiratórias trazendo dados aos pulmões (LELIEVELD et al., 2015). Tais situações como estas, são de extrema preocupação para saúde da população mundial.

Inúmeras patologias relacionadas aos pulmões podem ser diagnosticadas, dentre elas, doenças respiratórias como por exemplo; pneumonia, doença pulmonar obstrutiva crônica (DPOC), tuberculose, infecção respiratória e até mesmo diferentes tipos de câncer pulmonar. Esses são alguns dos problemas que afetam diretamente a saúde da sociedade sendo classificadas como doenças graves pela Organização Mundial de Saúde (OMS)(ORGANIZATION, 2013). De acordo com (BARNES, 2016), a DPOC é a quinta causa de insuficiência respiratória, responsável por afetar principalmente pessoas acima de 45 anos, desta forma, a doença afeta cerca de 10% da população mundial. Em um cenário global, segundo a Organização Mundial de Saúde (OMS), tais patologias como estas trazem cerca de 250 mil mortes a cada ano, onde a DPOC está entre as doenças que mais matam no mundo, e até 2030 se tornará o terceiro fator de morte por doença em escala global. (MARCO et al., 2004).

Segundo (BERAN et al., 2015), diferentes tipos de doenças pulmonares são responsáveis pela morte de mais de 3 milhões de pessoas a cada ano, cerca de 65 milhões de pessoas são afetadas pelas consequências de diferentes tipos de doenças relacionadas ao pulmão. Diversas pessoas são internadas em leitos de Unidade de Tratamento Intensivo (UTI), isso impacta diretamente no uso de aparelhos de oxigênios para auxílio à respiração do paciente possibilitando através de medidas extremas salvar vidas. Porém, seu uso pode causar outras complicações para o sistema respiratório, sendo responsáveis por milhares de óbitos relacionados às infecções do pulmão. Estudos recentes mostram que existem cerca de 10,4 milhões de novos casos de tuberculose diagnosticada a cada ano, causando aproximadamente 1,7 milhões de mortes, sendo a tuberculose classificada como a nona causa de morte no mundo por doenças em 2016 (GLOBAL..., 2017). O efeito da (DPI) Doença Pulmonar Intersticial intensifica o número de patologias e a consequências de decorrentes problemas respiratórios, a DPI representa um conjunto de

mais de 200 distúrbios pulmonares crônicos, distinguidos por inflamações nos tecidos do pulmão ocasionando cicatrizações, categorizada tal anomalia como fibrose pulmonar. Em alguns casos, a fibrose pode trazer como consequência a rigidez dos pulmões, interferindo na incumbência e capacidade dos sacos alvéolos de capturar e transportar oxigênio para corrente sanguínea, consequentemente, podendo levar à perda parcial ou permanente da capacidade respiratória do indivíduo. (SOCIETY; COMMITTEE, 1999).

Segundo (BUIST, 2003), o diagnóstico precoce é essencial para o sucesso do tratamento e aumento da probabilidade de cura da enfermidade, o tratamento adequado em doenças relacionadas aos pulmões requer um diagnóstico rápido para um tratamento eficaz, por meio de intervenções promissoras de acordo com o grau e evolução da doença (MOLINA-MOLINA et al., 2018). Pois todo este impacto na saúde mundial e na vida dos pacientes, reflete também em prejuízos financeiros (DÍAZ; CELLI; CELEDÓN, 2018), segundo as OMS (MARCINIUK COCHAIR DEAN E. SCHRAUFNAGEL, 2017), são gastos cerca de 71 à 167 bilhões de dólares no tratamento de diferentes doenças pulmonares graves a cada ano. Só nos Estados Unidos, cerca de 14,2 milhões de dias de trabalho foram perdidos em 2008, com custo total anual de 56 bilhões de dólares impactados na economia americana (MASOLI et al., 2004).

Nas últimas décadas, houveram várias melhorias relacionadas às ferramentas para auxílio ao diagnóstico médico. Dentre elas, a Tomografia Computadorizada (TC) é uma ferramenta de extrema importância para diagnóstico de doenças (HSIEH et al., 2009; SLUIMER et al., 2006). A TC é um tipo de imagem utilizada no diagnóstico e acompanhamento de diversas patologias relacionadas ao corpo humano, tais como; coração, pulmão, cérebro, fígado, dentre outros órgãos e ossos do corpo humano. Essas ferramentas são de extrema eficiência para investigação de patologias, sendo essencial para diagnósticos clínicos (COXSON, 2007), o procedimento permite a visualização de órgãos internos como os pulmões e suas estruturas. As TCs são usadas para monitorar o progresso ou cura de doenças por meio de tratamentos adequados com base no conhecimento obtido pelo especialista, aumentam a precisão da investigação clínica (MUZAMMAL et al., 2020; SODHRO; LI; SHAH, 2016; WU et al., 2018). Além disso, eles diminuem o número de possíveis erros em diagnósticos (DÍAZ; CELLI; CELEDÓN, 2018).

O diagnóstico de doenças pulmonares é um processo delicado realizado por profissionais capacitados na área da saúde, a segmentação é o primeiro passo para um diagnóstico clínico (AMIRAV et al., 1993). Um desafio clássico para o diagnóstico clínico de doenças pulmonares usando TC, é a demarcação da região dos pulmões. Uma imagem está associada a diversidade de informações, tais atributos contidos em uma imagem de TC definem a similaridade e a dissimilaridade entre os objetos contidos na imagem e sua tonalidade entre os pixels. O médico especialista faz a demarcação visual nos exames, na busca de diagnosticar regiões que caracterizam alterações patológicas com base no

estudo adquirido, segmentando-a visualmente, e demarcando regiões de interesse em um processo manual, contornando o objeto de interesse na imagem. Porém, por muitas vezes as variações que ocorrem são pequenas, com casos até imperceptíveis para análises visuais a olho nu, tornando assim o campo do diagnóstico mais limitado, restringindo a capacidade de investigação por meio da delimitação do olho humano (MESSAY; HARDIE; ROGERS, 2010).

No entanto, sistemas de visão computacional foram desenvolvidos para automatizar a tarefa de demarcação de regiões pulmonares, como uma espécie de pré-diagnóstico (SODHRO et al., 2019; SODHRO et al., 2019b; SODHRO et al., 2017) através de técnicas de Processamento de Imagem Digital (PDI) (SODHRO et al., 2019a; SODHRO; PIRBHULAL; ALBUQUERQUE, 2019), métodos de aprendizado de máquina como as Redes Neurais Artificiais (ANN) (SCHMIDHUBER, 2015) e *Deep Learning*. O processamento de análise por meio de algoritmo é um processo de localização e demarcação da área de interesse de forma automática ou semiautomática, a fim de aplicar quaisquer métodos computacionais para diagnósticos clínicos (HU et al., 2020). Poderosos métodos de aprendizado profundo combinados a RNAs (Redes Neurais Artificiais) usam técnicas significativas no campo da visão computacional, onde modelos computacionais permitem a segmentação semi-automática e automática de imagens de TCs dos pulmões.

Tais estudos voltados para sistema de Diagnóstico Assistido por Computador - *Computer Aided Diagnosis* (CAD), são cada vez mais utilizados na área da medicina para tomada de decisão, com o intuito de obter um pré-diagnóstico computacional eficaz para auxílio do especialista (MOSQUERA-LOPEZ et al., 2014). Aplicações com uso de *deep learning* combinados a métodos clássicos e aprendizagem de máquina com uso de Processamento Digital de Imagens (PDI) são cada vez mais utilizados, a fim de desenvolver ou aprimorar Sistemas (CAD) (ZHOU; GREENSPAN; SHEN, 2017). Considerando a necessidade de interpretação das imagens resultantes de TC e a urgência na identificação do tipo de lesão, torna-se de grande utilidade sistemas de suporte ao tratamento clínico em questão. Os sistemas (CAD), aliado ao conhecimento médico, vem ganhando mais espaço em várias modalidades de diagnóstico por imagem, reduzindo o tempo de avaliação dos exames, o número de falsos positivos e elevando a acurácia do diagnóstico (BONANNO et al., 2015). Em geral, os sistemas CAD utilizam-se de técnicas computacionais provenientes das áreas de processamento digital de imagens, *machine learning* e *pattern recognition* para fornecer uma grande quantidade de informações que o médico especialista precisa para analisar e avaliar os exames de forma abrangente em um curto espaço de tempo.

Com base na importância da segmentação rápida e precisa de Pulmões em TC, este estudo tem como proposta apresentar um novo modelo para segmentar imagens de TC de pulmão com uso da Rede Neural Convolucional utilizando a *Mask R-CNN*, combinados a métodos de aprendizagem de máquina (Redes Neurais Artificiais - RNA) com ênfase em

modelos supervisionados e não supervisionados. O método propõe a criação de modelos com *kernels* que auxiliam no processo dos resultados por meio de *fine-tuning*, o método também consegue diminuir gradativamente a necessidade de inúmeras quantidades de imagens do banco de dados para treino da rede, chegando em ótimos resultados, tornando o modelo mais robusto.

1.1 Motivação para a Dissertação

Inúmeros métodos são abordados na literatura com o intuito de segmentar a região do pulmão em imagens de tomografia computadorizada, utilizando métodos clássicos com modelos não automáticos ou semi-automáticos, o que torna o processo de segmentação dependente de interação humana. No entanto, novos modelos com uso de CNNs são bastante utilizados atualmente graças a grande capacidade de processamento de dados com geração de bons resultados. Porém, tratando-se de imagens médicas, diversas aplicações são dependentes de grande quantidade de dados com seu elevado custo computacional e financeiro, desde a marcação das imagens por especialistas, até as anotações de dados e armazenamento. Além disso, a pluralidade da resolução de problemas sem um refino focado na problemática, diminuem as possibilidades de construção de modelos distintos com aplicações em problemas específicos.

Por outro lado, o progresso dos modelos com uso das CNNs tem se potencializado junto a grande capacidade de processamento, automatização de modelos e possíveis soluções com bons resultados. Técnicas inspiradas em *fine-tuning* e aprendizagem por transferência possibilitaram a elaboração de modelos mais robustos para resoluções de determinados problemas, combinados a outros métodos de aprendizagem de máquina proporciona adaptações nos modelos adequando-os de acordo com problemas específicos, oferecendo assim estratégias mais eficazes na busca de melhoria dos resultados.

1.2 Descrição do problema

O problema de segmentação é um desafio clássico, segundo Nóbrega, Rodrigues e Filho (2017) se tratando de imagens médicas, tomografias computadorizadas do pulmão apresentam diferentes características, desde diferentes tamanhos do objeto de interesse na imagem, devido ao processo de respiração e inspiração do ar que inflam os pulmões, a tipos de patologias pulmonares e variações de contrastes contidos na imagem, como mostra a Figura 1.




Figura 1 – Diferentes características topológicas de crescimento da região do Pulmão, em imagem de Tomografias Computadorizadas (TC).

Existem variadas estruturas internas apresentadas em imagem de Tomografia Computadorizada, representada por diferentes densidades do tecido, a imagem de TC do pulmão é afetada diretamente entre o contraste de sua parede pulmonar e vias respiratórias.

Deste modo, para a idealização e criação de novos modelos de segmentação pulmonar, o método deverá considerar as devidas particularidades para que se obtenha êxito em todo o processo de segmentação. Não só em relação às formas topológicas, mas também as suas características patológicas, como apresentado na figura 2.




Figura 2 – Diferentes características patológicas, em imagem de Tomografias Computadorizadas (TC).

Criar novos modelos junto a tais desafios, demanda combinações de métodos e técnicas para a geração de modelos inovadores. Em cima disso, este trabalho traz como inovação, uma solução para segmentação de TC de pulmão, reunindo conceitos atuais inspirados no modelo *Mask R-CNN* combinados a métodos de aprendizagem de máquina.

1.3 Objetivo Geral e Específicos

O objetivo geral deste estudo tem como finalidade apresentar um novo método de segmentação de pulmão em Tomografia Computadorizada, o modelo traz como proposta uma ferramenta inovadora para uso em sistemas de auxílio e diagnóstico clínico para análise em TCs do pulmão. Visando oferecer um modelo com uso de *deep learning* em conjunto com métodos de aprendizagem de máquina de forma automática, rápida e inovadora com menos uso de dados.

Objetivos específicos:

1. Investigar na literatura, métodos de segmentação pulmonar para comparação de desempenho entre os modelos;
2. Propor diferentes modelos de detecção de bordas do pulmão com uso da *Mask R-CNN* em conjunto a *kernels*;
3. Desenvolver método para identificar a parede pulmonar por meio de clusterização após saída de resultado *Mask R-CNN*, chamado de mapa pulmonar;
4. Desenvolver na saída da *Mask R-CNN* com mapa pulmonar, *kernels* com métodos supervisionando em não-supervisionados para segmentação;
5. Examinar entre os modelos criados neste estudo, a segmentação mais próxima de marcações manuais realizadas pelo especialista;
6. Gerar um banco de imagens segmentadas com o método apresentado neste estudo na perspectiva de desenvolver estudos futuros.

1.4 Produção científica

Durante este projeto de mestrado, os seguintes trabalhos científicos foram aceitos e publicados, a saber:

- (ISDA 2019) - Automatic Lung Segmentation in CT Images Using Mask R-CNN for Mapping the Feature Extraction in Supervised Methods of Machine Learning
- 1º Autor - Qualis B1 (CC);

- (Elsevier - Journals - Artificial Intelligence in Medicine 2020) - An effective approach for CT lung segmentation using mask region-based convolutional neural networks - 2º Autor - Qualis A1 (Eng IV);
- (IEEE - Journals Access - 2020) - Internet of Medical Things-based Deep Learning Techniques for Segmentation of Lung and Stroke Regions in CT Scans - 3º Autor - Qualis A2 (Eng IV);
- (IJCNN 2020 - IEEE WORLD CONGRESS ON COMPUTATIONAL INTELLIGENCE (WCCI) 2020) - Intelligent Industrial IoT system for detection of short-circuit failure in windings of wind turbines - 2º Autor - Qualis A1 (Eng IV);

1.5 Estrutura da Dissertação

O capítulo 2 deste estudo apresenta uma revisão literária de trabalhos relacionados a métodos de segmentação de pulmão e utilização de Redes Neurais Convolucionais(CNN), abrangendo métodos tradicionais a métodos mais recentes baseados *deep learning*. Em seguida são apresentados métodos que serviram como base de análise e comparação de resultados entre a base de dados em estudo. No capítulo 3, são detalhados modelos de aprendizado de máquina usados para criação e desenvolvimento de *kernels* no método proposto.

No Capítulo 4 é apresentado o novo método de segmentação pulmonar baseado em *deep learning*, abordaremos desde o modelo *Mask R-CNN*, passando pela técnica da criação dos mapas pulmonares e desenvolvimento dos *kernels*; supervisionados e não-supervisionados. No Capítulo 5 serão discutidos os resultados dos experimentos. Por fim, a Conclusão e Trabalhos futuros no Capítulo 6.

2 Trabalhos relacionados

Neste capítulo é apresentado o estado da arte sobre métodos de segmentação pulmonar, incluindo métodos considerados clássicos, abrangendo métodos recentes baseados em *Deep Learning*.

O problema de segmentação de imagens é um desafio clássico na área médica (DOEL; GAVAGHAN; GRAU, 2015), na literatura existem diversas técnicas de Processamento Digital de Imagens (PDI) para segmentar imagens médicas, como os métodos *thresholding* (KHARE; TIWARY, 2005), *wavelet* (YANG; SU; SUN, 2010), crescimento de região (JIANG; SI; LUO, 2006), contornos ativos (FILHO et al., 2017) e *watershed* (GRAU et al., 2004).

Existem dois segmentos iniciais nos quais o aprendizado de máquina pode ocorrer, isto é, no método supervisionado, que se baseia em modelos e classificação de regressão, e no método não supervisionado, baseado em modelo de clusterização (MOHRI; ROSTAMIZADEH; TALWALKAR, 2012). Há também modelos conhecidos como misto, isto é, semi-supervisionado. Essas abordagens podem ser aplicadas em várias áreas diferentes, como na previsão do número de defeitos em software utilizando métodos supervisionados e não supervisionados (CHEN et al., 2019). Além disso, métodos semi-supervisionados são usados em sensores para prever a qualidade dos misturadores de borracha no campo de fabricação (ZHENG et al., 2018). Existem trabalhos na área da medicina como é o caso de (ZHANG; ISOLA; EFROS, 2017) que tem como objetivo a criação de auto-codificadores cerebrais. Portanto, são diversas possibilidades de métodos supervisionados e não supervisionados em diferentes domínios e contextos. No entanto, muitas aplicações, como os mencionados acima, usam métodos não automáticos ou semi-automáticos que requerem interação humana direta, total ou parcial para executar alguns procedimentos.

Novas aplicações baseadas em visão computacional continuam surgindo, criando novos conceitos e métodos (PIRBHULAL et al., 2019; MUZAMMAL et al., 2020), podemos enfatizar a eficácia das Redes Neurais Convolucionais (CNNs) para vários usos, como classificação, segmentação e detecção uniforme de objetos de interesse em imagens. O estudo de (DING et al., 2019) aplicou *Deep Learning* para identificar pessoas (DING et al., 2019). Os autores (SANTOS et al., 2015) alcançaram excelentes resultados no reconhecimento de sons de vozes em ambientes ruidosos. Os trabalhos de (YU et al., 2019; HUANG et al., 2019b; JOHNSON, 2018) mostraram resultados promissores em várias aplicações voltadas à classificação, aplicações em reconhecimento de regiões e localização de objetos em imagens. Novas abordagens com métodos de aprendizado profundo, como o uso de CNNs para classificar imagens histológicas de câncer de mama, foram aplicadas

no trabalho de (ARAÚJO et al., 2017). Assim como a classificação do som pulmonar no trabalho de (BARDOU; ZHANG; AHMAD, 2018).

Cada vez mais são utilizados modelos baseados em Redes Convolucionais para infinitas aplicações, como é o caso de Couteaux et al. (2019) que usou um modelo com um tipo específico de CNN objetivando a detecção automática e classificação da ruptura no menisco do joelho. Fundamentado também por redes Convolucionais ligado aos conceitos de *deep learning*, foi utilizado um modelo capaz que realiza a segmentação dos volumes da próstata por imagens RM usando a arquitetura V-net, foi apresentado nos estudos de (MILLETARI; NAVAB; AHMADI, 2016). A variedade de aplicações abrangem setores distintos se tratando de imagens, os autores (WACHINGER; REUTER; KLEIN, 2018) criaram o DeepNAT, um modelo baseado no aprendizado de ponta a ponta, para segmentar o cérebro por meio de (RM) Ressonância magnética, dentro de uma proposta baseada na projeção de imagens em 3D (BERNAL et al., 2019) o modelo mostrou a eficiência da CNN para análise de imagens cerebrais em imagens de ressonância magnética. Ambos os trabalhos (WACHINGER; REUTER; KLEIN, 2018; BERNAL et al., 2019) tinham em comum um grande número de imagens para o treinamento de seus modelos. No entanto, ainda existem muitos desafios relacionados à área médica, principalmente em relação à tomografia computadorizada de pulmão, onde os desafios são complexos, uma vez que o objeto de interesse (pulmões) na imagem muda constantemente de tamanho durante o exame clínico, por conta do processo de respiração e inspiração por meio das vias respiratórias (DOEL; GAVAGHAN; GRAU, 2015). Métodos que usam CNNs têm sido amplamente explorados em vários estudos para a segmentação e detecção e pré-diagnóstico de patologias (SUZUKI, 2017; SHI et al., 2019). (WANG et al., 2018) usou um método de segmentação baseado em CNN em imagens 2D e 3D em tomografias computadorizadas para o diagnóstico de doença pulmonar difusa. Estudos para prever o tempo de sobrevivência entre pacientes com câncer de pulmão foram realizados por (BARTHOLOMAI; FRIEBOES, 2018), a CNN foi também utilizada para detectar anomalias, através de análise de pixels na imagem de TC (PAWEŁCZYK et al., 2017; ANTHIMOPOULOS et al., 2016). Além disso, a classificação e segmentação da região torácica foi demonstrada por (NOVIKOV et al., 2018; LUSTBERG et al., 2018), onde as CNNs foram necessárias para detectar e segmentar automaticamente os pulmões e nódulos nas imagens de tomografia computadorizada (HUANG et al., 2019a).

Todo processo de detecção em imagens exige uma boa técnica de segmentação dos objetos, vários autores buscam aprimorar esta técnica tendo em vista a sua importância como fundamento dentro do processo de diagnóstico, como foi feito no estudo de (KASINATHAN et al., 2019) que introduziu dentro de seu modelo filtros gaussianos de várias escalas para detectar tumor pulmonar por meio de contorno ativo utilizando CNN, os autores conseguiram bons resultados com as métricas de avaliação em 89.0% referente Sensitivity e 91% referente a Specificity, levando ao aprimoramento da técnica, assim como

(LIU et al., 2019) que apresentou um método semi-supervisionado para detecção de nódulos pulmonares por meio de rede neural de transferência convolucional com base na análise de dados usando modelo modificado da rede U-Net. Técnica como a de segmentação por meio de sistemas automatizados em estruturas anatômicas nas radiografias é de fundamental importância para o sistema de diagnóstico assistido por computador, como mostra o estudo de (WANG et al., 2019) que atingiram 0,95 (mIoU: interseção média da união): 0,95 para segmentação de campos pulmonares em radiografias de tórax utilizando a Mask R-CNN.

Técnicas de segmentação usando sistemas automatizados em estruturas anatômicas em radiografias, são de fundamental importância para sistemas de diagnóstico assistido por computador (CAD) (WANG et al., 2019). atingiu em seus resultados 0,95 (mIoU: interseção média sobre a união): 0,95 para a segmentação pulmonar nas radiografias de tórax usando o Mask R-CNN.

(GORDIENKO et al., 2018) e (HUYNH; ANH, 2019) trazem estudos com treinamento em CNN baseado no modelo U-Net para segmentação pulmonar em radiografias de tórax com *accuracy* de 93%. (XU et al., 2019) propôs a segmentação do parênquima pulmonar usando um modelo CNN baseado em algoritmo de agrupamento com excelentes valores métricos como sensibilidade (0,909 / 0,906), especificidade (0,999 / 0,999) e gerou 121.728 amostras para treinamento e validação do modelo CNN. O estudo de (GHOSH et al., 2020) usou convoluções e técnicas de processamento de imagem para segmentação pulmonar, atingindo uma precisão de 97,78 % de *accuracy*, no entanto, eles usaram métodos para normalização de imagem, como pré-processamento com filtros clássicos como passa-baixo e gaussiano para normalizar as imagens de entrada de rede, reduzindo assim o ruído contido na imagem e, ajudando a melhorar significativamente os resultados obtidos no modelo.

A precisão da segmentação favorece um alto desempenho com motivação de bons diagnósticos de diferentes contextos, o estudo de (HWANG; PARK, 2017) obteve 0.964 ± 0.028 referente a métrica Dice (DC) na segmentação de TC de pulmão, os autores mostraram que por meio de treinamento inteligente com redes convolucionais podem ser alcançados excelentes desempenhos em segmentação com muito menos parâmetros, porém a otimização ainda necessita de grande quantidade de imagens para treinamento, onde os autores apresentaram em seu modelo um treinamento em cascata na busca de otimizar o processo de aprendizagem.

O aumento de aplicações utilizando CNN é notável na literatura, e isso se deve à sua eficiência na extração de dados com filtros de processamento de dados específicos e adequados para a extração ainda maior dos dados existentes. Produz informações mais complexas à medida que passa pelas camadas. No entanto, é necessário um grande número de imagens para que o treinamento possa gerar melhores resultados (SIMONYAN; VEDALDI; ZISSERMAN, 2013; ZEILER; FERGUS, 2014). Avanços recentes em estudos

e experimentos com CNNs tornaram cada vez mais popular as novas técnicas de visão computacional, segundo (GU et al., 2018). O uso de CNNs na indústria médica é cada vez mais comum, e pode ser encontrado em aplicativos inteligentes através de diagnósticos assistidos por computador para reconstrução de imagens por meio de segmentação. No entanto, ainda existem inúmeros desafios, como a segmentação automática de imagens médicas, grandes conjuntos de dados de amostra para treinamento em rede neural convolucional e a otimização de modelos com métodos de aprendizado de transferência (JAVOID; HALEEM, 2019).

Neste trabalho, é proposto explorar esses desafios, abordando a rede Mask R-CNN e técnicas de clusterização de dados combinadas com métodos de aprendizado de máquina supervisionados e não supervisionados para segmentação pulmonar em imagens de TC.

3 Fundamentação Teórica

Neste estudo é proposto um método para segmentação de imagens de TC de pulmão, usando uma abordagem de aprendizagem profunda (Mask R-CNN) baseada em métodos de aprendizado de máquina. Avaliamos a abordagem usando métodos supervisionados e não-supervisionados. Nas próximas seções deste capítulo é apresentado brevemente sobre os métodos de aprendizado de máquina, bem como as métricas de avaliação utilizadas para avaliar o método de segmentação pulmonar.

3.1 Aprendizagem de Máquina

Após a análise do estado da arte nas Seções 1 e 2, é possível notar o grande crescimento em pesquisas e aplicações relacionadas à aprendizagem de máquina na última década. Em termos gerais, a aprendizagem de máquina se trata de uma área específica da inteligência artificial, tendo como fundamento, elaboração e aperfeiçoamento de técnicas computacionais por meio de modelos de aprendizagem de modo automático, baseado em reconhecimento de padrões e tomada de decisões.(PROVOST; KOHAVI, 1998)

Segundo (SAMUEL, 1967), a aprendizagem automática é um campo de estudo que atribui a computadores, a habilidade capaz de aprender, de forma explicitamente não programável. Essa técnica se dá por meio de métodos probabilísticos baseadas em seus erros, criando previsões com base nos dados de entrada fornecidos aos modelos, identificando padrões e criando conexões entre eles no intuito de aprender a executar uma determinada tarefa sem interferência humana direta ou indireta, gerando e formalizando assim o conceito de inteligência computacional. Tais modelos utilizam análises estatísticas com objetivo de previsão de resultados para uma maior precisão, diminuindo a chance de erro referente aos dados processados. Esta metodologia pode ser definida em duas categorias apresentada na Seção 3.3 deste estudo. Métodos Supervisionados e Não Supervisionados.

A aprendizagem de máquina se fundamenta diretamente em tomada de decisões, métodos estatísticos, reconhecimento de padrões e inteligência artificial, no contexto voltado a um segmento da computação. Existe uma variedade de modelos baseados em aprendizagem de máquina (*Machine Learning*) que podem ser encontrados em meio a literatura, desde técnicas clássicas e eficientes (MOHRI; ROSTAMIZADEH; TALWALKAR, 2012) a métodos recentes baseados em aprendizagem profunda (*Deep Learning*)(LECUN; BENGIO; HINTON, 2015).

3.2 Deep Learning

A ciência trata o entendimento sobre o funcionamento do cérebro como, atividade com extrema complexidade em relação a capacidade de processamento de informação por parte dos neurônios (KOCH; TSUCHIYA, 2007). A atividade cerebral desempenha inúmeras tarefas simples que requer; percepção, reconhecimento de padrões, tomada de decisões, dentre outras tarefas afins desenvolvidas pelo corpo humano induzida por uma rede de neurônios. Baseada na rede neural, a computação aplicada a métodos matemáticos e estatísticos por meio da linguagem de programação, simula determinadas atividades de inteligência por meio de máquinas baseadas em conceitos computacionais, envolvendo a lógica computacional, probabilidade e estatística (HAYKIN, 2007).

Se tratando de Redes Neurais Artificiais (RNAs) em termos gerais, segundo (HAYKIN, 2007) compreende-se como uma máquina projetada com a finalidade de simular o funcionamento do cérebro para tomada de decisão ou realização de atividades específicas, isso se dá por meio de processamento dos dados (informação) fornecidos à rede. Com avanços do arranjo tecnológico agregado a capacidade de processamento, fez com que pesquisas proporcionassem a esta década a criação de diversas redes com capacidade de processamento profundo *Deep Learning* com excelentes resultados.

3.2.1 Convolutional Neural Network - CNN

Há pelo menos duas décadas, a *Convolutional Neural network* - *CNN* (Redes Neurais Convolucionais) vem sendo objeto de estudo em várias áreas de pesquisa para segmentação, detecção, reconhecimento de objetos e regiões aplicadas a grande quantidade de imagens, ou seja, (dados rotulados em grande escala). Porém, as CNNs foram impulsionadas após 2012 com o sucesso obtido na competição *ImageNet* que impactou diretamente no crescimento de aplicações e pesquisas, na qual foram utilizadas mais de 1 milhão de imagens, contendo mil classes distintas onde o sucesso se consolidou com os excelentes resultados (LECUN; BENGIO; HINTON, 2015). Toda essa vertente tecnológica trouxe uma revolução no campo da visão computacional, dada consequentemente também pela grande capacidade de processamento nas últimas décadas com diferentes modelos de processamento profundo, acompanhada paralelamente do crescimento de novas tecnologias voltadas ao hardware.

A rede CNN tem como proposta a aplicação de inúmeros e diferentes filtros, onde podem ser usados em dados do tipo visual, como as imagens, conservando a conexão (ligação) entre os pixels vizinhos dentro de todo o processo convolucional. Desta forma, pode se dizer que as entradas dos neurônios ocultos denominados (camada x) são feitas por um determinado subconjunto da referida camada anterior denominada de (camada $x-1$). A Figura 3 (A) ilustra a conexão entre as diferentes camadas, vale ressaltar que diante do método CNN, cada filtro f_i é replicado em cada campo visual da imagem. Sendo assim, as

unidades replicadas partilham entre si dos mesmos parâmetros; vetor, peso e polarização, formando um mapa de características apresentado na Figura 3 (B).




Figura 3 – (A)- Ilustração da ligação(conexão) entre as camadas de uma rede CNN. (B)- Representação de 3 neurônios da camada oculta interligados ao mesmo Mapa de Características. Fonte: O próprio autor.

Assim, compreende-se que o mapa de características ilustrado na Figura 3 (B) fazem parte dos 3 neurônios da camada oculta. Desta forma pode-se dizer que em cada uma das camadas ocultas é formada por diversos mapas de características. O gradiente do peso partilhado, é definido pela soma dos gradientes dos parâmetros partilhados entre si, no qual o cálculo do k-ésimo mapa de características f , onde os filtros são definidos por pesos w^k e bias b_k , conforme a equação 3.1

$$f_{ij}^k = \tanh((w^k * x)_{ij} + b_k) \quad (3.1)$$

Realizados assim, com as unidades replicadas tornam as características diretamente detectáveis, onde a partilha de pesos amplia gradativamente a eficácia sobre a aprendizagem, diminuindo também de forma gradativa o número de parâmetros a serem aprendidos. Em relação aos pesos da camada oculta, eles podem ser representados por um tensor 4D com elementos destinado a cada conjunto de mapa de características; de destino, de fonte, de posição (vertical e horizontal). Em relação às polarizações b , podem ser representadas por um determinado vetor, comportando um determinado elemento para cada mapa característico destino.




Figura 4 – Ilustração do processo de camadas convolucionais. Fonte: <[http:// deeplearning.net/tutorial/lenet.html](http://deeplearning.net/tutorial/lenet.html)>

A Figura 4 ilustra os determinados elementos pertencentes às camadas do processo convolucional. Como se pode perceber, a CAMADA $m-1$ contém 4 mapas de características e a CAMADA Oculta m obtêm especificamente 2 mapas de características denominados (f^1 e f^2). O processo de cálculo dos pixels adquiridos na saída dos 2 neurônios (f^1 e f^2) em CAMADA Oculta m representados pelos quadrados azuis e vermelhos são a partir dos pixels da denominada camada $m-1$ como apresentado na figura 4, assim, transferidas para as camadas de convolução. É importante observar que as camadas convolucionais englobam os 4 mapas de características referente a sua entrada. Desta forma, pode-se compreender que os pesos em w^0 e w^1 dos neurônios f^1 e f^2 representam tensores com peso 3D. Neste caso, a dimensão principal organiza indexando os mapas de características de entrada, assim, as duas dimensões restantes representam as localizações (coordenadas) dos pixels. Isso quer dizer que, o peso responsável por ligar todos os pixels do k -ésimo mapa de característica relacionados a CAMADA m , ao pixel de localização (coordenadas; i, j) do l -ésimo mapa de característica da CAMADA $m-1$. Vale destacar a importância do *Max-Pooling* para as Redes Neurais Convolucionais, uma espécie de agrupamento máximo em que é incumbido de dividir a imagem de entrada, fragmentando-a em conjuntos de retângulos na qual não sobrepõem, assim, para cada conjunto é gerado um valor máximo. Com essa peculiaridade o *max-pooling* depois de descartar valores que não sejam não-máximos, reduz o processo da computação para as camadas subsequentes com conexão em forma de cascata entre as camada *max-pooling* e camada de convolução.

A ilustração representada pela Figura 5, apresenta a Camada de Entrada, o *frame* representado pelo quadrado demarcado na imagem original, seguindo para as camadas convolucionais subsequentes, intercalando entre camadas de convolução e *max-pooling* efetuando o processo do cálculo da Equação 3.1. As camadas superiores apresentam-se totalmente conectadas, ou seja (Camada oculta + regressão logística, pode-se notar que




Figura 5 – Ilustração de diferentes camadas encarregadas em um processo de convolucional.
Fonte: <<http://deeplearning.net/tutorial/lenet.html>>

a entrada para a primeira camada é o conjunto de todos os mapas de características da CAMADA $x - 1$ como ilustrado na Figura 3 (B). Foi obtido como base de fundamentos em CNN o tutorial <<http://deeplearning.net/tutorial/lenet.html>>.

3.2.2 Mask R-CNN




Figura 6 – Imagem adaptada de (HE et al., 2017). Estrutura da *Mask R-CNN* para segmentação de instância (máscaras de segmentação).

A Rede Neural Convolucional recorrente do tipo *Mask*, chamada de *Mask R-CNN* (HE et al., 2017) faz parte da sequência e melhorias promissoras dos métodos de R-CNN (GIRSHICK et al., 2014), Fast R-CNN (GIRSHICK, 2015) e Faster R-CNN (REN et al., 2015). Essa abordagem possui excelente desempenho na segmentação e detecção de objetos (*bounding boxes*) em imagens digitais (HE et al., 2017), e prever máscaras de segmentação. No entanto, existem algumas limitações na *Mask R-CNN*, onde cada proposta de região exige uma aprovação completa da rede convolucional e grande uso de memória com baixa velocidade de detecção. Apesar disso, o uso do *Mask R-CNN* é justificado em situações que precisam de alta confiabilidade para a detecção de objetos.

A Mask R-CNN é uma arquitetura de Rede Neural Convolutacional baseada em *deep learning* que tem como função classificar os pixels existentes na imagem. Esse processo de classificação envolve as mais variadas camadas utilizadas pela rede, que variam de acordo com as características identificadas na imagem. Seu processo de funcionamento consiste em duas etapas: Na primeira a *Mask R-CNN* detecta a região de interesse e a demarca com uma caixa delimitadora. Na segunda etapa o método consiste na classificação dos pixels da região demarcada, nas quais durante o processo convolutacional da rede, os pixels selecionados como pertencentes da região de interesse são utilizados para a construção de uma máscara. Essa máscara representará a região detectada. Os pixels que constituem a região de interesse são adicionados na máscara através da fórmula:

$$L = Lcls + Lbox + Lmask \quad (3.2)$$

Na qual $Lcls$ representa a perda da caixa delimitadora, $Lbox$ representa as regiões idênticas e $Lmask$ representa o peso selecionado pelo algoritmo para uma melhor seleção dos pixels de interesse (HE et al., 2017).

A predição de máscaras de segmentação, denominada também de (segmentação de instâncias), é um desafio complexo, tendo em vista que é exigido no processo de detecção, a detecção exata de cada objeto contido em uma determinada imagem digital de forma simultânea. Ou seja, segmentando cada objeto contido na imagem em um único processo. No contexto deste estudo, a complexidade se dá também pela detecção de dois objetos de interesse em um único processo (2 pulmões), cujo fazem parte do sistema respiratório humano, apresentados também nas imagens de TCs. Com isso, o processo associa técnicas clássicas de visão computacional para detecção e localização de objetos, tendo como objetivo classificar individualmente os pulmões usando caixas delimitadoras com a proposta de classificar pixel a pixel regiões pertencentes a cada objeto, por meio dos conjuntos estáveis de diferentes categorias sem diferenciar instâncias de objeto na imagem (HE et al., 2017). A fim de melhorar a compreensão inicial do processo do modelo de segmentação, é necessário compreender como uma imagem digital é representada(interpretada) por uma máquina computacional.

A figura 7 apresenta diferentes interpretações referente a imagem, por meio de diferentes intensidades de cores de cinza contidos na imagem digital, variando entre 0 e 255 níveis de cinza.

As imagens de entrada na rede pertencem ao banco de dados para treinamento que serão apresentados posteriormente na seção 4.1. Sendo representadas na forma de matrizes, a rede interpreta as imagens de entrada baseada nos valores que cada nível de cinza representa, de acordo com o exemplo da figura 7. Essa variação ocorre entre os valores de 0 a 255 de acordo com a escala de representação. Dentro deste processo a matriz de valores é remodelada para um vetor de valores. Onde a partir daí, todo pixel será uma entrada para a rede. Desta forma, os atributos a serem identificados como pulmão ou não




Figura 7 – Representação da intensidade entre pixels em uma imagem. A imagem (A) representa a imagem original, a imagem (B) representa as diferentes intensidades de níveis de cinza representadas por seu valores correspondentes, na imagem (C) é extraída a imagem para simples representação dos valores dos níveis. Imagem adaptada de (YAMASHITA et al., 2018).

pulmão, (problemática de classificação dos pixels), podem indicar a região real pertencente ao objeto de interesse deste estudo.

Para encontrar a solução desta questão, é realizado dentro do modelo convoluções que possibilitam a rede o entendimento de invariância de translação ou seja, propriedades ou funções que não se modificam caso seus argumentos sofram uma translação, dentre outras palavras, entender que a região do pulmão é de fato a região do pulmão, independentemente da região em que o objeto de interesse apresente-se. O processo da *Mask R-CNN* subdivide a imagem de interesse em vários recortes, salvando-as em paralelo,

Mesmo com o processo de subdivisões na imagem sobreposta, os pesos originais são preservados. Após a subdivisão, cada recorte é processado no modelo, onde cada bloco pertencente a imagem é processado em uma rede neural de menor tamanho. Em relação aos pesos originais pertencentes a rede neural pós processo, eles são mantidos para cada bloco. Os resultados adquiridos com este processo são interpretados em novos vetores sem perda de ordenação e organização dos blocos pertencentes à imagem original, garantindo os reais valores.

A figura 8 apresenta o fluxograma da *Mask R-CNN*. O primeiro estágio, chamado *Network Proposal Region* - (Rede de Proposta de Região) - RPN (*ROi Aling*), propõe caixas delimitadoras de objetos (*bounding boxes*) candidatos e *predctz* das classes de objetos, conforme apresentado nas sub-figuras 2, 4 (a) e 4 (b) da Figura 8. O segundo estágio, paralelamente a previsão do deslocamento da classe e da caixa, a *Mask R-CNN* também gera uma máscara binária para cada objeto detectado, conforme apresentado nas

sub-configurações 3 e 5 da figura 8. Em poucas palavras, o *Mask R-CNN* substitui o *pool* da região de interesse (ROI) pelo *ROI-Align* Região de Interesse-Alinhada usado para criar máscaras de segmentação que resultem no uso da função de perda 3.2 (HE et al., 2017).

O algoritmo 1 apresenta o pseudo-código *Mask R-CNN* que retorna em sua saída; caixas delimitadoras (*bounding boxes*), classes e máscara binária.

Algorithm 1: MASK R-CNN PSEUDOCODE

Data: fileImage, trainedWeights

Result: bbox, classes, mask

```

1 inputImage = LoadImageFromFile(fileImage);
2 maskNetwork = LoadLungTrainedModel(trainedWeights);
3 [bbox, classes] = maskNetwork._classifier();
4 mask = maskNetwork._mask();
5 return [bbox, classes, mask];

```




Figura 8 – Fluxograma da Mask R-CNN. Fonte: O próprio autor.

3.3 Conceito - Métodos Supervisionados e Não Supervisionados.

Segundo (THEODORIDIS; KOUTROUMBAS, 2008), o reconhecimento de padrões se caracteriza em método supervisionado na medida em que o conjunto de dados de seu treinamento esteja disponível para exploração de informações previamente reconhecidas pelo classificador, chamado de aprendizado supervisionado.

Porém, no reconhecimento de padrões por meio de método não supervisionado, tais modelos caracterizam-se quando os dados de treinamento intitulados como (rótulos de classe) não estão disponíveis, neste contexto o modelo recebe um determinado conjunto de características com o propósito de encontrar similaridade e grupo (*cluster*) de vetores similares.

Por se tratar de Clusterização (agrupamento), o algoritmo específico de clusterização tem como premissa evidenciar os grupos (*clusters*) similares, tendo em vista que a definição do espaço e seus determinados pontos na dimensão sejam agrupados. Pontos estes que se definem de acordo com sua classificação, correspondentes ao mesmo *cluster* agrupado sendo possível de análise e identificação do tipo pertencente a sua classe, correlacionando a amostra de um determinado ponto em seu grupo, denominada Mapa.

São apresentados em seguida, métodos que foram utilizados na abordagem proposta *fine-tuning* junto a Mask R-CNN: Métodos supervisionados: Naive Bayes, SVM e Métodos Não-Supervisionados: K-means e Modelos de Mistura Gaussiana (GMMs)

3.3.1 Classificadores - Supervisionados

Naive Bayes - A probabilidade é um ramo da matemática responsável por analisar o acontecimento de fenômenos aleatórios. Em síntese, através da probabilidade é possível calcular, com poucas informações sobre determinados problemas, a probabilidade de tais fenômenos ocorrerem (MORGADO et al., 1991). Em relação aos eventos probabilísticos, podem ocorrer de duas formas: Os eventos incondicionais ocorrerem em um espaço amostral e são independentes de eventos anteriores. São expressos por $P(X)$ na qual X é o evento, e P a probabilidade de ocorrência do mesmo (sendo esse valor podendo variar entre 0 e 1) (MEYER, 1965) Já os eventos condicionais, esses dependem dos eventos anteriores para ocorrem. São dados como $P(X|Y)$ na qual podem ser interpretados como, a probabilidade da ocorrência do evento Y dada a ocorrência do evento X (MEYER, 1965).

A teoria de Bayes é uma ferramenta completa no quesito de resolução de problemas cujas informações são parcialmente desconhecida, e isso se dá pelo seu modelo proposto se basear na probabilidade condicional, na qual durante o processo de aprendizagem, a inclusão de novas variáveis influenciará diretamente na resposta ao problema (LIPSCHUTZ,

1994). A definição formal do teorema de Bayes é dada por:

$$P(A_i|B) = \frac{P(B|A_i).P(A_i)}{P(B)} = \frac{P(B|A_i).P(A_i)}{\sum_i P(B|A_i).P(A_i)} \quad (3.3)$$

Na qual os eventos A_i são os causadores do evento B , dessa forma a probabilidade da ocorrência de B se dá pela junção das probabilidades de ocorrência dos eventos A . Essas probabilidades são pré-determinadas antes do acontecimento dos eventos, para depois da ocorrência do evento B serem usadas, através da equação de Bayes, para calcular a probabilidade *a priori*. Dessa forma é atribuído aos eventos A_i a probabilidade *a posteriori* $P(A_i|B)$ (CRAMÉR; CARUSO, 1973).

De acordo com (THEODORIDIS; KOUTROUMBAS, 2008), Naive Bayes é um tipo específico de classificador baseado no teorema de Bayes, se trata de um modelo probabilístico com dependência condicional, assim, dada uma determinada ocorrência de Y , podemos encontrar a probabilidade de ocorrência do evento X . Por se tratar de método de classificação, o propósito baseia-se em construir um classificador, cujo dado um conjunto de treinamento com rótulos de classe, determinado por, E é representado por uma tupla de valores de Características $(x_1, x_2, \dots, x_n)$, em que x_i é o valor da característica X_i . Onde C irá representar a variável de classificação e c será o valor de C . Desta forma, reconhecemos neste exemplo a existência das classes; (positiva) ou (negativa).

O processo pode ser entendido da seguinte forma. Uma vez que o objetivo é maximizar a probabilidade da determinada classe de destino, por se tratar de um método supervisionado, é obtido um conjunto de dados com amostras e rotulados. Com isso é calculada a probabilidade das classes. Ou seja, estima a probabilidade da amostra pertencer a uma das classes como ilustra a Figura 9.




Figura 9 – Bayes - Ilustração da base de dados com suas respectivas amostras e rótulos. Imagem Adptada de: <https://www.globalsoftwaresupport.com/>

Com base na ilustração da Figura 9 pós treinamento, tem como finalidade classificar uma nova amostra (amostra com o ponto de interrogação). Desta forma o modelo considera as amostras vizinhas para em termos probabilísticos prevê qual seria a amostra (?) ilustrado na Figura 10.




Figura 10 – Bayes - Ilustração do processo probabilístico bayesiano. Imagem Adaptado de: <https://www.globalsoftwaresupport.com/>

Assim, a figura 10 ilustra de forma simplificada uma maior probabilidade da amostra (?), pertencente a uma determinada classe.

(SVM) Support Vectors Machine (VAPNIK, 1998) - Possui uma sólida formação matemática, sendo baseado na teoria da aprendizagem estatística. O SVM pode encontrar o melhor hiperplano de separação entre duas classes em um espaço N-dimensional (N é o número de atributos) de forma que ele tenha excelente desempenho para erros de generalização (precisão na previsão de amostras não vistas).




Figura 11 – SVM - O hiperplano da margem máxima. Fonte: O próprio autor

Apresentado por Vapnik (CORTES; VAPNIK, 1995), o modelo demonstra grande desempenho em problemas de classificação e regressões pareadas. O modelo separa o conjunto de dados de treinamento rotulados binários, por meio de um hiperplano onde

esteja ao máximo de distância entre eles, conhecida como "hiperplano da margem máxima", como mostra na figura 11.

O espaço de entrada de N pontos de dados de treinamento $(X_1, y_1), (X_2, y_2), \dots (X_N, y_N)$ pode ser separado por um *hyperplane* $H : w * X - b = 0$. O hiperplano H é localizado através da determinação de dois hiperplanos paralelos H_1, H_2 que possuem a margem máxima $2/||w||$ tendo condições esta que não haja pontos de dados entre eles.

3.3.2 Classificadores - Não Supervisionados

K-means - De acordo com (MACQUEEN et al., 1967) *K-means* é um método de *cluster* iterativo popular, que divide automaticamente amostras em grupos k . Ele funciona selecionando primeiramente os centros de *cluster*, em seguida, cada amostra é adicionada ao cluster mais próximo, como mostra a Figura 12.




Figura 12 – Apresenta etapas do método K-Means. Fonte: Müller, Guido et al. (2016)

Métodos de *clustering* não são supervisionados, em sua aprendizagem, os rótulos que podem ser agregados aos objetos do conjunto de dados de treinamento não são utilizados.

O modelo tem como premissa, descobrir e constatar o centro de regiões que representam determinados tipos de dados. o método diversifica entre atribuir a cada ponto o centro mais próximo e escolher o centro do *cluster* como a média dos pontos que foram atribuídos. (MÜLLER; GUIDO et al., 2016)

A princípio, o método inicia-se com a declaração do valor k de centros. Após a declaração os pontos são atribuídos para os centros mais próximos ("Atribuição de Pontos"). Em seguida, o centro dos *clusters* são atualizados, tornando as médias de seus pontos, seus centros recalculados. Terminando assim portanto, quando os pontos do centro se tornam estáveis, esta atribuição de um determinado ponto ao seu centro próximo, normalmente calcula-se a distância entre si, utilizando a distância euclidiana. A distância euclidiana é

calculada de cada ponto até o centro mais próximo, o valor é calculado pela soma do erro quadrático residual (SSE), como mostra a equação 3.4

$$SSE = \sum_{i=1}^k \sum_{x \in C_i} distEucli(C_i, x)^2 \quad (3.4)$$

Onde *distEucli* é a distância euclidiana entre dois pontos em um espaço euclidiano. O valor do centro que minimiza a soma dos quadrados do erro é portanto o valor médio entre os pontos atribuídos ao centro.

Modelos de Mistura Gaussiana (GMMs) assumem que as amostras são de distribuição gaussiana. Define-se k aglomerados que compreendem k funções gaussianas. Um algoritmo de otimização chamado *Expectation–Maximization (EM)* é aplicado para encontrar a forma do *cluster*, sua média e desvio padrão. (AMÉNDOLA; FAUGERE; STURMFELS, 2015)

O algoritmo Expectation-Maximization (MCLACHLAN; LEE; RATHNAYAKE, 2019) é uma função de verossimilhança, essa é dada pela fórmula: 3.5

$$p(X|\psi) = \prod_{i=1}^n p(x_i|\psi) \quad (3.5)$$

na qual $p(X|\psi)$ representa a verossimilhança, $p(x_i|\psi)$ representa a função densidade e ψ representa o vetor de parâmetros.

Normalmente é mais fácil trabalhar com o logaritmo da verossimilhança, pois esse é monotonicamente crescente, e sensível às alterações dos parâmetros. Logo a maximização do logaritmo também influirá na máxima verossimilhança (MCLACHLAN; LEE; RATHNAYAKE, 2019).

Em síntese o algoritmo Expectation-Maximization funciona da seguinte forma: a etapa Expectation calcula o logaritmo da verossimilhança com as variáveis conhecidas no problema de classificação. Posteriormente, na etapa de Maximization maximiza o logaritmo da verossimilhança para estimar os melhores parâmetros em função dos resultados obtidos da etapa de Expectation (PORTELA, 2015)

Em relação ao EM, o método (DEMPSTER; LAIRD; RUBIN, 1977) é capaz de descobrir um ótimo local da função de máxima verossimilhança da mistura gaussiana, dividindo-se em duas fases; E-Step, que calcula a probabilidade dos pontos referentes a cada Gaussiana, em seguida o M-Step, onde as componentes são maximizadas.

3.4 Modelos de Segmentação Pulmonar

É apresentado na literatura, diversos modelos para segmentação de imagens de TC de pulmão com diferentes aspectos e metodologias, a seção 3.4 apresenta alguns modelos que obtém em comum as imagens do dataset utilizada neste experimento, servindo para comparações entre os modelos. Destacamos o Balão Adaptativo de (REBOUÇAS FILHO et al., 2014), Gradient Vector Flow (GVF) de Xu e Prince (1998), o Vector Field Convolution (VFC) de Li e Acton (2006), o método Crisp proposto por REBOUÇAS FILHO (2010), como o método Crisp Adaptativo (CRAD) de REBOUÇAS FILHO et al. (2013a) e *Optimum path Snakes* (OPF) de Barros (2016). Bem como também o Sistema para a Detecção e a quantificação de Enfisema Pulmonar (SISDEP) proposto por FELIX (2007).

3.4.1 Balão

Inúmeros algoritmos fundamentados em otimização por meio de contornos ativos foram elaborados e arquitetados para o problema de segmentação. Porém, diversas aplicações ainda apresentam limitações, em relação às formas tubulares e bifurcações do objeto em imagens. Apesar de determinadas metodologias buscarem sanar certos problemas, o problema persiste em inúmeros casos aplicados a objetos de interesse iniciado a formas complexas de dimensões, delimitações e alcance de superfície, obtendo um desempenho não muito satisfatório em determinadas regiões.

Neste caso, o estudo de (REBOUÇAS FILHO et al., 2014) propôs uma otimização do método tradicional balão ACM, com o objetivo de segmentar distintas imagens, obtendo melhor desempenho com base nas limitações do método tradicional, e assim, superando suas limitações. Denominado Adaptive Balloon (AB), o método obteve ganhos significativos, porém tem demonstrado certas limitações, sobretudo em pontos onde a inicialização do processo de segmentação, inicia-se distante da região da borda do objeto de interesse. Evidenciando-se extremamente sensível à inexistência de gradiente. Neste caso, para tentar solucionar o problema, adicionaram ao método uma força interna, chamada por Cohen (1991), de Força Balão (F_{ballon}). Com base na equação 3.6, que equivale a métodos de contornos ativos, onde $E_{int}[c(p)]$ corresponde a energia interna, na qual depende das características internas à curva de segmentação.

$$E_{int}[c(p)] = \alpha(p)c'(p) + \beta(p)c''(p), \quad (3.6)$$

nos quais α e β retratam valores que ponderam a progresso de um ponto p da curva conduzindo a curvatura e a elasticidade, onde a elasticidade equivale a especificidade dos pontos distanciareem mutuamente, proporcionando a expansão da curva e a curvatura representa a flexibilidade entre os segmentos da reta, proporcionando uma ampliação ou redução de ângulos internos na região de interesse.

De acordo com a Equação 3.6, onde a força F_{ballon} é associada às forças de continuidade, proporciona o aprimoramento do cálculo sobre a energia interna. De maneira que, a força rege aumentando a região de curvatura inicial, conduzindo a curvatura até a região de influência de gradiente extremos da bórça do objeto, com base nos limites calculados.

Com isso, foi apresentado por Mackiewicz (1995) uma abordagem diferente com base no método Força Balão, propondo um vetor de curso contrário ao baricentro da curva em evolução (progresso). Desta forma, não viabilizando a concentração de áreas que não são afetadas com variações. Ainda assim, o método demonstra limitações, comparado-as a novos métodos de inicialização totalmente automáticos. O modelo se limita na medida em que o processo de inicialização começa em regiões descentralizadas, cometido pelo método ser fundamentado no vetor de curso contrário ao baricentro da curvatura, no qual, a cavidade realça a ação do vetor e o progresso dos pontos.

Apesar disso, o método ainda mostra limitações, isso ocorre quando o contorno ativo se inicia em áreas descentralizadas. Isto acontece pelo método ser fundamentado no vetor de curso contrário ao baricentro da curva, onde a concavidade acentua a atuação do vetor e a evolução dos pontos estabilizam, convergindo antes do espaço. Isso mostra a baixa adaptação às variações topológicas na imagem e seu tempo de segmentação variante maior.




Figura 13 – De (REBOUÇAS FILHO et al., 2014) Método Balão e sua evolução com inicialização no centro do objeto de interesse (Pulmão), até a evolução com inicialização próxima da área das bordas do pulmão

A Figura 13 ilustra a evolução do processo de segmentação baseado no método AB de (REBOUÇAS FILHO et al., 2014), e seu resultado apresentado pela Figura 14




Figura 14 – Resultado da segmentação gerado por (REBOUÇAS FILHO et al., 2014) (Método Balão), com contorno do pulmão esquerdo na imagem de TC.

3.4.2 Gradient Vector Flow (GVF)

Após apresentar o Método Balão e sua nova abordagem, é possível avaliar o desempenho de seu processo em relação ao método GVF *Gradient Vector Flow* no que se refere a segmentação dos pulmões em imagens de TC, a primeira limitação é a inicialização da curva fora dos pulmões, por conta da variedade de formas dos pulmões e suas diferentes estruturas, como escolha de nível de corte da visualização, realizado pelo exame tomográfico, ou diferentes tamanhos de suas estruturas, variadas pelos diferentes pacientes e inúmeras imagens sequenciadas como mostra a Figura 1.

Com o propósito de superar certas limitações do Método Balão tradicional, no que se refere a curvatura nas bordas do objeto de interesse, (REBOUÇAS FILHO et al., 2013a) apresentou um método baseado na expansão de fluxo gradiente a partir de uma determinada imagem, como apresentou o estudo de Xu e Prince (1998) que tem como premissa utilizar vetores de gradiente com a finalidade de adaptar o desempenho e comportamento da curva em regiões com contornos de baixas demarcações, denominado de *Gradient Vector Flow*, ou (GVF).

A metodologia é baseada em campo de vetores, o campo é definido pelo do fluxo do gradiente derivado das regiões do objeto de interesse (Bordas do pulmão). Neste caso, os vetores apresentam na mesma direção onde advém as significantivas variações e mudanças de intensidade localizada no objeto contido na imagem. desta forma, o método utiliza a energia externa apresentada pelo modelo de contorno ativo tradicional, apresentando-se como solução uma nova energia externa sendo proporcional ao ∇f , sendo f a imagem a ser segmentada então ∇f é o vetor gradiente de f , sendo assim, a energia calculada através do vetor gradiente é o valor que aponta a existência de aumento na alteração de intensidade na região do pulmão.

No contexto do método proposto, compreende-se que a curva é realizada de maneira iterativa, diminuindo a energia funcional E_{gvf} estabelecidas de acordo com as u e v , sendo as mesmas, responsáveis por calcular as derivadas parciais sobre as coordenadas x e y :

$$E_{gvf} = \int \int \mu \left(\frac{\partial u^2}{\partial x} + \frac{\partial u^2}{\partial y} + \frac{\partial v^2}{\partial x} + \frac{\partial v^2}{\partial y} \right) + |\nabla f|^2 |w - \nabla f|^2 dx dy, \quad (3.7)$$

onde w representa o fluxo de gradiente estabelecido $w(x, y) = [u(x, y), v(x, y)]$, contudo, a variável μ permite regular, ajustando o equilíbrio dentre os dois termos e ajustando-se a atuação de influência do campo de fluxo gradiente.

No momento em que ∇f é extremamente pequeno em regiões equivalentes, a energia adquirida decorre das derivadas parciais do fluxo de vetores, mostrando um campo com menor alteração. Com isso, o campo de vetores, envolve o progresso evolutivo da curva, alcançando as borda.

Porém, o método também apresenta restrições, certas limitações ao iniciar em regiões não próximas ao centro do objeto de interesse. Como apresenta o estudo de REBOUÇAS FILHO et al. (2013a), o trabalho apresenta soluções neste contexto, no entanto somente inicializa no ponto externo ao lado do objeto. Assim, o progresso da curva e em sua evolução, mantém-se em conformidade com o campo do gradiente, atraindo para o contexto de sumo fluxo. Em consequência, regiões distantes da borda não são alcançadas o campo de vetores, impedindo a curva e seu real percurso referente a borda do objeto, como mostra a Figura 15.




Figura 15 – Resultado da segmentação gerada pelo método Gradient Vector Flow - GVF em imagens de pulmão de TC.

A Figura 15 apresenta, diferentes imagens de TC de pulmão em diferentes contextos e formas, as imagens são segmentadas usando o método GVF. no qual não é suficiente para aproximar a curva até a borda do objeto, chegando o mais próximo da região delimitada. Pode-se identificar a desenvoltura do modelo para a segmentação do pulmão, no entanto apresenta imprecisões em determinados pontos dependendo da imagem ou forma do objeto. Com base no método, estudos precedentes como o de REBOUÇAS FILHO et al. (2013a), REBOUÇAS FILHO (2010), concluíram sobre o método GVF, mostrando um custo computacional aproximadamente 30 vezes mais demorado (limitações no tempo de segmentação) em comparação ao Método Balão.

3.4.3 Vector Field Convolutional (VFC)

O método *Vector Field Convolutional - GVF*, adquiriram grande popularidade devido à capacidade de solucionar problemas surgidos em modelos anteriores ao contorno ativo. O modelo também denominado campo vetorial convolucional, tem como base uma nova abordagem relacionados a energias internas referente ao método de contorno ativo convencional, apresentada no trabalho de Li e Acton (2006), o estudo propõe uma nova energia externa fundamentada na convolução entre o campo de vetores $k_{vfc}(x, y)$ com o mapa de bordas $f_{vfc}(x, y)$, a consequência realizada pela convolução é uma imagem $I(x, y)$, no qual representa a nova energia externa E_{vfc} .

O campo de vetores pode ser representado da seguinte forma, onde $k_{vfc}(x, y) = m_k(x, y)n_k(x, y)$, onde $m_k(x, y)$ é a magnitude do vetor na posição (x, y) e $n_k(x, y)$ é o vetor unitário para a origem do núcleo. Desta forma, apresentado por Li e Acton (2006), o vetor do núcleo pode ser compreendido por $n_{vfc}(x, y) = [-\frac{x}{r}, -\frac{y}{r}]$, no qual r é o raio do núcleo em relação à origem, em que $n(0, 0) = [0, 0]$. Em síntese, a nova energia E_{vfc} é determinada na seguinte equação:

$$E_{vfc} = k_{vfc}(x, y) * f_{vfc}(x, y) \quad (3.8)$$

Dessa forma, a vantagem do método VFC, fundamenta-se no custo computacional comparado a outros métodos tradicionais, incluindo o modelo GVF. Porém, diferente dos métodos anteriores, o método Vector Field Convolutional apresenta limitações por meio de perdas, ou seja, redução na sensibilidade no ponto onde inicia-se curva, além da robustez quando submetido a imagens com ruídos gaussianos e impulsivos. A Figura 16 ilustra a segmentação, bem como a limitação do método em regiões sensíveis próximo ao contorno.




Figura 16 – Resultado da segmentação gerada pelo método Vector Field Convolutional - VFC em imagens de pulmão de TC.

Desta forma, como se pode notar, o modelo indica tendências possíveis de falha, onde não apresenta uma boa definição do objeto como um todo, ressaltando o contorno referente ao objeto e sua precisão na segmentação das bordas. Apresentando dificuldades ainda mais em casos no qual exista dois objetos de interesse próximos, ficando claro também pela sua limitação em certas regiões.

3.4.4 Crisp Adaptativo (CRAD)

O estudo realizado para elaboração do método Crisp Adaptativo (CRAD), teve como base o trabalho de REBOUÇAS FILHO (2013), no qual, buscou um aperfeiçoamento fundamentado em suas técnicas proporcionando robustez e melhores resultados com base na segmentação de objetos em imagens. O trabalho se empenhou nas limitações de inicialização descentralizadas realizadas pelos modelos e internas a região pretendida, ou seja, a região de interesse, sendo o objeto (pulmão), como fora apresentada nos métodos anteriores (GVF e VFC). Como o intuito de segmentar a região de interesse com mais precisão, o método Crisp Adaptativo - CRAD é baseado na modificação da energia externa, alterando a Força Balão, colocando a nova força chamada de (Adaptativa), que da mesma forma altera a energia do método E_{crisp} colocando a nova adaptação E_{crad} .

O método CRAD de (REBOUÇAS FILHO, 2013), que se fundamenta em duas energias (novas), onde se determina uma nova energia que conduz a evolução da curva de segmentação. Desta forma, a energia total em um ponto $c(s)$ da curva, pode ser estabelecida como E_{CRAD}

$$E_{CRAD}[c(s)] = E_{int_{adap}}[c(s)] + E_{ext_{CRAD}}[c(s)], \quad (3.9)$$

no qual $E_{int_{adap}}$ significa a energia interna adaptativa e $E_{ext_{CRAD}}$ significa a energia externa Crisp Adaptativa (CRAD).

O modelo proposto utiliza dados da topologia da curvatura com objetivo de gradativamente tornar maior o contorno, no o intuito de expandir até as bordas do objeto buscando mais exatidão em seu contorno. Desta forma, o uso dos dados funcionam como informação para cada ponto, partindo da ideia de que a curva apresenta formas diferentes durante a sua topologia. Desta forma, a força Balão Adaptativa transfere cada ponto da curva de maneira diferente em direção às bordas do objeto de interesse, adaptando-se à região em que está inserido.

Assim, em conformidade com (REBOUÇAS FILHO, 2013), a energia $E_{int_{adap}}$ pode ser determinada pela equação:

$$E_{int_{adap}} = w_{cont}F_{cont}[c(s)] + w_{adap}F_{adap}[c(s)], \quad (3.10)$$

onde a primeira componente é a mesma força de continuidade usada pelo modelo convencional proposta por Kass, Witkin e Terzopoulos (1988), já a segunda componente $F_{adap}[c(s)]$ é a nova força denominada de CRAD, onde os parâmetros w_{cont} e w_{adap} são pesos relativos a cada força distinta.

No que se refere ao cálculo estipulado pela nova força interna, os dados utilizados como informação sobre a topologia dos pontos, são geradas com base em duas informações. Uma, baseada nas coordenadas de vizinhos imediatos, sendo a outra na forma geral da curva.

Fonte: Imagem adaptada de REBOUÇAS FILHO et al. (2013b)




Figura 17 – Ciclos do método Crisp Adaptativo - CRAD (REBOUÇAS FILHO, 2013), baseado em Energias adaptativas.

Por outro lado, em relação à energia externa o Crisp apresentou limitações relacionados a pontos de estruturas internas do pulmão, como hilo e vasos internos, o modelo passou a classificar com erros, determinados pontos referentes às bordas do pulmão. Ao modelo, foi proposto a energia externa $E_{ext_{CRAD}}[c(s)]$, inserindo uma Rede Neural Artificial denominada Rede Perceptron Multicamadas (MLP), com métodos de classificação supervisionado, a fim de determinar a origem de cada borda encontrada no objeto de interesse. Os resultados da etapa referente à classificação das bordas encontradas em imagens de TC do tórax, no qual são ou não os limites pertencentes ao pulmão, onde a energia externa pode ser representada pela seguinte equação:

$$E_{ext_{CRAD}}(x, y) = \begin{cases} S(x, y), & \text{para } f_{mlp}(u) = 1, \\ 1, & \text{caso contrário,} \end{cases} \quad (3.11)$$

no qual $S(x, y)$ representa o operador Sobel, e u representa o vetor de percentuais das classes de densidades. Assim, o modelo CRAD se predomina em sua força que é sendo bastante relevante para expansão da curva, especificamente em regiões que contidas com características homogêneas, ou seja, iguais. Visto que, a força externa é nula e as únicas forças que interferem na curva são as forças internas. Diante disto, a Força Adaptativa

adultera o contorno deformando com o objetivo de aproximar-se das bordas após diversas iterações. A figura 17 ilustra os ciclos do método CRAD.

3.4.5 Optimum path Snakes (OPS)

O método Optimum Path Snakes (OPS), é fundamentado na teoria dos contornos ativos, com base na energia interna e externa, tendo como referência conceitos e princípios embasados no classificador Optimum-Path Forest, com a análise de vizinhança de cada ponto, utilizando características e concepções da teoria dos grafos. O modelo elaborado teve o intuito de solucionar as limitações encontradas em metodologias tradicionais de segmentação, que apresentam resultados não satisfatórios ou inconsistentes, com o objetivo de propor um método adaptativo em imagens digitais e médicas, livre de parâmetros.

De acordo com trabalho realizado por (BARROS, 2016), um determinado ponto $c(p)$ é capaz de analisar sua vizinhança e definir o caminho ideal, ou seja, melhor para detectar o objeto de interesse com a base em sua região. Desta forma, cada ponto da curva c , denominado de ponto explorador, onde o ponto explorador é o elemento que sabe o que está a procura, no entanto não sabe o que irá encontrar no percurso de mobilidade até o objeto esperado. A energia total estabelecida pelo OPS pode ser compreendida pela equação

$$E_{OPS}[c(p)] = E_{intOBA}[c(p)] + E_{extOP}[c(p)], \quad (3.12)$$

onde, $E_{intOBA}[c(p)]$ representa a energia interna ótima na qual define o melhor trajeto para que um ponto explorador possa aumentar, expandindo a curvatura, indicando com precisão a força interna denominada Balão adaptativa - F_{OBA} .




Figura 18 – A imagem ilustra a inicialização do modelo OPS até o ponto de segmentação final, delineado pelas margens de cor azul. Fonte: Adaptado de Barros (2016).

As imagens representada na figura 18, apresenta a evolução do contorno OPS para segmentação pulmonar em imagens de TC com até 25 interações. Os pontos de cor azul

crecentes representam o crescimento baseado na estrutura elaborada, em busca da parede pulmonar, delineando o objeto de interesse na imagem.

O modelo exibe uma curva em conformidade com a aplicação da F_{OBA} , com a ampliação dos pontos, a partir do ponto médio dos vizinhos, M_{OB} e M_{EG} . Os pontos das regiões verdes, isso por se tratar de serem internos à curva, ou seja, já explorados, obtêm um curso alto, que impossibilita a exploração em regiões já visitadas. No caso, a energia externa $E_{extOP}[c(p)]$, é definida pelo conhecimento adquirido que conduz cada ponto explorador, este conhecimento é apreendido por meio do classificador OPF adaptado a um extrator de características ADTH (Análise da Densidade do Tecido Humano), sendo um aprimoramento do ADP.

3.4.6 SISDEP

Baseado em técnicas clássicas, o SISDEP foi criado baseado em métodos de Processamento Digital de Imagens combinados a métodos tradicionais, o sistema tem o intuito de agregar ferramentas capazes de segmentar o pulmão de forma automática, bem como o parênquima pulmonar, incluindo as medidas de área de secção dos pulmões em imagens de TCAR, densidade pulmonar média (DPM), percentual de áreas hiperaeradas compatíveis com enfisema - área relativa das unidades de volume.

Ao modelo foi adicionado uma ferramenta complementar, denominada "máscara colorida", com o objetivo de realçar pontos de densidades que se encontram em faixas pré-definidas pelo operador do sistema. A ferramenta apresenta as várias faixas de densidade encontradas na imagem do pulmão, destacando as áreas hipoaeradas de difícil percepção ao olho humano em relação a escala de tons de cinza. O modelo busca com precisão a segmentação com exatidão áreas referentes ao pulmão em imagens de (TCAR) tomografia computadorizada de alta resolução, densidade pulmonar média (DPM), determinando um percentual de regiões hiperaeradas compatíveis com enfisema.

Em relação aos parâmetros utilizado pelo modelo, foi definido alguns padrões como o limiar de -950 UH, onde passou ser adotado por ser validado microscopicamente, sendo adequado a cortes finos com medições de (1-2 mm de espessura) em TCAR em quantificação de enfisema como é apresentado no trabalho de FELIX (2007), mostrando a eficiência em realizar a segmentação automática em imagens de pulmões em TC, bem como extração da dimensão da área.

A figura 19, apresenta a imagem de TC de pulmão saudável, aplicado o método SISDEP, onde o sistema detecta a região da borda do pulmão, contornando-o com a demarcação de cor vermelha, onde se pode notar a existência de pontos de imprecisão em regiões próximas à borda do objeto de interesse. vale ressaltar que os resultados podem variar de acordo com a dificuldade, tanto em relação aos tipos de possíveis patologias



Figura 19 – Resultado gerado pelo método SISDEP, com o objetivo de segmentar o pulmão em TC. Fonte: Imagem adaptada de Felix et al. (2009)

contidos na imagem, quanto a fisionomia do formato do pulmão em seus diferentes aspectos e tamanhos.

Os métodos apresentados a esta Seção 3.4: (Balão, GVF, VFC, CRAD, OPS, SISDEP) são similares em relação ao propósito de segmentação em imagens de TC de pulmão. Relativos acerca das problemáticas em comum, os métodos serviram como base de comparação entre métodos e valores obtidos entre as métricas de avaliação, bem como também o uso em comum da base de dados. Desta forma, os métodos aqui apresentados foram escolhidos por terem como objetivo principal a segmentação de imagens do pulmão, tornando a comparação com o método proposto uma abordagem com mais precisão e confiabilidade.

3.5 Métricas de Avaliação

Foram utilizadas algumas métricas de segmentação para avaliar os experimentos, bem como validar o método proposto comparando-o com trabalhos relacionados. As métricas são descritas nesta subseção.

3.5.1 Ajuste de posição - (*Position adjustment*)

Com base nas desigualdades da abscissa média (xd) e da ordenada (yd), onde Fit_{xy} é o ponto central de cada área, ele avalia a medição com precisão ajustando A_k e A_l (DELVES et al., 1992).

$$Fit_{xy} = 1 - \frac{xd + yd}{2}, \quad (3.13)$$

onde xd e yd são dados por $xd = \frac{|\bar{X}_{A_k}| + |\bar{X}_{A_l}|}{M}$ e $yd = \frac{|\bar{Y}_{A_k}| + |\bar{Y}_{A_l}|}{N}$. Com $\bar{X}_{A_k}$; $\bar{X}_{A_l}$; $\bar{Y}_{A_k}$ e $\bar{Y}_{A_l}$ são a média de abscissa de X e a área ordena A_k e A_l . M e N são as dimensões da imagem.

3.5.2 Ajuste de intensidade - (*Intensity adjustment*)

Fit_i é a razão entre a variação média sobre as intensidades do nível de cinza pertencentes às áreas da imagem k_n e l_m (DELVES et al., 1992). Essa métrica é delimitada em $[0, 1]$ quando se aproxima de 1, indica uma alteração de baixa intensidade; caso contrário, terá alta variação,

$$Fit_i = 1 - \frac{|\bar{I}_{A_k} - \bar{I}_{A_l}|}{|\bar{I}_{A_k}| + |\bar{I}_{A_l}|} \quad (3.14)$$

onde I_{A_k} e I_{A_l} são as intensidade média(s) dos níveis de cinza das áreas A_k e A_l .

3.5.3 Ajuste de tamanho - (*Size adjustment*)

Fit_m é dado pela razão entre a desigualdade de A_k e A_l com sua soma (DELVES et al., 1992). Essa métrica é delimitada em $[0, 1]$. Se o valor tende a 1, significa que as áreas se assemelham; no entanto, se tende a zero, haverá um aumento na desigualdade entre as áreas. Como mostrado na Equação 3.15.

$$Fit_i = 1 - \frac{[\bar{A}_k - \bar{A}_l]}{[\bar{A}_k] + [\bar{A}_l]} \quad (3.15)$$

3.5.4 Coeficiente dos dados - (*Dice's coefficient*)

O coeficiente dos dados (DC) é usado para medir a similaridade entre as regiões segmentadas automática e manualmente, e é definido como. Neste métrica a segmentação proveniente do algoritmo e a segmentação do especialista são comparadas por sobreposição.

$$DC = 2 \times \frac{|S_m \cap S_t|}{|A_k| + |A_l|}, \quad (3.16)$$

Conforme mostrado na Equação 3.16, S_m significa a região segmentada automaticamente e S_t o padrão de referência. Quando o valor de sobreposição dos intervalos é igual a 0, não há sobreposição entre as duas regiões, enquanto que quando é igual a 1, a sobreposição é perfeita (DICE, 1945). O valor DC aumenta juntamente com a semelhança entre a região segmentada e a verdade básica (QIAN et al., 2013).

3.5.5 Sensibilidade e Especificidade - (*Sensitivity and Specificity*)

Sensibilidade, ou recall, calcula o número de positivos reais corretamente detectado. A sensibilidade refere-se à capacidade do sistema de detectar corretamente as amostras que realmente pertencem à classe desejada. Ou seja, a capacidade do método de identificar corretamente as regiões que verdadeiramente pertencem à região do pulmão.

Especificidade (negativo real) calcula o número de negativos reais que foram detectados corretamente (FAWCETT, 2006).

$$Sensitivity = 1 - \frac{TP}{TP + FN} = \frac{TP}{PixelsDoPulmão}. \quad (3.17)$$

$$Specificity = \frac{TN}{TN + FP} = \frac{TN}{PixelsDoPulmão}. \quad (3.18)$$

onde TP significa Verdadeiro Positivo, FN significa Falso Negativo, TN significa Verdadeiro Negativo e FP são os pixels de Falso Positivo.

3.5.6 Precisão - (*Accuracy*)

Accuracy (Precisão), é o número de ocorrências positivas em P dividido pelo número total de amostras N (FAWCETT, 2006). Ou seja, é a relação entre as respostas do algoritmo e o conjunto das possibilidades de erros. Essa medida avalia os acertos do algoritmo em relação ao total de amostras apresentadas, indicando desta forma, a proximidade dos resultados obtidos daqueles desejados. Podendo ser compreendida pela equação:

$$Accuracy = \frac{P}{P + N}. \quad (3.19)$$

4 Método Proposto

Esta seção apresenta o conjunto de dados das imagens de TCs de pulmão utilizadas neste experimento, bem como a metodologia proposta para tipos específicos de métodos supervisionadas e não supervisionadas.

4.1 Conjunto de Dados

O conjunto de dados usado neste estudo é um conjunto de 39 exames de tomografia computadorizada de pulmão (CT) no formato Digital Imaging and Communications in Medicine (DICOM). Cada exame tem aproximadamente ≈ 333 imagens, portanto, o conjunto de dados é composto por 13.000 imagens: 512 x 512 pixels e resolução de 16 bits. Dessas 13.000 imagens, 1.265 foram segmentadas por um especialista, onde são denominadas na literatura de ground truth. O conjunto de dados foi obtido em colaboração com o Hospital Walter Cantídio da Universidade Federal do Ceará (UFC), Brasil, analisado e aprovado pelo Comitê de Ética em Pesquisa. Comitê - COMEPE (Protocolo nº 35/06), dentro dos parâmetros exigidos pela Resolução 196/96 do Conselho Nacional de Saúde. Esse mesmo conjunto de dados também foi usado em alguns dos trabalhos relacionados relatados neste estudo (REBOUCAS; SARMENTO; FILHO, 2015; RAMALHO et al., 2016; REBOUCAS FILHO et al., 2014; FILHO et al., 2017; FILHO et al., 2019).

Os experimentos foram realizados com as 1.265 imagens (ground truth) que contém a verdade já segmentada por um especialista. Além disso, as imagens foram utilizadas sem nenhum pré-processamento aplicado no modelo proposto, tornando-o totalmente automático. Foram utilizadas 998 imagens para treinamento do modelo, o que corresponde a 80% do conjunto de dados.

4.2 Metodologia

Este trabalho aborda um novo método baseado em fine-tuning para segmentação automática de pulmão em imagens de TC. Uma rede baseada em *deep learning* (Mask R-CNN) especializada no mapeamento de regiões pulmonares com o uso de classificadores aplicados no último estágio da Mask R-CNN é proposta neste estudo, com intuito de segmentar a região pulmonar com maior precisão e robustez. O método utiliza modelos supervisionados e não supervisionados para atingir melhores resultados. A Figura 20, apresenta o método proposto e suas respectivas etapas.

A Figura 20.A) apresenta o treinamento do modelo baseado na rede Mask R-CNN

projetada para mapear regiões pulmonares em imagens de TC. O conjunto de treinamento atua como a verdade básica, pois utiliza apenas imagens já segmentadas por um especialista como base de seu treino, denominadas de Padrão Ouro (Ground Truth), o conhecimento gerado pelo modelo Mask R-CNN é armazenado no final do treinamento. Com isso são armazenados ao treinamento, os pesos gerados pelo resultado para o processo de *fine-tuning*.

A Figura 20 .B) mostra o resultado do mapeamento pulmonar gerado com base em uma nova imagem pulmonar utilizando o conhecimento armazenado (adquirido) pelo modelo Mask R-CNN para detecção do pulmão na etapa anterior. A Equação 4.1 explica o ponto do mapa do pulmão. $MapaPulmonar(x, y)$ retorna 1 quando o Mask R-CNN encontra uma região pulmonar (Região pulmonar) e 0 caso contrário (região de segundo plano), denominadas (Região Não Pulmonar).

$$MapaPulmonar(x, y) = \begin{cases} 1, & \text{Região do Pulmão} \\ 0, & \text{Região Não Pulmonar} \end{cases} \quad (4.1)$$

Nas subseções a seguir, são apresentados as abordagens de *fine-tuning* (Continuação direta do treinamento da rede Mask R-CNN onde cada mapa é retreinado) por meio de métodos supervisionados e não supervisionados com uso do Mapa Pulmonar gerado pelo modelo Mask R-CNN. A abordagem supervisionada está na Etapa 2.C paralela à abordagem não supervisionada, Etapa 2.D. Ao final de ambas as abordagens, os resultados dessas etapas são as segmentações da região pulmonar na imagem de entrada, ou seja, resultado da aplicação do método proposto.




Figura 20 – Fluxograma do novo método para segmentação automática do pulmão em imagens de TC, utilizando a Mask R-CNN com um kernel para mapear a extração de características usando métodos supervisionados e não supervisionados de aprendizado de máquina. Fonte: O próprio Autor.

4.3 Metodologia - Modelo Supervisionado e Não-Supervisionado

Nesta subseção será apresentado a segunda etapa do método baseado em modelos supervisionados correspondente aos *kernels*: Bayes e SVM, e respectivamente os modelos baseados em métodos não supervisionados correspondente aos *kernels*: GMMs e Kmeans. Desta forma, com o uso dos pesos gerado pela rede *deep learning*, agregado aos kernels, reformula o processo do resultado da rede com o uso de *fine-tuning* para um refinamento dos dados. Isso ocorre com propósito de melhorar a precisão da delineação (segmentação) referente às bordas do pulmão.

4.3.1 Método - Modelo Supervisionado

Antes de tudo, é necessário calcular o mapa pulmonar máximo e mínimo para obter as regiões internas e externas ao pulmão para os métodos supervisionados, que são apresentados na Figura 20.C). Portanto, uma dilatação morfológica foi aplicada para determinar o mapa pulmonar máximo com base no mapa original. Em seguida, extrapola a região pulmonar após a dilatação usando a morfologia matemática, como mostra a Figura 20.Ca). A região vermelha indica o resultado da operação morfológica.

Ao mesmo tempo, uma erosão morfológica é aplicada ao mapa original gerado pela rede Mark R-CNN para calcular o mapa pulmonar mínimo, ou seja, a região interna de todo o pulmão, vista em verde na Figura 20.Ca).

Um *Kernel* convolucional foi determinado automaticamente para essas operações morfológicas. Isso é essencial, pois a dificuldade de segmentação pulmonar se deve à variação no tamanho do objeto de interesse durante toda a tomografia clínica. As imagens da TC são capturadas nos pulmões enquanto o sistema respiratório está em operação normal e contínua do corpo; O sistema respiratório humano desenvolve naturalmente sua atividade: Inspiração responsável por inflar os pulmões e expirar causando o efeito oposto de desinflar, isso resulta em imagens pulmonares (cortes de TC) de diferentes tamanhos. Este Kernel convolucional é representado na Equação 4.2; no entanto, é necessário primeiro calcular o $Mapa_{Densidade}$, que corresponde ao número de pontos no mapa do pulmão igual a 1.

$$kernel = (Imagem_{Altura}) \frac{Mapa_{Densidade}}{Imagem_{Tamanho}} \quad (4.2)$$

O polígono mais externo, usando o mapa pulmonar máximo, e o mais interno, usando o mapa pulmonar mínimo, devem ser encontrados para localizar os pontos-chave do pulmão. Assim, o polígono mais externo do mapa pulmonar máximo retorna pontos externos ao pulmão, e o polígono mais interno do mapa pulmonar mínimo retorna pontos internos ao pulmão, com parâmetro mínimo de 3x3. O resultado é mostrado na Figura 20

.Cb), onde os pontos verdes representam os pontos-chave internos e os vermelhos os pontos externos do pulmão. A Figura 23 da na Seção 5 referente aos Resultados, é apresenta o pulmão com suas regiões definidas baseada na equação.

Por fim, a Figura 20.Cc) mostra o modelo realizando o treinamento dos métodos supervisionados com base no aprendizado de máquina, especificamente para segmentação pulmonar. O treinamento ocorre usando a densidade pulmonar encontrada pelos pontos-chave previamente calculados, como os atributos de entrada. Os pontos externos ao pulmão são da classe 0 e os internos da classe 1. Portanto, o treinamento é realizado usando métodos clássicos de classificação e retorna quais pontos da imagem pertencem às regiões pulmonares apresentadas na Figura 20.Cd). Desta forma, os classificadores supervisionados, recebem o valor RGB de cada ponto, onde as classes são a própria cores (Vermelha e Verde), desta forma a regra de adesão para o Crescimento de Região aplicado é o próprio classificador.

4.3.2 Método - Modelo Não-Supervisionado

Como mostra a Figura 20.Da), o agrupamento (a clusterização) baseado nas faixas de densidade pulmonar foi aplicado com um *kernel* definido k para os métodos não supervisionados. Depois disso, o mapa pulmonar é usado para calcular o histograma na imagem "clusterizada"(realizando a contagem dos pixels e seus respectivos valores), apenas nas regiões detectadas como pulmonares. Portanto, o histograma da imagem é calculado apenas em regiões que $MapaPulmonar(x, y) = 1$, conforme apresentado na Figura 20.Db).

O *cluster* que atingir o valor máximo no histograma da imagem em *cluster* deve ser encontrado para localizar o *cluster* k mais provável que melhor se ajusta às regiões pulmonares *MapaPulmonar*. Como solução, o ponto de inflexão da curva do histograma é calculado para determinar o melhor *cluster* que representa o caso de $MapaPulmonar(x, y) = 1$.

Por fim, aplicamos um crescimento de região na imagem do *cluster*. O melhor *cluster*, previamente definido pelo ponto de inflexão da curva do histograma, foi definido como regra de adesão. Consequentemente, o valor atual na imagem agrupada é sempre igual à regra de adesão em que a região é segmentada como pulmonar, como mostra a Figura 20 .Dd).

5 Resultados e Discussão

Esta seção descreve como as experiências foram configuradas, bem como os resultados. Os resultados são apresentados em duas etapas. O primeiro passo corresponde aos resultados e discussão dos modelos propostos por nossa metodologia. Na segunda etapa, comparamos nosso melhor modelo com dois trabalhos relacionados. Os resultados são apresentados em termos de custo computacional, bem como métricas de segmentação.

5.1 Configuração e Experimento

As experiências foram realizadas, reproduzidas e testadas em laptops pessoais com as seguintes configurações: processador Intel Core i7 a 2,9 GHz, 8 GB de RAM, GPU NVIDIA GeForce GTX 1050 TI com Ubuntu 16.04.

Os experimentos foram realizados para avaliar e validar a proposta deste estudo: Mask R-CNN usando métodos de aprendizado de máquina supervisionados e não supervisionados, com os *kernels* do Mask R-CNN. A estrutura de detecção de objetos do Tensorflow (ABADI et al., 2015) suportou a implementação da Mask R-CNN. A abordagem proposta foi configurada usando o modelo Faster R-CNN Inception V2 como extrator de recursos, com uma taxa de aprendizado de 0,0002 e um tamanho de lote de 1 para 2 classes durante as 1000000 etapas.

O primeiro passo tem como objetivo identificar qual dos modelos supervisionados e não supervisionados obteve o melhor desempenho. Os classificadores utilizados foram Bayes e SVM, que representaram os métodos supervisionados, e os classificadores K-means e GMM, que representaram os métodos não supervisionados. Todos os dados para precisão e medidas de tempo de execução foram registrados, juntamente com as métricas: *Position Adjustment*, *Intensity Adjustment*, *Size Adjustment*, *Dice*, *Sensitivity*, and *Specificity*. As experiências foram conduzidas usando as imagens de TC pulmonar descritas na Seção 4.1.

A classificação pelos métodos K-means e GMM foi testada com 2 a 10 grupos e os melhores resultados foram utilizados apenas dois grupos. Os hiperparâmetros SVM foram escolhidos usando as técnicas de validação cruzada de 10 vezes com pesquisa aleatória (BERGSTRA; BENGIO, 2012). Usamos a função base radial do *kernel* (RBF) para o classificador SVM e adotamos o intervalo $[2^{-15}, 2^{33}]$ para os γ e $[2^{-5}, 2^{15}]$ por C . O classificador Bayes foi validado usando a distribuição de probabilidade Gaussiana Normal.

O segundo passo visa validar nossos experimentos de segmentação pulmonar, comparando nosso melhor modelo com os trabalhos de (REBOUÇAS FILHO et al., 2014; FILHO et al., 2019); Kernel (Mask + K-means) nas imagens pulmonares usadas nos experimentos de (REBOUÇAS FILHO et al., 2014; FILHO et al., 2019).

5.2 Discussão

Os resultados da segmentação de cada modelo foram apresentados na Figura 21, onde é possível observar visualmente como o *kernel* trouxe ganhos significativos ao verificar os contornos coloridos no objeto de interesse (pulmões). Os resultados dos modelos supervisionados (Bayes, SVM) são apresentados primeiro, e os modelos não supervisionados (GMMs e kmeans) são as duas últimas linhas da figura. Os modelos não supervisionados mostraram-se mais adequados e geraram melhores resultados para a segmentação da TC pulmonar, onde o modelo Mask-K-means foi o melhor entre os modelos criados.




Figura 21 – Resultados da comparação entre os modelos de nossa metodologia utilizando *deep learning* para gerar mapas dos pulmões com os *kernels* criados. a) imagem de entrada, b) Mask+Bayes, c) Mask+SVM, d) Mask+MMGs e) Mask+K-means

Os resultados das métricas são apresentados na Tabela 1, onde pode se notar que todos os modelos baseados em nossa metodologia superaram o resultado gerado pelo Mask R-CNN sem o *kernel*, mostrando assim que o *kernel* trouxe ganhos significativos no desempenho de cada modelo. Entre os métodos supervisionados, o modelo Mask+SVM destaca-se com melhores resultados na segmentação. No entanto, os modelos baseados em

Tabela 1 – Métricas de avaliação de segmentação usando o Mask R-CNN, com métodos de aprendizado de máquina supervisionados e não supervisionados, com seus respectivos kernels.

Métricas	Abordagens				
	Mask R-CNN	Mask + Bayes	Mask + SVM	Mask + K-means	Mask + EM
Position Adjustment	97.82 $\pm$ 4.05	98.41 $\pm$ 2.18	99.15 $\pm$ 2.11	99.21 $\pm$ 2.44	98.94 $\pm$ 2.92
Intensity Adjustment	96.17 $\pm$ 5.82	96.18 $\pm$ 7.17	98.33 $\pm$ 3.60	99.40 $\pm$ 1.34	99.10 $\pm$ 2.83
Size Adjustment	95.03 $\pm$ 8.00	87.64 $\pm$ 12.52	95.91 $\pm$ 5.98	97.62 $\pm$ 5.71	97.11 $\pm$ 5.47
DC	76.81 $\pm$ 16.90	76.10 $\pm$ 16.49	86.05 $\pm$ 11.21	97.33 $\pm$ 3.24	87.63 $\pm$ 9.39
Accuracy	89.96 $\pm$ 4.38	86.42 $\pm$ 11.11	95.78 $\pm$ 2.62	97.68 $\pm$ 3.42	97.28 $\pm$ 3.85
Sensitivity	87.72 $\pm$ 16.82	91.06 $\pm$ 14.66	96.69 $\pm$ 10.24	96.58 $\pm$ 8.58	95.86 $\pm$ 8.67
Specificity	86.70 $\pm$ 6.12	78.05 $\pm$ 17.25	92.18 $\pm$ 4.87	97.11 $\pm$ 3.65	96.42 $\pm$ 4.49

métodos não supervisionados são superiores em todos os aspectos, conforme mostrado na Tabela 1.

Apresentamos também as métricas e seus respectivos desvios padrões na Figura 22. Se tratando de análises médicas, a alta precisão é desejável e essencial. No entanto, ao lidar com tarefas de segmentação, é necessário ter atenção aos resultados de sensibilidade, uma vez que resultados com valores de alta sensibilidade (verdadeiro-positivo) são mais desejáveis do que valores de alta especificidade (verdadeiro-negativo).




Figura 22 – Uma representação de plotagem da Tabela 1. Pos-Position Adjustment, Int-Intensity Adjustment, Size - Size Adjustment, DC - Dice, Acc - Accuracy, Sens-Sensitivity and Spec-Specificity.

Os valores mais baixos de especificidade observados nos resultados de Mask+Bayes, Mask+SVM e Mask+ GMMs, significam que algumas regiões das tomografias computadorizadas de pulmão foram erroneamente classificadas como regiões não pulmonares. Portanto, é possível que em alguns casos durante o processo de segmentação alguns nódulos pulmonares em uma determinada região não tenham sido considerados e tenham sido segmentados como regiões não pulmonares. Além disso, alguns altos valores de desvio padrão também foram encontrados; por exemplo, com relação à Precisão (Acurácia), havia valores que tinham um desvio padrão de 11,11, como foi o caso do modelo Mask+Bayes, contra 3,42 usando o método Mask + K-means.

Após a primeira etapa deste estudo, ficou claro e bem definido que a melhor abordagem foi baseada em métodos não supervisionados, e que o método Mask+K-means foi o mais adequado para a segmentação de imagens de pulmão, superando a Mask-RCNN e outros modelos. O método Mask + K-means obteve valores métricos mais altos em todas as métricas com Precisão (Acurácia) de $(97,68 \pm 3,42)$, especificidade de $(97,11 \pm 3,65)$, e valor de sensibilidade de $(96,58 \pm 8,58)$. Em relação à métrica Sensibilidade o modelo Mask+SVM atingiu resultado equivalente com $(96,69 \pm 10,24)$, porém o desvio padrão para a métrica de sensibilidade foi maior que os valores do desvio padrão para suas outras métricas. Portanto, o modelo Mask+K-means foi escolhido para o próximo estágio.




Figura 23 – Apresenta a região de barreira referente a parede do pulmão (contorno) em 3D utilizando nosso melhor modelo, Mask R-CNN + K-means por meio de fine-tuning.

A segunda etapa deste estudo tem como proposta, validar o estudo com método Mask+K-means, comparando-o com dois estudos relacionados, desenvolvidos por (REBOUÇAS FILHO et al., 2014; FILHO et al., 2019) estudos ambos com o objetivo de segmentar imagens de TC pulmonar utilizando método baseado em contorno ativo. O estudo utilizou 36 imagens de pulmão. Nesta segunda etapa, executamos nossa melhor abordagem (Mask+K-means), já treinada, com as mesmas 36 imagens de TC de pulmão utilizadas pelos trabalhos (REBOUÇAS FILHO et al., 2014; FILHO et al., 2019).

Table 2 apresenta os resultados de Mask + K-means e Adaptive Balloon (REBOU-

ÇAS FILHO et al., 2014) com as referidas métricas de avaliação: *Position*, *Intensity*, *Size* e Tempo de Segmentação.

Tabela 2 – Resultados do método Balão adaptativo (REBOUÇAS FILHO et al., 2014) sobre as 36 imagens utilizadas no trabalho de (REBOUÇAS FILHO et al., 2014) e seus respectivos resultados de métricas.

Método	Position Adjustment	Intensity Adjustment	Size Adjustment	Time (s)
Modelo Proposto	99.21 ± 2.44	99.40 ± 1.34	97.62 ± 0.59	11.24 ± 2.57
Balão Adaptativo	99.80 ± 0.11	98.11 ± 0.96	98.81 ± 0.41	12.87 ± 2.25

O método proposto foi equivalente em valores métricos referente ao método de (REBOUÇAS FILHO et al., 2014). A métrica de Ajuste de Posição (*Position Adjustment*) obteve ($99, 80 \pm 0, 11$ contra $99, 21 \pm 2, 44$), O modelo proposto superou (REBOUÇAS FILHO et al., 2014) em relação a métrica de Ajuste de Intensidade (*Intensity Adjustment*) ($99, 40 \pm 1, 34$ contra $98, 11 \pm 0, 96$) e em Tempo de Segmentação (*Time*) ($11, 24$ contra $12, 87$) sendo equivalente em relação à métrica de Ajuste de tamanho (*Size Adjustment*) ($97, 62 \pm 0, 59$ contra $98, 81 \pm 0, 41$). Os valores do desvio padrão foram tão baixos nas duas abordagens relacionadas às métricas de segmentação, demonstrando robustez.

O trabalho de (FILHO et al., 2019) refere-se a segmentação das tomografias pulmonares. O autor usou as mesmas 36 imagens que (REBOUÇAS FILHO et al., 2014). Foram comparados os métodos Mask+Kmeans com os modelos (GVF-Gradient Vector Flow, VFC - Vector Field Convolution, SISDEP - Sistema para Detecção e Quantificação de Enfisema Pulmonar, OPS-Optimal Path Snake, CRAD-Crisp Adaptativo) usado no trabalho de (FILHO et al., 2019). A Tabela 3 compara a métrica e o tempo de segmentação dos dados.

Tabela 3 – Modelo Proposto em comparação aos modelos (GVF, VFC, SISDEP, OPS, CRAD) usado no trabalho de (FILHO et al., 2019).

Métodos	Dice(DC)	Time (s)
Modelo Proposto	0.97 ± 0.03	11.24 ± 2.57
GVF	0.82 ± 0.06	240.00 ± 3.05
VFC	0.84 ± 0.04	30.00 ± 2.67
SISDEP	0.93 ± 0.02	4.00 ± 0.68
OPS	0.93 ± 0.02	6.73 ± 2.38
CRAD	0.94 ± 0.11	2.00 ± 0.16

Além disso, a Figure 24 descreve os resultados da Tabela 3, onde apresenta a distinção entre a abordagem proposta e (FILHO et al., 2019).

Os métodos que serviram como comparação variaram significativamente entre os valores apresentados em termos de métrica de Dice (DC) usada por (FILHO et al., 2019). O modelo proposto alcançou o melhor desempenho entre todos os métodos apresentados,




Figura 24 – Modelo Proposto e métodos utilizados por (FILHO et al., 2019), baseados na literatura para comparação entre modelos (GVF, VFC, SISDEP, OPS, CRAD). Métrica Coeficiente de Dados (*Dice's coefficient*.)

incluindo o método (FILHO et al., 2019) (OPS), que atingiu DC ($0,93 \pm 0,02$), mostrando que nosso método teve um desempenho melhor, chegando a ($0,97 \pm 0,03$). No entanto, nosso modelo exigiu mais tempo para segmentação quando comparado com CRAD com ($2 \pm 0,16$), SISDEP com ($4 \pm 0,68$) e OPS com ($6,73 \pm 2,38$). Porém, nenhum desses métodos apresentados na Tabela 3 são métodos totalmente automáticos, que é desvantagem em relação ao nosso método.

O modelo OPS obteve os melhores resultados no trabalho de (FILHO et al., 2019). A Tabela 4 apresenta a comparação entre a Abordagem Proposta e OPS para imagens de TC de pulmão classificadas em Normal, DPOC e Fibrose.

Tabela 4 – Comparação entre o Modelo Proposto e a melhor abordagem e (FILHO et al., 2019) em imagens de TC de pulmão agrupadas por Normal, DPOC e Fibrose.

Método	Dice(DC)	Time(s)
Modelo Proposto	97.33 ± 3.24	11.24 ± 2.57
OPS (Normal)	93.00 ± 1.00	5.86 ± 1.96
OPS (DPOC)	93.00 ± 2.00	6.06 ± 2.55
OPS (Fibrose)	93.00 ± 1.00	8.27 ± 2.63

A Figura 25 mostra que a abordagem Proposta por este estudo segmentou com sucesso os pulmões com base na métrica DC, quando comparada ao método OPS de Figure (FILHO et al., 2019).

Podemos afirmar que os resultados das duas etapas dos dois experimentos foram excelentes. Esse tipo de abordagem abre novas opções usando técnicas de *deep learning*. Novas possibilidades surgem na segmentação pulmonar automática com modelos inovadores




Figura 25 – Comparação do Modelo Proposto com o melhor resultado de (FILHO et al., 2019) métrica de avaliação DC.

utilizando métodos convolucionais com um *kernel* para criação de mapas por meio de extração de características através de métodos supervisionados e não supervisionados de aprendizado de máquina. Nossa abordagem foi capaz de reduzir significativamente a quantidade de interações de treinamento em rede convolucional e, conseqüentemente, o tempo de treinamento. Isso foi possível devido ao número reduzido de imagens usadas pelo modelo convencional durante o treinamento e pelo fato do *kernel* atuar como parte significativa da rede.

A quantidade de informação é um fator importante para modelos baseados em *deep learning*, a obtenção de resultados está diretamente ligado aos dados fornecidos para os modelos criados (LEBEDEV et al., 2018). Alguns trabalhos visam diminuir a quantidade de imagens durante o treinamento da Mask R-CNN, é o caso de (ZIMMERMANN; SIEMS, 2019) que propuseram um treinamento mais rápido por meio de combinações de filtros dentro da estrutura da rede. Estudos recentes mostraram que a transferência de aprendizagem nas CNNs torna-se uma alternativa diante dos problemas de insuficiência de dados no processo de treinamento, novas abordagens estão sendo encontradas para suprir essa escassez por meio de transferência de aprendizagem dentro dos modelos (AFRIDI; ROSS; SHAPIRO, 2018; HAN; LIU; FAN, 2018).

A Tabela 5 compara trabalhos com uso da Mask R-CNN, é possível notar que o número de imagens é gradativamente importante dentro do processo de treinamento da rede e sua relação com o treinamento de modelos, nosso modelo demonstra eficácia também pelo fato de utilizar apenas 998 imagens no processo de treino, garantindo em paralelo a excelência e eficácia nos resultados que podem ser vistos na Seção 5, possibilitando assim novas soluções se tratando de imagens médicas.

O modelo proposto por este estudo não utilizou nenhum método de pré-processamento nas imagens de entrada, tais como técnicas clássicas de PDI para normalização de imagens

Autores	Trabalhos	# Conjunto de treinamento
Yang et al. (2019)	BoSR: A CNN-based aurora image retrieval method	600.000
Ma, Chen e Yong (2019)	AU R-CNN: Encoding expert prior knowledge into R-CNN for action unit detection	400.000
Malhotra et al. (2018)	Autonomous detection of disruptions in the intensive care unit using deep mask R-CNN	58.053
Danielczuk et al. (2019)	Segmenting Unknown 3D Objects from Real Depth Images using Mask R-CNN Trained on Synthetic Data	50.000
Tang et al. (2019)	ULDor: A Universal Lesion Detector for CT Scans with Pseudo Masks and Hard Negative Example Mining	32.735
Liu et al. (2018)	Segmentation of Lung Nodule in CT Images Based on Mask R-CNN	24.000
Lu, Hu e Lu (2019)	Dilated Light-Head R-CNN using tri-center loss for driving behavior recognition	22.424
Bharati e Pramanik (2020)	Multi-Class Object Detection from Aerial Images Using Mask R-CNN	9.993
Zhu et al. (2019)	Mask Guided Knowledge Distillation for Single Shot Detector	9.963
Wang, Ma e Chen (2016)	Salient object detection via fast R-CNN and low-level cues	4.000
Modelo Proposto (HU et al., 2020)	An Effective Approach of CT Lung Segmentation using Mask Region-based Convolutional Neural Networks	998

Tabela 5 – Trabalhos relacionados ao uso da Mask R-CNN em conjunto com o número de imagens usadas no treinamento por diferentes métodos.

no intuito da retirada de ruídos, como fizeram vários métodos citados na Tabela 5 e na Seção 2 para se obter melhores resultados. Simplificamos o treinamento do nosso modelo como mencionado na Seção 3, utilizando a Rede Mask R-CNN como a etapa inicial de processamento da rede, trouxemos como inovação, o mapeamento da área do pulmão por meio de clusterização, a partir do resultado da Mask R-CNN como relatados na Metodologia do estudo, combinando com outras redes supervisionadas e não supervisionadas.

Nosso processo de clusterização é inovador, utilizamos métodos da literatura (Erosão e Dilatação) na saída da rede Mask R-CNN, isso possibilitou acharmos os ponto que ligam regiões de dentro e fora da área pulmonar, até o momento na literatura não encontramos esta técnica para buscar regiões internas e externas do pulmão, isso tudo de forma totalmente automática, diferente dos modelos relatados na Seção 2 - Trabalhos Relacionados, que buscaram automatizar em alguns modelos, porém precisaram de pré-processamentos para dar mais qualidade em seus resultados ou utilizar modelos semi-automáticos para sua segmentação.

Este estudo foi capaz de criar um modelo capaz de segmentar as Tomografias do pulmão por meio de transferência de aprendizagem de uma rede para outras redes; *kernel* implantados na ponta do modelo que são constituídos de redes de aprendizagem no qual buscam melhores resultados, os resultados podem ser comparados entre modelos, neste estudo tiveram como experimento imagens de TC de pulmão com modelo Mask-Kmeans como melhor desempenho para segmentação, isso significa uma abertura de novas possibilidades de testes para uso de diferentes imagens médicas em trabalhos futuros.

6 Conclusão

Neste trabalho, é proposto um novo método robusto para segmentação automática de pulmão em tomografias computadorizadas (TC) usando Mask R-CNN com modelos de aprendizado de máquina supervisionados e não supervisionados, atuando como *kernels*. O desafio da segmentação pulmonar se deve à variação no tamanho do objeto de interesse, pois durante a tomografia computadorizada, as imagens são capturadas dos pulmões com o sistema respiratório em operação; o processo de inflar e desinflar resulta em imagens pulmonares (cortes de TC) de diferentes tamanhos.

Nossa abordagem aplicada ao aprendizado por transferência; métodos de erosão e dilatação na saída final da rede Mask R-CNN, utiliza uma técnica para mapear a região do pulmonar através de clusterização combinado com métodos supervisionados e não supervisionados. A quantidade de informações é um fator essencial para modelos baseados em aprendizado profundo, os resultados são diretamente ligados aos dados fornecidos como entrada para os modelos. O método foi capaz de reduzir significativamente o número de imagens usadas pelo modelo convolucional durante o treinamento e suas interações; consequentemente, alcançou excelentes resultados de segmentação. Além disso, nossa abordagem automática é diferente de muitos modelos atuais da literatura que exigem o uso de estágios de pré-processamento para melhorar a qualidade de seus resultados ou usar modelos semi-automáticos para a segmentação pulmonar.

No experimento proposto, foram combinados diferentes configurações da abordagem, variando os *kernels* entre os métodos supervisionado, a fim de descobrir qual dessas configurações apresentaria melhor desempenho. A configuração da Mask R-CNN + Kmeans produziu os melhores valores de ajuste de posição (99,21 %), Ajuste de intensidade (99,40 %), Ajuste de tamanho (97,62 %), coeficiente de dados DC (97,33 %), Precisão (Accuracy) (97,11 %) e a segunda melhor em Sensibilidade (96,58 %), depois da Mask R-CNN+SVM (96,69 %).

Os resultados das configurações Mask R-CNN e K-means, dentre as cinco configurações propostas, apresentaram maior eficiência na segmentação dos pulmões em imagens de tomografia computadorizada, sendo, portanto, a principal contribuição do trabalho.

Esse tipo de abordagem inovadora abre novas oportunidades para aplicações de aprendizado profundo, e surgem novas possibilidades na segmentação pulmonar automática para apoiar a tomada de decisões médicas, além de modelos inovadores usando métodos convolucionais com um *kernel* para mapear a extração de características por métodos supervisionados e não supervisionados de aprendizado de máquina. Com relação às aplicações do mundo real, este estudo pode ser integrado aos softwares de diagnóstico

auxiliado por computador (CAD) relacionados a doenças pulmonares para segmentar automaticamente o pulmão.

Existem alguns pontos que ainda podem ser melhorados, como aperfeiçoamento do modelo para diminuição do tempo médio de segmentação e reformulação do modelo para ser capaz de generalizar, não só para imagens de pulmão mas para outras imagens médicas. Para trabalhos futuros, pretendemos utilizar nossa metodologia de segmentação automática, bem como aplicá-la a outras imagens médicas (ou seja, cérebro, mama, melanoma) por meio de técnicas de aprendizado por transferência.

7 Anexo A



Universidade Federal do Ceará
Comitê de Ética em Pesquisa

Of. N° 107/06

Fortaleza, 31 de março de 2006

Protocolo COMEPE n° 36/06

Pesquisador responsável: Simone Castelo Branco Fortaleza

Dept°./Serviço: Hospital Universitário Walter Cantídio

Título do Projeto: "Efeitos da administração da CPAP sobre o parênquima pulmonar nas posições prona e supina em pacientes com doença pulmonar obstrutiva crônica: alterações na tomografia computadorizada de alta resolução e correlação com a dispnéia"

Levamos ao conhecimento de V.Sª. que o Comitê de Ética em Pesquisa da Universidade Federal do Ceará – COMEPE, dentro das normas que regulamentam a pesquisa em seres humanos, do Conselho Nacional de Saúde – Ministério da Saúde, Resolução n°196 de 10 de outubro de 1996 e complementares, aprovou o projeto supracitado na reunião do dia 30 de março de 2006.

Outrossim, informamos, que o pesquisador deverá se comprometer a enviar o relatório parcial e final do referido projeto.

Atenciosamente,

Dr. Fernando A. Freire Bezerra
Coordenador do Comitê
de Ética em Pesquisa
COMEPE/UFC

Referências

- ABADI, M. et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. Software available from tensorflow.org. Citado na página 69.
- AFRIDI, M. J.; ROSS, A.; SHAPIRO, E. M. On automated source selection for transfer learning in convolutional neural networks. *Pattern recognition*, Elsevier, v. 73, p. 65–75, 2018. Citado na página 75.
- AMÉNDOLA, C.; FAUGERE, J.-C.; STURMFELS, B. Moment varieties of gaussian mixtures. *arXiv preprint arXiv:1510.04654*, 2015. Citado na página 50.
- AMIRAV, I. et al. Assessment of methacholine-induced airway constriction by ultrafast high-resolution computed tomography. *Journal of Applied Physiology*, v. 75, n. 5, p. 2239–2250, 1993. Citado na página 26.
- ANTHIMOPOULOS, M. et al. Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. *IEEE transactions on medical imaging*, IEEE, v. 35, n. 5, p. 1207–1216, 2016. Citado na página 34.
- ARAÚJO, T. et al. Classification of breast cancer histology images using convolutional neural networks. *PloS one*, Public Library of Science, v. 12, n. 6, p. e0177544, 2017. Citado na página 34.
- BARDOU, D.; ZHANG, K.; AHMAD, S. M. Lung sounds classification using convolutional neural networks. *Artificial intelligence in medicine*, Elsevier, v. 88, p. 58–69, 2018. Citado na página 34.
- BARNES, P. J. Inflammatory mechanisms in patients with chronic obstructive pulmonary disease. *Journal of Allergy and Clinical Immunology*, Elsevier, v. 138, n. 1, p. 16–27, 2016. Citado na página 25.
- BARROS, A. C. da S. *Optimum Path Snakes: Novo Método de Contornos Ativos Adaptativo e Não-Paramétrico*. Tese (Doutorado) — Universidade de Fortaleza, Fortaleza, CE, 2016. Citado 3 vezes nas páginas 16, 51 e 58.
- BARTHOLOMAI, J. A.; FRIEBOES, H. B. Lung cancer survival prediction via machine learning regression, classification, and statistical techniques. In: IEEE. *2018 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*. [S.l.], 2018. p. 632–637. Citado na página 34.
- BERAN, D. et al. Forum of international respiratory societies working group c. burden of asthma and chronic obstructive pulmonary disease and access to essential medicines in low-income and middle-income countries. *Lancet Respiratory Med*, v. 3, n. 2, p. 159–70, 2015. Citado na página 25.
- BERGSTRA, J.; BENGIO, Y. Random search for hyper-parameter optimization. *J. Mach. Learn. Res.*, JMLR.org, v. 13, p. 281–305, fev. 2012. ISSN 1532-4435. Citado na página 69.

BERNAL, J. et al. Deep convolutional neural networks for brain image analysis on magnetic resonance imaging: a review. *Artificial intelligence in medicine*, Elsevier, v. 95, p. 64–81, 2019. Citado na página 34.

BHARATI, P.; PRAMANIK, A. Deep learning techniques—r-cnn to mask r-cnn: A survey. In: *Computational Intelligence in Pattern Recognition*. [S.l.]: Springer, 2020. p. 657–668. Citado na página 76.

BONANNO, L. et al. Validation of a computer-aided diagnosis system for the automatic identification of carotid atherosclerosis. *Ultrasound in medicine & biology*, Elsevier, v. 41, n. 2, p. 509–516, 2015. Citado na página 27.

BUIST, A. S. Similarities and differences between asthma and chronic obstructive pulmonary disease: treatment and early outcomes. *European respiratory journal*, Eur Respiratory Soc, v. 21, n. 39 suppl, p. 30s–35s, 2003. Citado na página 26.

CHEN, X. et al. Software defect number prediction: Unsupervised vs supervised methods. *Information and Software Technology*, Elsevier, v. 106, p. 161–181, 2019. Citado na página 33.

COHEN, L. D. On active contour models and balloons. *CVGIP: Image understanding*, Elsevier, v. 53, n. 2, p. 211–218, 1991. Citado na página 51.

CORTES, C.; VAPNIK, V. Support-vector networks. *Machine learning*, Springer, v. 20, n. 3, p. 273–297, 1995. Citado na página 48.

COUTEAUX, V. et al. Automatic knee meniscus tear detection and orientation classification with mask-rcnn. *Diagnostic and Interventional Imaging*, v. 100, n. 4, p. 235 – 242, 2019. ISSN 2211-5684. Citado na página 34.

COXSON, H. *Computed tomography and monitoring of emphysema*. [S.l.]: Eur Respiratory Soc, 2007. Citado na página 26.

CRAMÉR, H.; CARUSO, L. A. *Elementos da teoria da probabilidade e algumas das suas aplicações*. [S.l.: s.n.], 1973. Citado na página 47.

DANIELCZUK, M. et al. Segmenting unknown 3d objects from real depth images using mask r-cnn trained on synthetic data. In: IEEE. *2019 International Conference on Robotics and Automation (ICRA)*. [S.l.], 2019. p. 7283–7290. Citado na página 76.

DELVES, L. et al. Comparing the performance of sar image segmentation algorithms. *International Journal of Remote Sensing*, Taylor & Francis, v. 13, n. 11, p. 2121–2149, 1992. Citado 2 vezes nas páginas 60 e 61.

DEMPSTER, A. P.; LAIRD, N. M.; RUBIN, D. B. Maximum likelihood from incomplete data via the em algorithm. *Journal of the Royal Statistical Society: Series B (Methodological)*, Wiley Online Library, v. 39, n. 1, p. 1–22, 1977. Citado na página 50.

DÍAZ, A. A.; CELLI, B.; CELEDÓN, J. C. Chronic obstructive pulmonary disease in hispanics. a 9-year update. *American journal of respiratory and critical care medicine*, American Thoracic Society, v. 197, n. 1, p. 15–21, 2018. Citado na página 26.

DICE, L. R. Measures of the amount of ecologic association between species. *Ecology*, Wiley Online Library, v. 26, n. 3, p. 297–302, 1945. Citado na página 61.

- DING, G. et al. Feature mask network for person re-identification. *Pattern Recognition Letters*, Elsevier, 2019. Citado na página 33.
- DOEL, T.; GAVAGHAN, D. J.; GRAU, V. Review of automatic pulmonary lobe segmentation methods from ct. *Computerized Medical Imaging and Graphics*, Elsevier, v. 40, p. 13–29, 2015. Citado 2 vezes nas páginas 33 e 34.
- FAWCETT, T. An introduction to roc analysis. *Pattern recognition letters*, Elsevier, v. 27, n. 8, p. 861–874, 2006. Citado na página 62.
- FELIX, J. H. da S. et al. Avaliação computacional de enfisema pulmonar em TC: comparação entre um sistema desenvolvido localmente e um sistema de uso livre. *Jornal Brasileiro de Pneumologia*, SciELO Brasil, v. 35, n. 9, p. 868–876, 2009. Citado 2 vezes nas páginas 16 e 60.
- FELIX, J. H. S. *Sistema de Visão Computacional para Detecção e Quantificação de Enfisema Pulmonar*. Tese (Doutorado) — Dissertação de Mestrado, Universidade Federal do Ceará, Fortaleza, CE, 2007. Citado 2 vezes nas páginas 51 e 59.
- FILHO, P. P. R. et al. A new effective and powerful medical image segmentation algorithm based on optimum path snakes. *Applied Soft Computing*, Elsevier, v. 76, p. 649–670, 2019. Citado 8 vezes nas páginas 16, 17, 63, 69, 72, 73, 74 e 75.
- FILHO, P. P. R. et al. Novel and powerful 3d adaptive crisp active contour method applied in the segmentation of ct lung images. *Medical image analysis*, Elsevier, v. 35, p. 503–516, 2017. Citado 2 vezes nas páginas 33 e 63.
- GHOSH, S. et al. Using convolutions and image processing techniques to segment lungs from ct data. In: *Emerging Technology in Modelling and Graphics*. [S.l.]: Springer, 2020. p. 129–136. Citado na página 35.
- GIRSHICK, R. Fast r-cnn. In: *Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2015. p. 1440–1448. Citado na página 41.
- GIRSHICK, R. et al. Rich feature hierarchies for accurate object detection and semantic segmentation. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2014. p. 580–587. Citado na página 41.
- GLOBAL tuberculosis report 2017. Geneva, Switzerland: World Health Organization, 2017. ISBN 978-92-4-156551-6. Citado na página 25.
- GORDIENKO, Y. et al. Deep learning with lung segmentation and bone shadow exclusion techniques for chest x-ray analysis of lung cancer. In: SPRINGER. *International Conference on Computer Science, Engineering and Education Applications*. [S.l.], 2018. p. 638–647. Citado na página 35.
- GRAU, V. et al. Improved watershed transform for medical image segmentation using prior information. *IEEE transactions on medical imaging*, IEEE, v. 23, n. 4, p. 447–458, 2004. Citado na página 33.
- GU, J. et al. Recent advances in convolutional neural networks. *Pattern Recognition*, Elsevier, v. 77, p. 354–377, 2018. Citado na página 36.

GUAN, W.-J. et al. Impact of air pollution on the burden of chronic respiratory diseases in china: time for urgent action. *The Lancet*, Elsevier, v. 388, n. 10054, p. 1939–1951, 2016. Citado na página 25.

HAN, D.; LIU, Q.; FAN, W. A new image classification method using cnn transfer learning and web data augmentation. *Expert Systems with Applications*, Elsevier, v. 95, p. 43–56, 2018. Citado na página 75.

HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2007. Citado na página 38.

HE, K. et al. Mask r-cnn. In: *Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2017. p. 2961–2969. Citado 4 vezes nas páginas 15, 41, 42 e 44.

HSIEH, J. et al. Computed tomography: principles, design, artifacts, and recent advances. In: SPIE BELLINGHAM, WA. [S.l.], 2009. Citado na página 26.

HU, Q. et al. An effective approach for ct lung segmentation using mask region-based convolutional neural networks. *Artificial Intelligence in Medicine*, Elsevier, p. 101792, 2020. Citado 2 vezes nas páginas 27 e 76.

HUANG, X. et al. Fast and fully-automated detection and segmentation of pulmonary nodules in thoracic ct scans using deep convolutional neural networks. *Computerized Medical Imaging and Graphics*, Elsevier, 2019. Citado na página 34.

HUANG, Z. et al. Mask r-cnn with pyramid attention network for scene text detection. In: IEEE. *2019 IEEE Winter Conference on Applications of Computer Vision (WACV)*. [S.l.], 2019. p. 764–772. Citado na página 33.

HUYNH, H. T.; ANH, V. N. N. A deep learning method for lung segmentation on large size chest x-ray image. In: IEEE. *2019 IEEE-RIVF International Conference on Computing and Communication Technologies (RIVF)*. [S.l.], 2019. p. 1–5. Citado na página 35.

HWANG, S.; PARK, S. Accurate lung segmentation via network-wise training of convolutional networks. In: *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*. [S.l.]: Springer, 2017. p. 92–99. Citado na página 35.

JAVAID, M.; HALEEM, A. Industry 4.0 applications in medical field: a brief review. *Current Medicine Research and Practice*, Elsevier, 2019. Citado na página 36.

JIANG, H.-Y.; SI, Y.-p.; LUO, X.-g. Medical image segmentation based on improved ostu algorithm and regional growth algorithm. *JOURNAL-NORTHEASTERN UNIVERSITY NATURAL SCIENCE*, v. 27, n. 4, p. 398, 2006. Citado na página 33.

JOHNSON, J. W. Adapting mask-rcnn for automatic nucleus segmentation. *arXiv preprint arXiv:1805.00500*, 2018. Citado na página 33.

KASINATHAN, G. et al. Automated 3-d lung tumor detection and classification by an active contour model and cnn classifier. *Expert Systems with Applications*, Elsevier, v. 134, p. 112–119, 2019. Citado na página 34.

- KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. *International journal of computer vision*, Springer, v. 1, n. 4, p. 321–331, 1988. Citado na página 56.
- KHARE, A.; TIWARY, U. S. Soft-thresholding for denoising of medical images—a multiresolution approach. *International Journal of Wavelets, Multiresolution and Information Processing*, World Scientific, v. 3, n. 04, p. 477–496, 2005. Citado na página 33.
- KOCH, C.; TSUCHIYA, N. Attention and consciousness: two distinct brain processes. *Trends in cognitive sciences*, Elsevier, v. 11, n. 1, p. 16–22, 2007. Citado na página 38.
- LEBEDEV, G. et al. Application of artificial intelligence methods to recognize pathologies on medical images. *Procedia Computer Science*, Elsevier, v. 126, p. 1171–1177, 2018. Citado na página 75.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. Citado 2 vezes nas páginas 37 e 38.
- LELIEVELD, J. et al. The contribution of outdoor air pollution sources to premature mortality on a global scale. *Nature*, Nature Publishing Group, v. 525, n. 7569, p. 367, 2015. Citado na página 25.
- LI, B.; ACTON, S. T. Vector field convolution for image segmentation using snakes. In: IEEE. *Image Processing, 2006 IEEE International Conference on*. [S.l.], 2006. p. 1637–1640. Citado 2 vezes nas páginas 51 e 55.
- LIPSCHUTZ, F. *Probabilidade, 4ª Ed.. Trad. De Ruth Ribas Itacarabi*. [S.l.]: São Paulo, Makon Books, 1994. Citado na página 47.
- LIU, M. et al. Segmentation of lung nodule in ct images based on mask r-cnn. In: IEEE. *2018 9th International Conference on Awareness Science and Technology (iCAST)*. [S.l.], 2018. p. 1–6. Citado na página 76.
- LIU, M. et al. A semi-supervised convolutional transfer neural network for 3d pulmonary nodules detection. *Neurocomputing*, Elsevier, 2019. Citado na página 35.
- LU, M.; HU, Y.; LU, X. Dilated light-head r-cnn using tri-center loss for driving behavior recognition. *Image and Vision Computing*, Elsevier, 2019. Citado na página 76.
- LUSTBERG, T. et al. Clinical evaluation of atlas and deep learning based automatic contouring for lung cancer. *Radiotherapy and Oncology*, Elsevier, v. 126, n. 2, p. 312–317, 2018. Citado na página 34.
- MA, C.; CHEN, L.; YONG, J. Au r-cnn: Encoding expert prior knowledge into r-cnn for action unit detection. *Neurocomputing*, Elsevier, v. 355, p. 35–47, 2019. Citado na página 76.
- MACKIEWICH, B. *Intracranial boundary detection and radio frequency correction in magnetic resonance images*. Tese (Doutorado) — Theses (School of Computing Science)/Simon Fraser University, 1995. Citado na página 52.

- MACQUEEN, J. et al. Some methods for classification and analysis of multivariate observations. In: OAKLAND, CA, USA. *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*. [S.l.], 1967. v. 1, n. 14, p. 281–297. Citado na página 49.
- MALHOTRA, K. R. et al. Autonomous detection of disruptions in the intensive care unit using deep mask r-cnn. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. [S.l.: s.n.], 2018. p. 1863–1865. Citado na página 76.
- MARCINIUK COCHAIR DEAN E. SCHRAUFNAGEL, C. T. F. K. M. F. G. J. V. L. V. H. Z. D. D. Foro de las sociedades respiratorias internacionales. el impacto global de la enfermedad respiratoria – segunda edición. México, asociación latinoamericana de tórax, 2017. *European Respiratory Society, on behalf of the Forum of International Respiratory Societies (FIRS)*., European Respiratory Society, on behalf of the Forum of International Respiratory Societies (FIRS)., n. 9, p. 9–10, 2017. Citado na página 26.
- MARCO, R. D. et al. An international survey of chronic obstructive pulmonary disease in young adults according to gold stages. *Thorax*, BMJ Publishing Group Ltd, v. 59, n. 2, p. 120–125, 2004. Citado na página 25.
- MASOLI, M. et al. The global burden of asthma: executive summary of the gina dissemination committee report. *Allergy*, Wiley Online Library, v. 59, n. 5, p. 469–478, 2004. Citado na página 26.
- MCLACHLAN, G. J.; LEE, S. X.; RATHNAYAKE, S. I. Finite mixture models. *Annual review of statistics and its application*, Annual Reviews, v. 6, p. 355–378, 2019. Citado na página 50.
- MESSAY, T.; HARDIE, R. C.; ROGERS, S. K. A new computationally efficient cad system for pulmonary nodule detection in ct imagery. *Medical image analysis*, Elsevier, v. 14, n. 3, p. 390–406, 2010. Citado na página 27.
- MEYER, P. L. Probabilidade: aplicações à estatística. 2ª Edição–Tradução de Ruy de CB Lourenço Filho, 1965. Citado na página 46.
- MILLETARI, F.; NAVAB, N.; AHMADI, S.-A. V-net: Fully convolutional neural networks for volumetric medical image segmentation. In: IEEE. *2016 Fourth International Conference on 3D Vision (3DV)*. [S.l.], 2016. p. 565–571. Citado na página 34.
- MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. *Foundations of Machine Learning*. [S.l.]: The MIT Press, 2012. ISBN 026201825X, 9780262018258. Citado 2 vezes nas páginas 33 e 37.
- MOLINA-MOLINA, M. et al. *Importance of early diagnosis and treatment in idiopathic pulmonary fibrosis*. [S.l.]: Taylor & Francis, 2018. Citado na página 26.
- MORGADO, A. C. d. O. et al. *Análise combinatória e probabilidade*. [S.l.]: Instituto de Matemática pura e aplicada, 1991. Citado na página 46.
- MOSQUERA-LOPEZ, C. et al. Computer-aided prostate cancer diagnosis from digitized histopathology: a review on texture-based systems. *IEEE reviews in biomedical engineering*, IEEE, v. 8, p. 98–113, 2014. Citado na página 27.

- MÜLLER, A. C.; GUIDO, S. et al. *Introduction to machine learning with Python: a guide for data scientists*. [S.l.]: "O'Reilly Media, Inc.", 2016. Citado 2 vezes nas páginas 15 e 49.
- MUZAMMAL, M. et al. A multi-sensor data fusion enabled ensemble approach for medical data from body sensor networks. *Information Fusion*, Elsevier, v. 53, p. 155–164, 2020. Citado 2 vezes nas páginas 26 e 33.
- NÓBREGA, R. V. M. da; RODRIGUES, M. B.; FILHO, P. P. R. Segmentation and visualization of the lungs in three dimensions using 3d region growing and visualization toolkit in ct examinations of the chest. In: IEEE. *2017 IEEE 30th International Symposium on Computer-Based Medical Systems (CBMS)*. [S.l.], 2017. p. 397–402. Citado na página 28.
- NOVIKOV, A. A. et al. Fully convolutional architectures for multiclass segmentation in chest radiographs. *IEEE transactions on medical imaging*, IEEE, v. 37, n. 8, p. 1865–1876, 2018. Citado na página 34.
- ORGANIZATION, W. H. *Global tuberculosis report 2013*. [S.l.]: World Health Organization, 2013. Citado na página 25.
- PAWEŁCZYK, K. et al. Towards detecting high-uptake lesions from lung ct scans using deep learning. In: SPRINGER. *International Conference on Image Analysis and Processing*. [S.l.], 2017. p. 310–320. Citado na página 34.
- PIRBHULAL, S. et al. A joint resource-aware and medical data security framework for wearable healthcare systems. *Future Generation Computer Systems*, Elsevier, v. 95, p. 382–391, 2019. Citado na página 33.
- PORTELA, N. M. Modelo de mistura de gaussianas fuzzy contextual. Universidade Federal de Pernambuco, 2015. Citado na página 50.
- PROVOST, F.; KOHAVI, R. Glossary of terms. *Journal of Machine Learning*, v. 30, n. 2-3, p. 271–274, 1998. Citado na página 37.
- QIAN, W. et al. Mapping and candidate-gene screening of the novel turnip mosaic virus resistance gene retr02 in chinese cabbage (*brassica rapa* l.). *Theoretical and applied genetics*, Springer, v. 126, n. 1, p. 179–188, 2013. Citado na página 61.
- RAMALHO, G. L. B. et al. Rotation-invariant feature extraction using a structural co-occurrence matrix. *Measurement*, Elsevier, v. 94, p. 406–415, 2016. Citado na página 63.
- REBOUCAS, E. S.; SARMENTO, R. M.; FILHO, P. P. R. 3d adaptive balloon active contour: method of segmentation of structures in three dimensions. *IEEE Latin America Transactions*, IEEE, v. 13, n. 1, p. 195–203, 2015. Citado na página 63.
- REBOUÇAS FILHO, P. P. *Mca crisp: nova técnica de segmentação dos pulmões em imagens de tomografia computadorizada baseada no método de contorno ativo*. Tese (Doutorado) — Universidade Federal do Ceará, Fortaleza, CE, 2010. Citado 2 vezes nas páginas 51 e 54.

- REBOUÇAS FILHO, P. P. *Métodos De Contornos Ativos Crisp Adaptativo 2D e 3D Aplicados Na Segmentação Dos Pulmões em Imagens De Tomografia Computadorizada Do Tórax*. Tese (Doutorado) — Tese de Doutorado, Universidade Federal do Ceará, Fortaleza, CE, 2013. Citado 3 vezes nas páginas 15, 56 e 57.
- REBOUÇAS FILHO, P. P. et al. Novel adaptive balloon active contour method based on internal force for image segmentation—a systematic evaluation on synthetic and real images. *Expert Systems with Applications*, Elsevier, v. 41, n. 17, p. 7707–7721, 2014. Citado 9 vezes nas páginas 15, 17, 51, 52, 53, 63, 69, 72 e 73.
- REBOUÇAS FILHO, P. P. et al. Adaptive 2d crisp active contour model applied to lung segmentation in ct images of the thorax of healthy volunteers and patients with pulmonary emphysema. *Revista Brasileira de Engenharia Biomédica*, SciELO Brasil, v. 29, n. 4, p. 363–376, 2013. Citado 3 vezes nas páginas 51, 53 e 54.
- REBOUÇAS FILHO, P. P. et al. Modelo de contorno ativo crisp adaptativo 2d aplicado na segmentação dos pulmões em imagens de tc do tórax de voluntários sadios e pacientes com enfisema pulmonar. *Revista Brasileira de Engenharia Biomédica*, v. 29, n. 4, p. 363–376, 2013. Citado na página 57.
- REN, S. et al. Faster r-cnn: Towards real-time object detection with region proposal networks. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2015. p. 91–99. Citado na página 41.
- SAMUEL, A. L. Some studies in machine learning using the game of checkers. ii—recent progress. *IBM Journal of research and development*, IBM, v. 11, n. 6, p. 601–617, 1967. Citado na página 37.
- SANTOS, R. M. et al. Speech recognition in noisy environments with convolutional neural networks. In: IEEE. *2015 Brazilian Conference on Intelligent Systems (BRACIS)*. [S.l.], 2015. p. 175–179. Citado na página 33.
- SCHMIDHUBER, J. Deep learning in neural networks: An overview. *Neural networks*, Elsevier, v. 61, p. 85–117, 2015. Citado na página 27.
- SHI, Y. et al. Prediction of progression in idiopathic pulmonary fibrosis using ct scans at baseline: A quantum particle swarm optimization-random forest approach. *Artificial Intelligence in Medicine*, Elsevier, p. 101709, 2019. Citado na página 34.
- SIMONYAN, K.; VEDALDI, A.; ZISSERMAN, A. Deep inside convolutional networks: Visualising image classification models and saliency maps. *arXiv preprint arXiv:1312.6034*, 2013. Citado na página 35.
- SLUIMER, I. et al. Computer analysis of computed tomography scans of the lung: a survey. *IEEE transactions on medical imaging*, IEEE, v. 25, n. 4, p. 385–405, 2006. Citado na página 26.
- SOCIETY, B.; COMMITTEE, S. The diagnosis, assessment and treatment of diffuse parenchymal lung disease in adults. *Thorax*, BMJ Publishing Group, v. 54, n. Suppl 1, p. S1, 1999. Citado na página 26.
- SODHRO, A. H.; LI, Y.; SHAH, M. A. Energy-efficient adaptive transmission power control for wireless body area networks. *IET Communications*, IET, v. 10, n. 1, p. 81–90, 2016. Citado na página 26.

- SODHRO, A. H. et al. Artificial intelligence based qos optimization for multimedia communication in iov systems. *Future Generation Computer Systems*, Elsevier, v. 95, p. 667–680, 2019. Citado na página 27.
- SODHRO, A. H. et al. An adaptive qos computation for medical data processing in intelligent healthcare applications. *Neural Computing and Applications*, Springer, p. 1–12, 2019. Citado na página 27.
- SODHRO, A. H.; PIRBHULAL, S.; ALBUQUERQUE, V. H. C. de. Artificial intelligence driven mechanism for edge computing based industrial applications. *IEEE Transactions on Industrial Informatics*, IEEE, 2019. Citado na página 27.
- SODHRO, A. H. et al. Towards an optimal resource management for iot based green and sustainable smart cities. *Journal of Cleaner Production*, Elsevier, v. 220, p. 1167–1179, 2019. Citado na página 27.
- SODHRO, A. H. et al. Medical-qos based telemedicine service selection using analytic hierarchy process. In: *Handbook of Large-Scale Distributed Computing in Smart Healthcare*. [S.l.]: Springer, 2017. p. 589–609. Citado na página 27.
- SUZUKI, K. Overview of deep learning in medical imaging. *Radiological physics and technology*, Springer, v. 10, n. 3, p. 257–273, 2017. Citado na página 34.
- TANG, Y. et al. Uldor: A universal lesion detector for ct scans with pseudo masks and hard negative example mining. *arXiv preprint arXiv:1901.06359*, 2019. Citado na página 76.
- THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition (Fourth Edition)*. USA: Academic Press, 2008. Citado 2 vezes nas páginas 46 e 47.
- TRAVIS, W. D. et al. The 2015 world health organization classification of lung tumors: impact of genetic, clinical and radiologic advances since the 2004 classification. *Journal of thoracic oncology*, Elsevier, v. 10, n. 9, p. 1243–1260, 2015. Citado na página 25.
- VAPNIK, V. N. *Statistical Learning Theory*. Nova Jersey, EUA: John Wiley & Sons, 1998. Citado na página 48.
- WACHINGER, C.; REUTER, M.; KLEIN, T. Deepnat: Deep convolutional neural network for segmenting neuroanatomy. *NeuroImage*, Elsevier, v. 170, p. 434–445, 2018. Citado na página 34.
- WANG, J. et al. Instance segmentation of anatomical structures in chest radiographs. In: IEEE. *2019 IEEE 32nd International Symposium on Computer-Based Medical Systems (CBMS)*. [S.l.], 2019. p. 441–446. Citado na página 35.
- WANG, X.; MA, H.; CHEN, X. Salient object detection via fast r-cnn and low-level cues. In: IEEE. *2016 IEEE International Conference on Image Processing (ICIP)*. [S.l.], 2016. p. 1042–1046. Citado na página 76.
- WANG, X. et al. High throughput lung and lobar segmentation by 2d and 3d cnn on chest ct with diffuse lung disease. In: *Image Analysis for Moving Organ, Breast, and Thoracic Images*. [S.l.]: Springer, 2018. p. 202–214. Citado na página 34.

- WU, W. et al. Optimization of signal quality over comfortability of textile electrodes for ecg monitoring in fog computing based medical applications. *Future generation computer systems*, Elsevier, v. 86, p. 515–526, 2018. Citado na página 26.
- XU, C.; PRINCE, J. L. Snakes, shapes, and gradient vector flow. *IEEE Transactions on image processing*, IEEE, v. 7, n. 3, p. 359–369, 1998. Citado 2 vezes nas páginas 51 e 53.
- XU, M. et al. Segmentation of lung parenchyma in ct images using cnn trained with the clustering algorithm generated dataset. *Biomedical engineering online*, BioMed Central, v. 18, n. 1, p. 2, 2019. Citado na página 35.
- YAMASHITA, R. et al. Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, Springer, v. 9, n. 4, p. 611–629, 2018. Citado 2 vezes nas páginas 15 e 43.
- YANG, X. et al. Bosr: A cnn-based aurora image retrieval method. *Neural Networks*, Elsevier, v. 116, p. 188–197, 2019. Citado na página 76.
- YANG, Y.; SU, Z.; SUN, L. Medical image enhancement algorithm based on wavelet transform. *Electronics letters*, IET, v. 46, n. 2, p. 120–121, 2010. Citado na página 33.
- YU, Y. et al. Fruit detection for strawberry harvesting robot in non-structural environment based on mask-rcnn. *Computers and Electronics in Agriculture*, Elsevier, v. 163, p. 104846, 2019. Citado na página 33.
- ZEILER, M. D.; FERGUS, R. Visualizing and understanding convolutional networks. In: SPRINGER. *European conference on computer vision*. [S.l.], 2014. p. 818–833. Citado na página 35.
- ZHANG, R.; ISOLA, P.; EFROS, A. A. Split-brain autoencoders: Unsupervised learning by cross-channel prediction. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2017. p. 1058–1067. Citado na página 33.
- ZHENG, W. et al. Just-in-time semi-supervised soft sensor for quality prediction in industrial rubber mixers. *Chemometrics and Intelligent Laboratory Systems*, Elsevier, v. 180, p. 36–41, 2018. Citado na página 33.
- ZHOU, S. K.; GREENSPAN, H.; SHEN, D. *Deep learning for medical image analysis*. [S.l.]: Academic Press, 2017. Citado na página 27.
- ZHU, Y. et al. Mask guided knowledge distillation for single shot detector. In: IEEE. *2019 IEEE International Conference on Multimedia and Expo (ICME)*. [S.l.], 2019. p. 1732–1737. Citado na página 76.
- ZIMMERMANN, R. S.; SIEMS, J. N. Faster training of mask r-cnn by focusing on instance boundaries. *Computer Vision and Image Understanding*, Elsevier, p. 102795, 2019. Citado na página 75.