UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

Trabalho de Conclusão de Curso

SEGMENTAÇÃO DA PNEUMONIA CAUSADA POR COVID-19 EM IMAGENS TOMOGRÁFICAS

João Pedro Betanza Dal Caro

Natal/RN

2022

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

SEGMENTAÇÃO DA PNEUMONIA CAUSADA POR COVID-19 EM IMAGENS TOMOGRÁFICAS

Trabalho de conclusão de curso apresentado ao Departamento de Engenharia Biomédica da Universidade Federal do Rio Grande do Norte para obtenção do título de Bacharel em Engenharia Biomédica.

Graduando: João Pedro Betanza Dal Caro

Orientadora: Prof.ª Dra. Heliana B. Soares

Natal/RN

2022

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Caro, Joao Pedro Betanza Dal.
Segmentação da pneumonia causada por COVID-19 em imagens tomográficas / Joao Pedro Betanza Dal Caro. - 2022.
57 f.: il.

Monografia (graduação) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Curso de Engenharia Biomédica, Natal, RN, 2022.
Orientadora: Profa. Dra. Heliana Bezerra Soares.

1. COVID-19 - Monografia. 2. Segmentação - Monografia. 3. Processamento digital de imagens - Monografia. 4. Tomografia - Monografia. 5. Comprometimento pulmonar - Monografia. I. Soares, Heliana Bezerra. II. Título.

RN/UF/BCZM CDU 004.932

Elaborado por Ana Cristina Cavalcanti Tinoco - CRB-15/262

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE

CENTRO DE TECNOLOGIA

DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

SEGMENTAÇÃO DA PNEUMONIA CAUSADA POR COVID-19 EM IMAGENS TOMOGRÁFICAS

Banca Examinadora do Trabalho de Conclusão de Curso:

Prof.ª Dra. Heliana Bezerra Soares _____

Orientadora - UFRN

Prof. Dr. Anthony Andrey Ramalho Diniz _____

Avaliador Externo

Enga. Luísa Christina de Souza _____

Avaliadora Externa

Natal/RN

2022

DEDICATÓRIA

Dedico este trabalho a todos os que se esforçam em fazer o bem pelos outros.

AGRADECIMENTOS

Gostaria de agradecer primeiramente à professora Heliana, por ter acompanhado meu trabalho e me motivado a continuar ao longo de 3 semestres, além de ter se esforçado excepcionalmente para ajudar a todos os seus orientandos ao fim desse semestre.

Gostaria de agradecer à minha família próxima, que me deu suporte quando possível e me colocou nos trilhos quando necessário. Agradecer à minha família distante no Rio Grande do Sul em especial, minha tia Kamari, por ter me mostrado um dos caminhos para a paz espiritual, que hoje tem forte influência na minha vida.

Agradeço aos meus amigos do curso de Engenharia Biomédica: Jade, Jackson e Epitácio, por termos se ajudado e vivenciado juntos diversas experiências alegres, tristes e por vezes, desesperadoras nessa graduação. Agradeço também aos meus amigos do curso de Ciências de Tecnologias e outros cursos: *Stolen*, Raphael, Pareja, Pereira, Leon e outros.

Por fim, agradeço à natureza deste mundo em que vivemos. Nos últimos anos, vivenciei diversos momentos que parecem coincidência até demais. Penso que se acontecem situações de grande impacto em nossas vidas, das quais não temos o menor controle sobre, é porque precisamos da experiência e agradeço por todos esses momentos.

SUMÁRIO

LISTA DE FIGURAS IX
LISTA DE TABELAS XII
LISTA DE ABREVIAÇÕES, SIGLAS E SÍMBOLOS XIII
RESUMO XIV
ABSTRACT XV
1. INTRODUÇÃO 1
1.1. OBJETIVO GERAL 2
1.1.1. OBJETIVOS ESPECÍFICOS 3
1.2. ESTADO DA ARTE 3
1.3. ESTRUTURA DO TRABALHO 5
2. COVID-19 6
2.1. CARACTERÍSTICAS 6
2.1.1. SINTOMAS 7
2.2. DIAGNÓSTICO 10
3. PROCESSAMENTO DIGITAL DE IMAGENS 11
3.1. IMAGENS DIGITAIS 11
3.1.1 HISTOGRAMA 12
3.2. FILTROS 14
3.3. LIMIARIZAÇÃO 15
3.4. OPERAÇÕES MORFOLÓGICAS 16
3.4.1. ELEMENTO ESTRUTURANTE 16
3.4.2. EROSÃO E DILATAÇÃO 17
3.4.3. PREENCHIMENTO 18
3.4.4. ABERTURA E FECHAMENTO 18
3.4.5. TRANSFORMADA *TOP-HAT* 19
4. ALGORITMO DESENVOLVIDO 20
4.1. BASE DE DADOS 21
4.1.1 IMAGENS SELECIONADAS 21
4.2. PRÉ PROCESSAMENTO 22
4.3. MÁSCARA PULMONAR 25
4.4. MÁSCARA DE INFECÇÃO 26
5. RESULTADOS E DISCUSSÕES 30

6. CONCLUSÃO E TRABALHOS FUTUROS 38
6.1 TRABALHOS FUTUROS 39
REFERÊNCIAS BIBLIOGRÁFICAS 40

LISTA DE FIGURAS

FIGURA 1: ESTRUTURA VIRAL DO SARS-COV-2 7
FIGURA 2: DURAÇÃO DA COVID LONGA 8
FIGURA 3: COMPARATIVO ENTRE: (A) PULMÃO SAUDÁVEL, (B) COM PRESENÇA DE OVF, (C) COM PRESENÇA DE CONSOLIDAÇÃO..... 9
FIGURA 4: INTENSIDADES EM IMAGENS (A) EM ESCALA DE CINZA E (B) COLORIDAS..... 12
FIGURA 5: COMPARAÇÃO ENTRE IMAGENS EM (A) NÍVEIS DE CINZA E (B) IMAGENS BINÁRIAS. 12
FIGURA 6: COMPARAÇÃO ENTRE IMAGENS COM HISTOGRAMAS DIFERENTES, (A) IMAGEM ESCURA, (B) IMAGEM CLARA, (C) IMAGEM COM BAIXO CONTRASTE, (D) IMAGEM COM ALTO CONTRASTE..... 13
FIGURA 7: FILTRAGEM POR FILTRO DE MEDIANA COM *KERNEL* 3X3 14
FIGURA 8: LIMIARIZAÇÃO COM INTENSIDADE DE CORTE (A) 89 E (B) 153. 15
FIGURA 9: ELEMENTOS ESTRUTURANTES DE VIZINHANÇA-4 E VIZINHANÇA-8..... 17
FIGURA 10: FUNCIONAMENTO DOS OPERADORES DE (A) EROSÃO E (B) DILATAÇÃO. 17
FIGURA 11: (A) IMAGEM ORIGINAL E (B) SEU PREENCHIMENTO. 18
FIGURA 12: PROCEDIMENTO MORFOLÓGICO DE (A) ABERTURA E (B) FECHAMENTO..... 19
FIGURA 14: *TOP-HAT* MANTÉM REGIÕES PEQUENAS DE ALTA INTENSIDADE E REMOVE OUTRAS. 19
FIGURA 15: DIAGRAMA DE BLOCOS DOS PROCESSAMENTOS..... 20
FIGURA 16: EXEMPLO DAS IMAGENS (A) ORIGINAIS, (B) DE MÁSCARA PULMONAR E (C) MÁSCARA DE INFECÇÃO FORNECIDAS PELO BANCO DE DADOS DO *SLICE* 114 DO EXAME 9..... 21
FIGURA 17: EXEMPLOS DE IMAGENS (B) UTILIZADAS, (A) E (C) NÃO UTILIZADAS. 22
FIGURA 18: DIAGRAMA DE BLOCOS DO PRÉ-PROCESSAMENTO..... 22
FIGURA 19: EXIBIÇÃO DE (A) CORTE TRANSVERSAL DE EXAME DE TC E (B) SEU AJUSTE DE CONTRASTE. 23

FIGURA 20: (A) IMAGEM ORIGINAL, (B) TRANSFORMADA *TOP-HAT* SEM PROCESSAMENTO PRÉVIO E (C) SUA SUBTRAÇÃO. 23
FIGURA 21: *TOP-HAT* (A) ORIGINAL E (B) ATENUADA. 24
FIGURA 22: COMPORTAMENTO DA EQUAÇÃO DE ATENUAÇÃO. 24
FIGURA 23: (A) IMAGEM ORIGINAL FILTRADA, (B) *TOP-HAT* ATENUADA E FILTRADA E A (C) SUBTRAÇÃO ENTRE ELAS. 25
FIGURA 24: DIAGRAMA DE BLOCOS DO PROCESSAMENTO DA MÁSCARA PULMONAR. 25
FIGURA 25: SEQUÊNCIA DE OPERAÇÕES DE (A) LIMIARIZAÇÃO DA IMAGEM CARACTERÍSTICA DO PRÉ-PROCESSAMENTO, (B) PREENCHIMENTO A PARTIR DAS EXTREMIDADES, (C) EROSÃO, (D) INVERSÃO, (E) EROSÃO. 26
FIGURA 26: DIAGRAMA DE BLOCOS DO PROCESSAMENTO DA MÁSCARA DE INFECÇÃO 26
FIGURA 27: (A) MÁSCARA PULMONAR APLICADA À IMAGEM CARACTERÍSTICA DO PRÉ-PROCESSAMENTO (B) SUA TRANSFORMADA *TOP-HAT* E (C) SUA SUBTRAÇÃO. 27
FIGURA 28: SEQUÊNCIA DE OPERAÇÕES NO (A) RESULTADO DO ÚLTIMO PASSO: (B) DILATAÇÃO DA IMAGEM, (C) APLICAÇÃO DA MÁSCARA PULMONAR E (D) AJUSTE DE CONTRASTE. 27
FIGURA 29: (A) TABELA COM VALORES DOS LIMIARES ESCOLHIDOS E DE OTSU PARA OS EXAMES E *SLICES* CORRESPONDENTES, (B) GRÁFICO COM OS VALORES DA TABELA E APROXIMAÇÃO POLINOMIAL. 28
FIGURA 30: (A) IMAGEM A SER LIMIARIZADA PARA OBTER (B) A MÁSCARA DE INFECÇÃO. 29
FIGURA 31: SEQUÊNCIA DE OPERAÇÕES DO ALGORITMO PARA O *SLICE* 136, PACIENTE 9. 30
FIGURA 32: SEQUÊNCIA DE OPERAÇÕES DO ALGORITMO PARA O *SLICE* 175, PACIENTE 10. 31
FIGURA 33: EXEMPLOS DE (A) MÁSCARAS DE INFECÇÃO ORIGINAIS, (B) DESENVOLVIDAS E SUAS (C) INTERCESSÕES (*PIXELS* VERDADEIRO POSITIVOS EM BRANCO). 34

FIGURA 34: EXEMPLO DE (A) *SLICE* ORIGINAL, (B) MÁSCARA PULMONAR FORNECIDA PELO BANCO E (C) MÁSCARA PULMONAR DESENVOLVIDA. 36
FIGURA 35: EXEMPLO DE (A) *SLICE* ORIGINAL, (B) MÁSCARA DE INFECÇÃO FORNECIDA PELO BANCO E (C) MÁSCARA DE INFEÇÃO DESENVOLVIDA COM INFORMAÇÕES PERDIDAS DURANTE A SUBTRAÇÃO DA *TOP-HAT*. 36

LISTA DE TABELAS

TABELA 5.1: TABELA DE RESULTADOS PARA O PROCESSAMENTO DA MÁSCARA PULMONAR DOS *SLICES* 30 A 40 DO EXAME 2. 32
TABELA 5.2: TABELA DE RESULTADOS PARA O PROCESSAMENTO DA MÁSCARA DE INFECÇÃO DOS *SLICES* 30 A 40 DO EXAME 2..... 32
TABELA 5.3: NÍVEL DE COMPROMETIMENTO PULMONAR DESENVOLVIDO COMPARADO COM O SUGERIDO PELOS RADIOLOGISTAS DO BANCO CORONACASES. 33
TABELA 5.3: RESULTADO DE CADA EXAME COMPARADO COM OS RESULTADOS DO BANCO CORONACASES. 35
TABELA 5.4: COMPARAÇÃO ENTRE MÉTODOS DA LITERATURA E O DESENVOLVIDO. 35

LISTA DE ABREVIAÇÕES, SIGLAS E SÍMBOLOS

TC - Tomografia computadorizada

PDI - Processamento digital de imagens

OVF - Opacidade de vidro fosco

PPM - Padrão de pavimentação em mosaico

RT-PCR - Polimerase por transcrição reversa em tempo real

RT-qPCR - Polimerase por transcrição reversa em tempo real quantitativa

RDT - Teste de diagnóstico rápido

ELISA - Ensaio de imunoabsorção enzimática

CLIA - Imunoensaio por quimioluminescência CLIA

EM - Espectro eletromagnético

VP - Verdadeiro positivo

VN - Verdadeiro negativo

FP - Falso positivo

FN - Falso negativo

SENS - Sensibilidade

ESP - Especificidade

ACC – Acurácia

SDC - Coeficiente de *Sorensen-Dice*

CARO, João Pedro Betanza Dal. **Segmentação da pneumonia causada por COVID-19 em imagens tomográficas.** Trabalho de Conclusão de Curso, Graduação em Engenharia Biomédica, Universidade Federal do Rio Grande do Norte, 57 p., 2022.

RESUMO

Com o surgimento da pandemia de COVID-19, causada pelo novo coronavírus chamado de Sars-COV-2, houve uma corrida global na busca por formas de diagnosticar a doença e entender seus efeitos no corpo humano. Como os casos mais graves compreendem infeções pulmonares, o efeito do vírus nos pulmões possui alta relevância para os estudos da área, tornando bastante popular a utilização e análise de imagens de tomografia computadorizada (TC) do tórax. Visando auxiliar o profissional de saúde no acompanhamento da doença, este trabalho apresenta uma estratégia algorítmica com o objetivo de segmentar a região comprometida pela pneumonia de COVID-19. Utilizando técnicas de operações morfológicas e um método de limiarização adaptativa para adquirir as máscaras pulmonares e de infecções, o trabalho foi capaz de sugerir um nível percentual de comprometimento pulmonar do paciente com um erro médio de 3,55%. O algoritmo também apresentou uma acurácia média de 99,11% e uma especificidade de 99,65%.

Palavras-chave: COVID-19, segmentação, processamento digital de imagens, tomografia, comprometimento pulmonar.

CARO, João Pedro Betanza Dal. **Segmentation of pneumonia caused by COVID-19 in tomographic images.** Conclusion Work Project, Biomedical Engineering Bachelor Degree, Federal University of Rio Grande do Norte, 57p., 2022.

ABSTRACT

With the arrival of the COVID-19 pandemic, caused by the new coronavirus Sars-CoV-2, there was a global race in search of methods to diagnose the disease and understand its effects on the human body. As most severe cases refer to pulmonary infections, the effects of the virus in the lungs reached high interest for the area research, popularizing the usage of computed tomography (CT) chest scans. Aiming to ease the healthcare professional's follow-up, this work presents an algorithmic strategy with the objective of segmenting the COVID-19 compromised region within the lungs. Using morphologic operations and an adaptive limiarization technique to achieve lung and infection masks, the algorithm could suggest a compromise rate with a mean error of 3.55%. It also presented a mean accuracy of 99.11% and a specificity of 99.65%.

Keywords: COVID-19, segmentation, digital imaging processing, tomography, lung compromise.

1. INTRODUÇÃO

A COVID-19 surgiu no fim do ano de 2019, mas só foi descoberta no início de 2020 após a investigação de uma epidemia de pneumonia severa que havia surgido em Wuhan, na província de Hubei, no sul da China (WOROBEY, *et al*., 2022). A doença causada pelo vírus Sars-Cov-2 de natureza provavelmente zoonótica que surgiu do contato entre seres humanos e animais contaminados com o Sarbecovírus proveniente dos morcegos da família Rhinolophidae (LYTRAS *et al*., 2022).

Pacientes afetados pela COVID-19 podem apresentar uma variedade de sintomas, leves e graves, sendo os mais comuns: febre, tosse e falta de ar. Apesar do alvo principal da infecção ser os pulmões, diversos outros órgãos como os rins, fígado, sistema nervoso central e cardiovascular, podem ser afetados. Sintomas gastrointestinais como vômito, diarreia e dor abdominal também foram reportados em uma parcela significativa dos pacientes. A detecção de uma baixa quantidade de células de defesa e uma média menor de hemoglobina no sangue também ocorre com frequência (CIOTTI *et al*., 2020).

Devido à sua facilidade de transmissão, a doença foi reconhecida pela Organização Mundial da Saúde como pandemia em 11 de março de 2020 e, desde então, diversas medidas foram tomadas pelos governos para que se evitasse o contágio e a consequente morte por parte da população. O uso de máscaras se tornou indispensável e pessoas doentes ou idosas foram recomendadas a ficar em isolamento social em diversos países (CIOTTI *et al*., 2020).

Apesar disso, segundo a Atualização Epidemiológica Semanal da COVID-19 (*COVID-19 Weekly Epidemiological Update*) do dia 21 de setembro de 2022, disponibilizado pela Organização Mundial da Saúde – OMS, a COVID-19 atingiu 609.095.968 casos e 6.505.455 mortes confirmadas, sendo a Europa e as américas os responsáveis pelo maior número de casos (41% e 29% respectivamente) e pelo maior número de mortes (América com 44% e Europa com 32%) (OMS, 2022).

Dada a gravidade da situação, métodos foram desenvolvidos para diagnosticar a COVID-19 de forma mais eficiente. Ainda que o teste RT-PCR seja o procedimento padrão para diagnóstico, devido sua possível indisponibilidade e

baixa sensibilidade, alguns estudos sugerem o uso de imagens de tomografia computadorizada (TC), permitindo a visualização em 3 dimensões dos pulmões, podem ajudar no diagnóstico, no acompanhamento da evolução da doença, e na avaliação da severidade da mesma (PAKRAY, 2020; RAJINIKANTH *et al*., 2020).

Contudo, exames de imagem para pneumonias possuem diversas características que dificultam o trabalho do radiologista para definir a área contaminada pela doença, tornando a atividade de segmentar manualmente, diversas imagens de TC de apenas um paciente, um trabalho lento e tedioso (RAJINIKANTH *et al*., 2020).

Assim, as técnicas de processamento digital de imagens (PDI) compõem um conjunto de métodos contra a lentidão dos trabalhos de análise manual de imagens, além de possuir inúmeras áreas de aplicação. As áreas compreendem a aquisição de imagens em diversos espectros eletromagnéticos incluindo os que o ser humano se mostra incapaz de visualizar a olho nu como raios-x e ultrassons, ambos amplamente utilizados em imageamento médico, ajudando a tratar imagens e facilitar a visualização de informações significativas (GONZALEZ; WOODS, 2010).

Desse modo, para que seja possível determinar o nível de infecção, facilitando a realização de acompanhamento médico de acordo com a evolução da doença, foi desenvolvido um algoritmo capaz de realizar a segmentação de regiões de pneumonia causada por COVID-19 nas imagens de TC, melhorando a visualização das informações importantes e determinando a razão de comprometimento dos pulmões.

1.1. OBJETIVO GERAL

O objetivo deste trabalho foi desenvolver um algoritmo capaz de segmentar regiões afetadas pela COVID-19 em imagens pulmonares de tomografia computadorizada através de técnicas de processamento digital de imagens.

1.1.1. OBJETIVOS ESPECÍFICOS

- pesquisar bases de dados utilizadas na literatura;
- compreender o comportamento visual do COVID-19 e outras pneumonias em imagens de tomografia computadorizada;
- selecionar técnicas para segmentação da área de infecção por COVID-19;
- implementar técnicas para pré-processar os *slices* dos exames de TC;
- efetuar o processamento das imagens para realizar a extração de características relevantes;
- calcular a taxa de infecção pulmonar;
- comparar os resultados com as máscaras disponibilizadas pela base de dados.

1.2. ESTADO DA ARTE

Buscando destacar o conhecimento da literatura sobre a COVID-19 no que diz respeito a imagens médicas, Kanne *et al*. (2021) compilaram informações de diversas publicações, e a importância do PDI para a área devido à utilidade das imagens médicas para avaliação da gravidade dos casos e manejo de cada um deles. São discutidas as diferentes técnicas de imageamento; a alta eficiência de inteligências artificiais para diagnóstico; assim como características físicas da infecção presentes nas imagens.

Rajinikanth *et al.* (2020) elaboraram uma técnica de processamento de imagens para adquirir, em imagens de TC pulmonares, a área afetada por COVID-19. O método foi baseado em 2 etapas de processamento principais, sendo a primeira delas o isolamento do pulmão usando um corte de intensidade; e a segunda o isolamento das regiões infectadas dentro dos pulmões, usando a técnica de *watershed*. A técnica foi inicialmente implementada em imagens de TC do plano coronal e em seguida, experimentada também no plano transversal. Ainda que o trabalho não apresente resultados de comparação, os resultados visuais condizem com o descrito na literatura sobre a detecção de pneumonias.

Yao *et al.* (2021) elaboraram um método para treinar redes de *Deep Learning* sem a necessidade de bancos de dados com imagens de tomografia

computadorizada (TC) de pacientes com COVID-19 segmentadas. Com o conhecimento de que esses bancos são raros; a segmentação foi feita de forma manual e subjetiva; e que pulmões saudáveis apresentam estruturas que podem ser confundidas com a infeção, os pesquisadores decidiram treinar a rede de *Deep Learning* com imagens de TC de pulmões saudáveis e construir um algoritmo simulador da pneumonia para que fosse possível detectar onde estaria apenas a infeção. A rede apresentou um resultado, para o mesmo de banco de dados deste trabalho, de 66,2% de sensibilidade, 82,1% de precisão e um coeficiente de Sorensen-Dice de 69,8%.

Fields *et al*. (2021) apresentou um comparativo das características visuais da infecção por COVID-19 entre os 3 tipos de imagem (tomografia computadorizada, PET *Scan* e ressonância magnética) mais utilizados com o objetivo de avaliar suas vantagens e desvantagens. Devido à versatilidade do exame e alta fidelidade de detalhes, ainda que os resultados apresentados pudessem ser de qualquer pneumonia, a tomografia computadorizada se apresentou como melhor candidata como exame de imagem para acompanhamento da doença.

Behnaz *et al*, (2010) criou uma interface gráfica capaz de realizar uma segmentação semiautomática de tumores no fígado. O algoritmo realiza uma filtragem de difusão anisotrópica na imagem e, com o auxílio do *input* do usuário foi selecionada uma área de interesse para então ocorrer a segmentação baseada em níveis de intensidade. Comparando o resultado com uma segmentação manual, o trabalho proposto obteve uma diferença média de área tumoral de 7%, diminuindo o tempo de segmentação manual em 30 minutos em situações mais complexas.

OULEFKI *et al*. (2021) desenvolveu um algoritmo capaz de segmentar e medir automaticamente as regiões lesionadas por COVID-19 em imagens de TC no ambiente do MATLAB. O algoritmo funciona utilizando e otimizando a entropia de Kapur para encontrar limiares para realizar a limiarização de pequenas sub-regiões da imagem. O algoritmo alcançou resultados de acurácia de 98,9%, sensibilidade de 73,3% e especificidade de 99,4%.

Fan *et al*. (2020) utilizaram uma *Deep Network* em conjunto com um sistema semi-supervisionado para segmentação de COVID-19 em imagens de

tomografia computadorizada, que por sua vez criou um banco de dados para ser utilizado pela *Deep Network*. Após o treino da rede, foram alcançados os resultados de 72,5% de sensibilidade, especificidade de 96% e coeficiente de Sorensen-Dice de 73,9%.

Saood e Hatem (2021) utilizaram duas redes de *Deep Learning* populares e compararam seus resultados a partir de um banco de dados de referência, previamente segmentado por outra método automático. Utilizando o otimizador estocástico ADAM, as redes *U-NET* e *SegNet* foram treinadas e obtiveram, respectivamente, uma média de sensibilidade de 66.1% e 67.3%, uma média de especificidade de 95,8% e 95,9% e um coeficiente de Sorensen-Dice de 33,7% e 31,7%.

Neste trabalho, foi desenvolvido um algoritmo capaz de segmentar, sem o auxílio de qualquer tipo de inteligência artificial, a área de pneumonia causada por COVID-19. Utilizando técnicas básicas de PDI e uma limiarização de Otsu (1972) adaptada, o algoritmo alcançou uma sensibilidade de 60,08%, uma especificidade de 99,65%, uma acurácia de 99,11% e um coeficiente de *Sorensen-Dice* de 58,35%.

1.3. ESTRUTURA DO TRABALHO

Este trabalho foi seccionado em 6 partes. Na seção 2, serão apresentadas características comuns referentes a todas as pneumonias e, de forma mais específica, o comportamento do vírus Sars-Cov-2 enquanto atua no corpo humano. Na seção 3, serão abordados os conceitos e técnicas voltados para o processamento digital de imagens que foram utilizados no algoritmo, explorando as técnicas que envolvem o contraste de uma imagem e operações morfológicas. Na seção 4 será detalhado o algoritmo desenvolvido, descrevendo cada etapa necessária para chegar aos resultados que, por sua vez, serão apresentados na seção 5 ao compará-los com outros resultados encontrados na literatura. Na seção 6, estão descritas as conclusões do trabalho e as perspectivas para futuros trabalhos.

2. COVID-19

O novo coronavírus SARS-CoV-2 possui uma similaridade de sua sequência nucleotídicas de 79% com o SARS-CoV (causador da SARS em 2002) e consequentemente, possuem muitas características em comum. Ambos foram coronavírus que apresentaram transmissão zoonótica, foram espalhados entre humanos e causaram uma síndrome respiratória aguda grave ao se ligarem às células hospedeiras pela angiotensina ao converter a enzima ACE2, levando a uma alta taxa de mortalidade nas últimas 2 décadas (BARUPAL *et al*., 2020).

Estudos sugerem que o vírus do COVID-19 tenha se originado de morcegos, e utilizado pangolins como hospedeiro intermediário até que ocorresse a zoonose aos seres humanos no mercado de Huanan, onde era vendida uma diversidade de animais silvestres. Nesse local, amostras ambientais como as de gaiolas, carrinhos de compras e *freezers* que tinham relação com o mercado de animais silvestres apresentaram resultado positivo para o vírus SARS-CoV-2 (BARUPAL *et al*., 2020; WOROBEY *et al*., 2022).

A partir de uma amostra de lavado broncoalveolar, o SARS-CoV-2 foi isolado pela primeira vez e, posteriormente, também foi detectada presença do RNA viral em esfregaços nasofaríngeos, fezes e em fluidos corporais como sangue, urina e saliva (BARUPAL *et al*., 2020).

Sendo assim, a doença transmitida de entre seres humanos por vetores passivos, contato físico, gotículas de água, transmissão nosocomial e zoonose. O contato com mucosas da boca e nariz colabora grandemente com a infecção mesmo em indivíduos assintomáticos ou em período de incubação e, devido a isso, políticas e recomendações como o uso de máscaras, uso de álcool em gel ou sabão para lavar as mãos constantemente, manter distanciamento de 1 metro de outras pessoas, evitar contato físico e *lockdown* foram implementados em diversos países (BARUPAL *et al*., 2020; OMS, 2022).

2.1. CARACTERÍSTICAS

Os coronavírus são partículas envelopadas esféricas não segmentadas, de 150 a 160 nm de diâmetro, ligadas a RNA de fita simples. Proteínas virais mais

relevantes desses vírus são as proteínas do nucleocapsídeo, que protege o RNA e colabora na replicação e transcriptase do genoma; da membrana, que define o formato do vírus e sua organização; da glicoproteína *spike*, responsável pela ligação com as células hospedeiras; e da proteína da pequena membrana do envelope, que ao interagir com a proteína da membrana, forma o envelope viral. Diferente de outros coronavírus, o SARS-CoV-2 tem ainda a capacidade de codificar uma glicoproteína suplementar que possui propriedades de acetilterase, e hemaglutinação (BARUPAL *et al*., 2020). As estruturas que compõem o SARS-CoV-2 podem ser observadas na Figura 1.

Figura 1: Estrutura viral do SARS-CoV-2

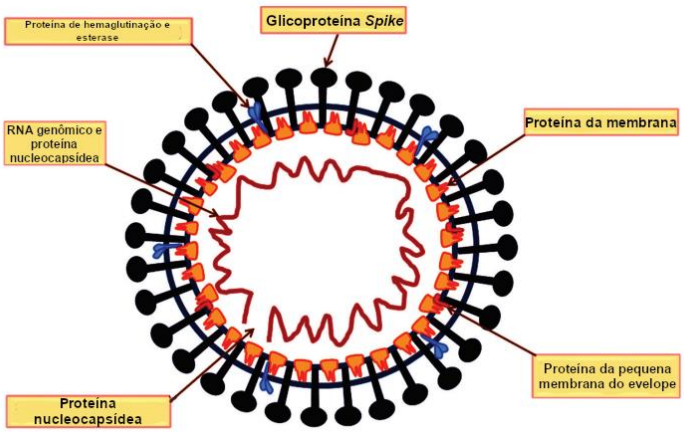

Fonte: Adaptado de Barupal *et al*., 2020

2.1.1. SINTOMAS

A COVID-19 passa por um período de incubação no qual não apresenta sintomas por aproximadamente 5 dias e, depois desse período, há mais 4 estágios de desenvolvimento da doença referentes à condição pulmonar do paciente. Os sintomas se agravam gradativamente até aproximadamente o 10º dia, no 3º estágio e em seguida, começam a amenizar (LAUER *et al*., 2020; PAN *et al*., 2020).

A doença afeta uma diversidade de órgãos dependendo da capacidade imunológica de cada indivíduo, portanto, os sintomas podem ser variados. Normalmente, pacientes com sintomas moderados ou leves se deparam com febre baixa, tosse seca, dor de garganta, fadiga, irritação respiratória e mal-estar, mas também podem sentir dores de estômago, perda de olfato, rouquidão, dor muscular,

dor no peito, diarreia e confusão. Em casos em que há risco de morte, além da possibilidade de sentirem os sintomas anteriores em maior intensidade, o paciente apresenta febre alta acompanhada de hipóxia causada por pneumonia (BARUPAL *et al*., 2020).

Outros sintomas que a COVID-19 pode ocasionar são os sintomas ligados à Covid longa. Com escala de duração representada na Figura 2, os sintomas podem durar até 12 semanas ou mais e se originam das sequelas deixadas pela doença durante sua fase aguda, inflamação, efeitos colaterais de medicamentos, problemas psicológicos, entre outros. Os sintomas podem ser fadiga, falta de ar, tosse, dor no peito, palpitações, dor de cabeça, dor nas articulações, mialgia e fraqueza, insônia, formigamento, diarreia, erupção cutânea ou perda de cabelo, equilíbrio e marcha prejudicados, problemas neuro cognitivos, incluindo problemas de memória e concentração e piora da qualidade de vida (RAVEENDRAN; JAYADEVAN; SASHIDHARAN, 2021).

Figura 2: Duração da COVID Longa

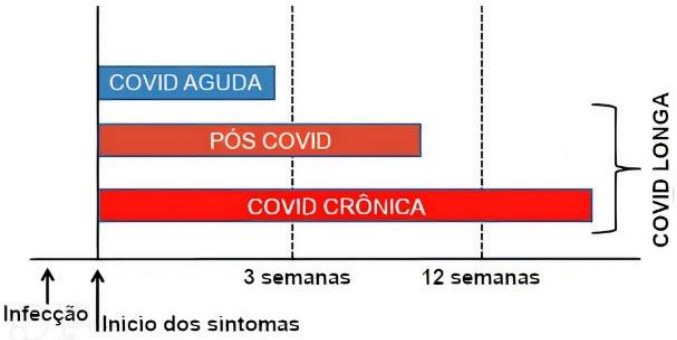

Fonte: Adaptado de Raveendran *et al.*, 2021

2.1.1.1. PNEUMONIA

A aspiração de secreções nasofaríngeas ou orofaríngeas consiste na principal forma de contaminação das vias aéreas inferiores, ainda que seja impedida enquanto acordados pelos reflexos da epiglote, quando dormimos, aspiramos regularmente pequenas quantidades dessas secreções, que contêm uma infinidade de microrganismos que estavam no trato respiratório ou que foram adquiridos há pouco tempo através do contato da mão contaminada com a boca ou nariz (BROADDUS, 2016).

Como descrito por Pan *et al.*, (2020), após o início dos sintomas, a COVID-19 apresenta 4 fases principais de desenvolvimento baseadas na evolução da pneumonia causada:

- De 0 a 4 dias: Opacidade de vidro fosco (OVF) com padrão de pavimentação em mosaico (PPM) e consolidação.
- De 5 a 8 dias: Expansão da OVF a outros lobos pulmonares com PPM e consolidação.
- De 9 a 13 dias: Consolidação como principal manifestação da pneumonia, diminuição da OVF e PPM.
- Mais de 14 dias: Consolidação parcialmente absorvida e sem PPM.

Representado na Figura 3(a), um pulmão saudável apresenta uma imagem com *background* da imagem limpo, contendo apenas as informações bem definidas que compõem os vasos sanguíneos, brônquios e alvéolos. Em comparação, A OVF compreende uma região nebulosa que mantém a visualização das delimitações dos vasos e brônquios nas imagens de TC, ocorre devido ao preenchimento parcial dos brônquios e alvéolos pulmonares com algum material diferente do ar, observado na Figura 3(b). O PPM se refere à organização das regiões com OVF, que tendem a preencher os lobos pulmonares, que são bem delimitados. Observada na Figura 3(c), a consolidação diz respeito ao preenchimento completo dos alvéolos com macrófagos e fragmentos de neutrófilos, impedindo as trocas gasosas (DONG *et al*., 2020).

Figura 3: Comparativo entre: (A) pulmão saudável, (B) com presença de OVF, (C) com presença de consolidação

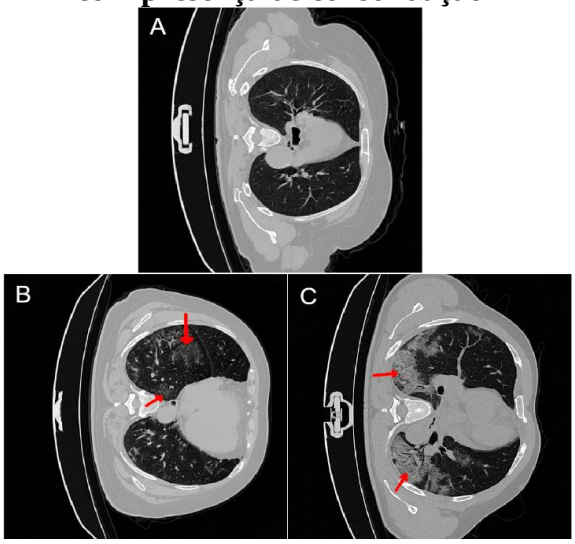

Fonte: Adaptado de Paiva (2020).

2.2. DIAGNÓSTICO

Para diagnóstico, amostras do nariz e da garganta podem ser usadas para detectar o COVID-19 por meio de ensaios de reação em cadeia da polimerase por transcrição reversa (RT-PCR) em tempo real. Apesar da alta especificidade do RT-PCR, podem surgir resultados falso-positivos ou falso-negativos. Indivíduos com resultados negativos de RT-PCR e com manifestações clínicas podem ser solicitados a realizar tomografia computadorizada (TC) de acompanhamento e outros testes de esfregaço (SARANGI *et al.*, 2022).

Atualmente, o RT-PCR quantitativo (RT-qPCR) e o sequenciamento de alto rendimento são as ferramentas de diagnóstico para a infecção por SARS-CoV-2 mais utilizadas, sendo o primeiro deles o mais prático e comum. Apesar disso, a detecção do método RT-qPCR ainda possui uma sensibilidade de 50% a 79% e, portanto, pacientes com resultado negativo desse exame são recomendados a refazer o teste e realizar um exame de TC de alta resolução para a triagem. Ainda que exames de TC não sejam capazes de identificar a COVID-19, eles conseguem detectar a presença de uma pneumonia, o que facilita o acompanhamento médico (SARANGI *et al.*, 2022).

Há também testes sorológicos como o ensaio de imunoabsorção enzimática (ELISA), o teste de diagnóstico rápido (RDT), o imunoensaio por quimioluminescência (CLIA) e o teste de neutralização. O RDT, um exame que utiliza a mesma tecnologia que testes de gravidez e requer uma gota de sangue para detecção de anticorpos que atuem contra o SARS-CoV-2 (IgA, IgM ou IgG). CLIA e ELISA são ambos sequenciamentos de alto rendimento que funcionam ligando os anticorpos a uma superfície e adicionando uma substância química que reagirá com os anticorpos, gerando uma mudança de coloração que pode ser medida por um espectrofotômetro. O teste de neutralização consiste no teste de prevenção da infecção viral pelos anticorpos, feito com o vírus e células *in vitro* (SARANGI *et al.*, 2022).

3. PROCESSAMENTO DIGITAL DE IMAGENS

Imagens são de extrema importância para nós humanos pois dizem respeito ao mais avançado de nossos sentidos, a visão. Ainda assim, existem muitas informações “invisíveis” no mundo que não estão contidas na banda visual do espectro eletromagnético (EM). Portanto, utilizamos de tecnologias únicas para capturar imagens a partir de bandas não visíveis do EM, como raios X, ultravioleta, infravermelha, micro-ondas, rádio, etc. (GONZALEZ; WOODS, 2010).

Segundo Gonzalez e Woods (2010), o processamento digital de imagens (PDI) corresponde ao processamento de imagens digitais, com o auxílio de computadores digitais e suas ferramentas, com o intuito de atingir um certo objetivo.

PDI apresenta alguns processos clássicos fundamentais, sendo os mais relevantes para este trabalho a aquisição, o processo de obter a imagem a ser utilizada, podendo conter pré-processamentos; realce, a manipulação de uma imagem para facilitar um processamento específico; processamento morfológico, a manipulação das formas contidas em uma imagem, para extrair informações importantes; segmentação, a divisão de uma imagem em uma ou mais partes; e a exibição de imagens (GONZALEZ; WOODS, 2010).

Essa seção apresentará a descrição das técnicas e ferramentas de PDI utilizadas para atingir o objetivo deste trabalho, a segmentação de regiões de pneumonia causada por COVID-19.

3.1. IMAGENS DIGITAIS

Para entender as técnicas de PDI, se faz necessário primeiro o entendimento das imagens digitais. Imagens digitais são matrizes finitas na qual cada posição possui um nível de intensidade, para imagens em níveis de cinza, e três níveis para imagens coloridas (no padrão RGB por exemplo, um para vermelho, verde e azul), essas posições são chamadas de *pixels* (GONZALEZ; WOODS, 2010).

A intensidade denota o atributo referente à variação de luz monocromática que um *pixel* da imagem possui, podendo variar do escuro, com intensidade 0, ao

claro, com intensidade 255. Quando essa intensidade se refere à escala do preto ao branco, dizemos que o *pixel* está na escala de cinza (GONZALEZ; WOODS, 2010). A influência das intensidades cromáticas e monocromáticas em imagens digitais pode ser visualizada na Figura 4.

Figura 4: Intensidades em imagens (A) em escala de cinza e (B) coloridas

Fonte: MathWorks, 2022.

De forma alternativa, existem as imagens binárias, nas quais o nível de intensidade varia apenas entre dois valores, entre o preto e o branco, não possuindo uma escala de cinza (ABDULRAHMAN e VAROL, 2020). O Gonzalez (2010) descreve que os *pixels* de valor 1 são a frente da imagem, e os de valor 0 o fundo, utilizados amplamente em operações morfológicas e de segmentação (Figura 5).

Figura 5: Comparação entre imagens em (a) níveis de cinza e (b) imagens binárias.

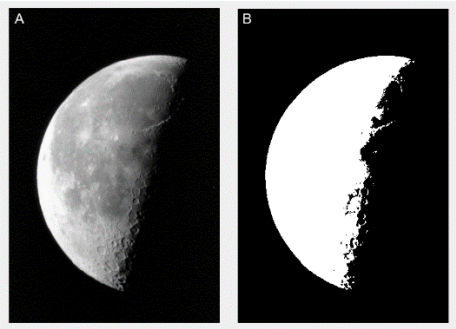

Fonte: Autor.

3.1.1 HISTOGRAMA

Imagens médicas podem ser obtidas através de uma variedade de tecnologias, modelos de equipamentos e condições ambientais, com o auxílio ou

não de contraste. Desse modo, dificilmente são encontradas imagens brutas de equipamentos diferentes com as mesmas propriedades e, portanto, a análise do histograma das imagens para cada caso possui alta relevância (GONZALEZ; WOODS, 2010).

Um histograma consiste na representação mais utilizada para exibir a distribuição das intensidades dos *pixels* de uma imagem. Deriva de uma função discreta $h(k) = n$ onde k representa o nível de intensidade e n a quantidade de *pixels* com a intensidade k, podendo ser normalizado ao se dividir n pela quantidade de *pixels* total da imagem (GONZALEZ; WOODS, 2010).

Histogramas são importantes para PDI por nos fornecerem uma série de estatísticas úteis sobre a imagem e nos ajudam a realizar compressões, segmentações e realces de imagens. Referente aos realces, as imagens apresentam propriedades diferentes dependendo da distribuição do histograma, como observado na Figura 6 (GONZALEZ; WOODS, 2010).

Uma imagem clara apresenta em seu histograma, uma quantidade maior de *pixels* com altas intensidades, enquanto imagens escuras possuem mais *pixels* de baixa intensidade. Imagens com baixo contraste são vistas como sem brilho e desbotadas e costumam não apresentar uma boa distribuição de intensidades, concentrando-as no meio do histograma. Enquanto uma imagem com alto contraste possui uma ampla distribuição de intensidades (GONZALEZ; WOODS, 2010).

Figura 6: Comparação entre imagens com histogramas diferentes, (A) imagem escura, (B) imagem clara, (C) imagem com baixo contraste, (D) imagem com alto contraste.

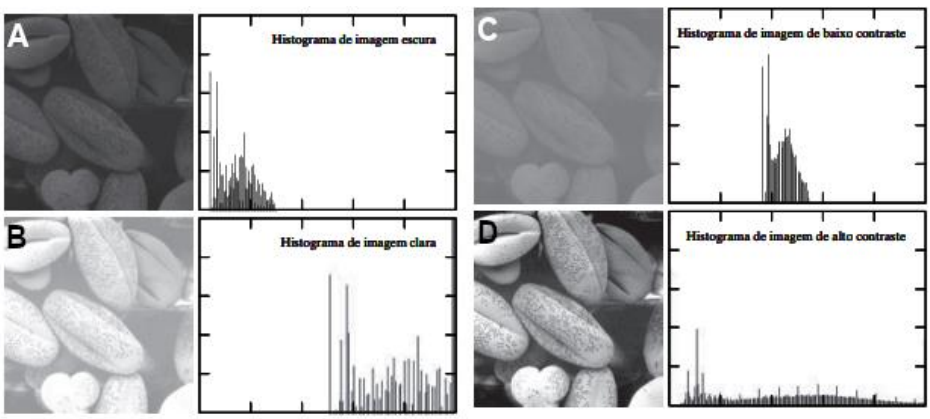

Fonte: Adaptado de Gonzalez e Woods, 2010.

3.2. FILTROS

A filtragem diz respeito a um processo diretamente interligado com o aprimoramento da imagem por se tratar de um método capaz de remover ruídos, destacar bordas, ou borrar a imagem. A filtragem pode ocorrer tanto no domínio espacial, atuando diretamente sob os *pixels* da imagem com o auxílio de uma máscara ou *kernel*, quanto no domínio da frequência. A filtragem espacial possui ainda a possibilidade de não ser linear, tornando-a mais versátil que a filtragem no domínio da frequência (GONZALEZ; WOODS, 2010; SOLOMON; BECKON, 2011).

Realizada pela convolução entre a imagem que se deseja filtrar e um *kernel*, a filtragem pode ser descrita, para imagens bidimensionais, como

$$g(x,y) = f(x,y) * h(x,y) \tag{3.1}$$

onde *g(x,y)* representa a imagem filtrada, *f*(x,y) a imagem antes do filtro, e *h*(x,y) o *kernel* utilizado (SOLOMON; BRECKON, 2011).

O *kernel* dado por uma matriz de *pixels* menor que a imagem que se deseja filtrar e durante a convolução, percorre os *pixels* da imagem de interesse e gera uma nova. A Figura 7 representa as etapas da filtragem por mediana, nesse exemplo, ao utilizar um *kernel* 3x3 com valor 1 em todos os seus *pixels*, o mesmo percorre a imagem e em seguida, a mediana dos valores contidos no *kernel* substitui o *pixel* central (GONZALEZ; WOODS, 2010; SOLOMON; BECKON, 2011).

Figura 7: Filtragem por filtro de mediana com *kernel* 3x3

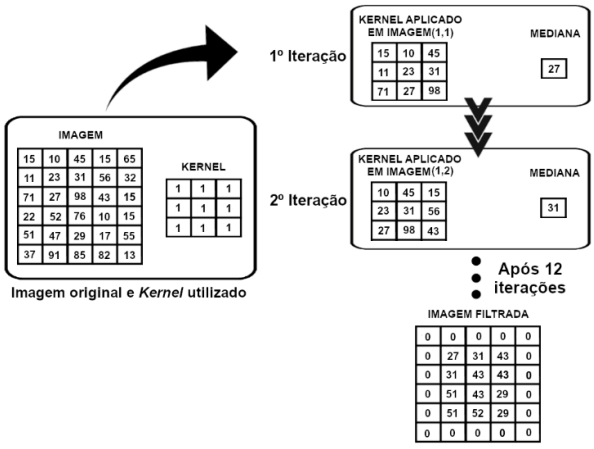

Fonte: Autor.

3.3. LIMIARIZAÇÃO

Nas imagens médicas, a segmentação de regiões específicas costuma possuir interesse clínico, seja para medir o tamanho e formato de um tumor ou nódulo, a dilatação de um vaso, a área comprometida por um aneurisma, etc. Além disso, as propriedades físicas de determinados tecidos no corpo humano permitem a diferenciação deles nas imagens médicas a partir da disparidade de suas intensidades (SOLOMON; BRECKON, 2011).

O método da limiarização serve para realizar a segmentação de informações de interesse quando há dois grupos predominantes de intensidades diferentes. Denotada pela Equação (3.2), a limiarização se trata de um método de binarização com um valor limiar de entrada *T* referente à intensidade de corte. *Pixels* na posição *x* e *y* com intensidade *f(x,y)* maior que a intensidade de corte escolhida se tornam 1 e *pixels* com intensidade menor, 0 (ABDULRAHMAN e VAROL, 2020).

$$g(x,y) = \begin{cases} 1, & f(x,y) > T \\ 0, & f(x,y) \leq 0 \end{cases} \tag{3.2}$$

Dependendo do limiar escolhido, as imagens binarizadas apresentam resultados diferentes, como apresentado na Figura 8. Existem alguns métodos para realizar o cálculo do valor ideal para o corte da limiarização, mas o método desenvolvido por Otsu (1979), utilizado neste trabalho.

Figura 8: Limiarização com intensidade de corte (a) 89 e (b) 153.

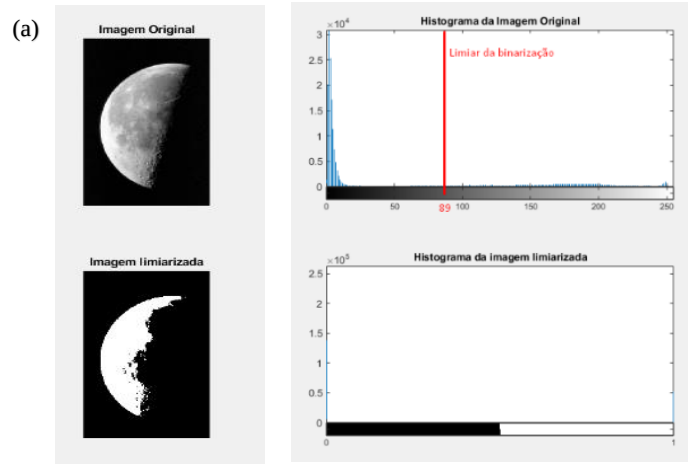

(b)

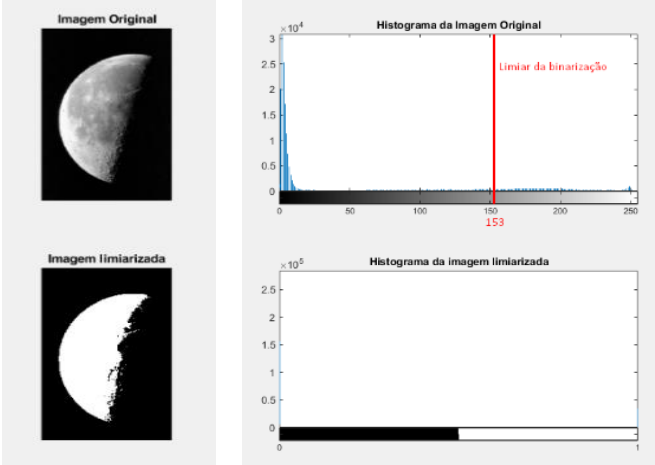

Fonte: Autor.

3.4. OPERAÇÕES MORFOLÓGICAS

Segundo Solomon e Breckon (2011), a palavra morfologia se refere ao estudo da forma ou estrutura e, no campo de PDI, as operações morfológicas são úteis tanto na extração de descritores importantes relacionados às formas e estruturas da imagem, quanto para modificar *pixels* de frente e fundo, com o auxílio de um elemento estruturante, para atingir objetivos específicos.

A princípio, as operações morfológicas podem ser aplicadas a qualquer tipo de imagem, mas são frequentemente usadas em imagens binárias devido à facilidade do entendimento e aplicação (SOLOMON; BRECKON, 2011).

3.4.1. ELEMENTO ESTRUTURANTE

Em imagens binárias, o *kernel*, ou elemento estruturante, também representa uma matriz de tamanho menor que a imagem original e, nesse caso, realiza modificações na forma da imagem fazendo uso das propriedades de conectividade e vizinhança (GONZALEZ; WOODS, 2010; SOLOMON; BECKON, 2011).

A conectividade diz respeito à relação entre um *pixel* central e os *pixels* de uma vizinhança pré-determinada. Caso possuam o mesmo valor, dizemos que eles fazem parte de uma única região conectada e que não são conectados caso contrário (GONZALEZ; WOODS, 2010; SOLOMON; BECKON, 2011).

As vizinhanças mais usadas são as *vizinhanças-4* e *vizinhança-8*, ambas destacadas visualmente na Figura 9. A primeira verifica a conectividade de um *pixel* central com seus *pixels* horizontais e verticais vizinhos enquanto a

vizinhança-8 verifica se estão conectados os *pixels* vizinhos diagonais. Ambas determinam a forma como a imagem deve ser processada durante algum procedimento, oferecendo resultados distintos (GONZALEZ; WOODS, 2010; SOLOMON; BECKON, 2011).

Figura 9: Elementos estruturantes de vizinhança-4 e vizinhança-8

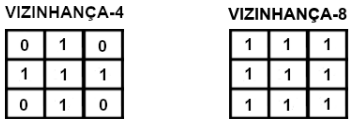

Fonte: Autor.

3.4.2. EROSÃO E DILATAÇÃO

A erosão e a dilatação são os operadores morfológicos mais básicos que existem, de modo que todas as outras operações podem ser descritas como combinações entre eles. Assim como na filtragem espacial, essas operações funcionam de forma semelhante à convolução do *Kernel*, modificando a imagem conforme o elemento estruturante a percorre (SOLOMON; BRECKON, 2011).

A erosão (Figura 10(a)) descrita como um processo que erode a imagem, mantendo apenas os *pixels* que possuem outros *pixels* de intensidade 1 a sua volta no mesmo formato e em quantidade que o elemento estruturante, envolvendo-o completamente (SOLOMON, 2011).

A dilatação (Figura 10(b)) dilata a imagem, modificando *pixels* para o valor de intensidade 1 se houverem quaisquer outros *pixels* de intensidade 1 dentro do campo do elemento estruturante, caso ele estivesse sobrepondo centralizadamente o *pixel* a ser modificado (SOLOMON; BRECKON, 2011).

Figura 10: Funcionamento dos operadores de (a) erosão e (b) dilatação.

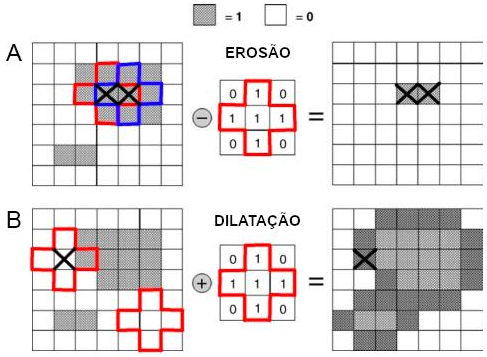

Fonte: Adaptado de Solomon, 2011.

3.4.3. PREENCHIMENTO

Após a binarização de uma imagem, espaços vazios residuais dentro de regiões que normalmente representam uma única região são comuns e, para lidar com esse problema, o processo de preenchimento pode ser utilizado. O preenchimento (Figura 11) toma como base um *pixel* pertencente a um espaço vazio ou um *pixel* qualquer definido previamente. Para determinar se um *pixel* faz parte de um espaço vazio, há a verificação da existência de qualquer caminho para chegar às bordas da imagem sem passar por um *pixel* de valor 1. Para preencher, sequências de dilatações do *pixel* de referência são executadas até que o espaço esteja completamente preenchido (SOLOMON; BRECKON, 2011).

Figura 11: (a) Imagem original e (b) seu preenchimento.

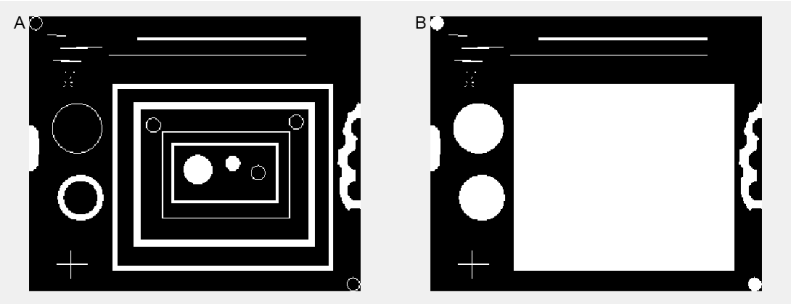

Fonte: Autor.

3.4.4. ABERTURA E FECHAMENTO

A abertura, uma operação morfológica que consiste na erosão seguida por dilatação utilizando o mesmo elemento estruturante e sua aplicação responsável por remover pequenos objetos isolados, eliminar conexões estreitas entre objetos e suavizar suas bordas. O fechamento, por sua vez, compreende a dilatação seguida por erosão, usando também um mesmo elemento estruturante. Sua função tem como objetivo remover pequenos buracos e conectar objetos que possuem pouco espaço entre si (GONZALEZ; WOODS, 2010; SOLOMON; BRECKON, 2011).

Ambas as operações também podem ser executadas em imagens em níveis de cinza. A abertura (Figura 12(a)), nesse caso, possui a tendência de remover pequenas regiões de alta intensidade enquanto o fechamento (Figura 12(b)) faz o

mesmo, mas para pequenas regiões de baixa intensidade (SOLOMON; BRECKON, 2011).

Figura 12: Procedimento morfológico de (a) abertura e (b) fechamento.

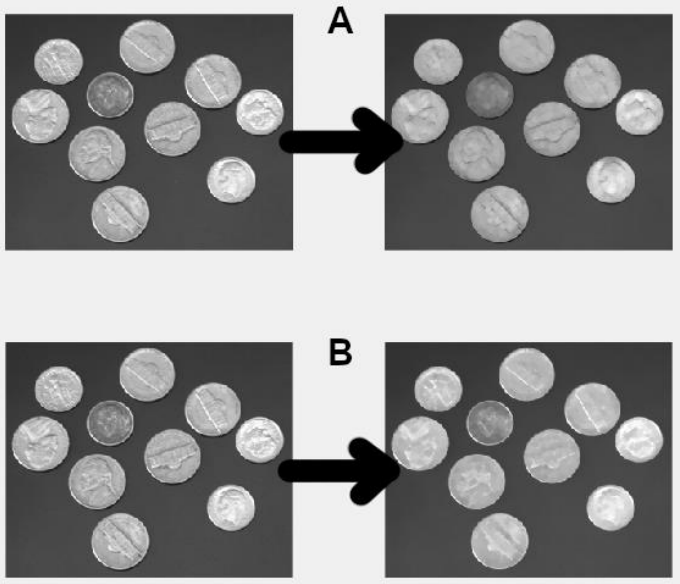

Fonte: Autor.

3.4.5. TRANSFORMADA *TOP-HAT*

Segundo Solomon e Breckon (2011), a transformada *top-hat* foi definida como a diferença entre a imagem e ela mesma após uma abertura. Como visto anteriormente, a abertura consiste na remoção de regiões pequenas com alta intensidade e mantém as regiões mais escuras. Desse modo, como visto na Figura 14, quando subtraímos da imagem original a sua abertura, temos apenas as regiões pequenas com alta intensidade.

Figura 14: *Top-Hat* mantém regiões pequenas de alta intensidade e remove outras.

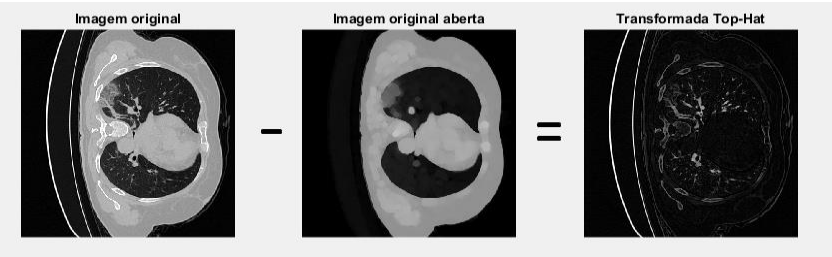

Fonte: Autor.

4. ALGORITMO DESENVOLVIDO

Nesta seção, são apresentados o banco de dados e as técnicas utilizadas para realizar a segmentação da pneumonia causada por COVID-19 em imagens de tomografia computadorizada. O algoritmo foi desenvolvido no programa *MATLAB* e possui três etapas, o pré-processamento, o processamento da máscara pulmonar e o processamento da máscara de infecção. As três partes possuem suas etapas definidas no diagrama de blocos da Figura 15.

Figura 15: Diagrama de blocos dos processamentos.

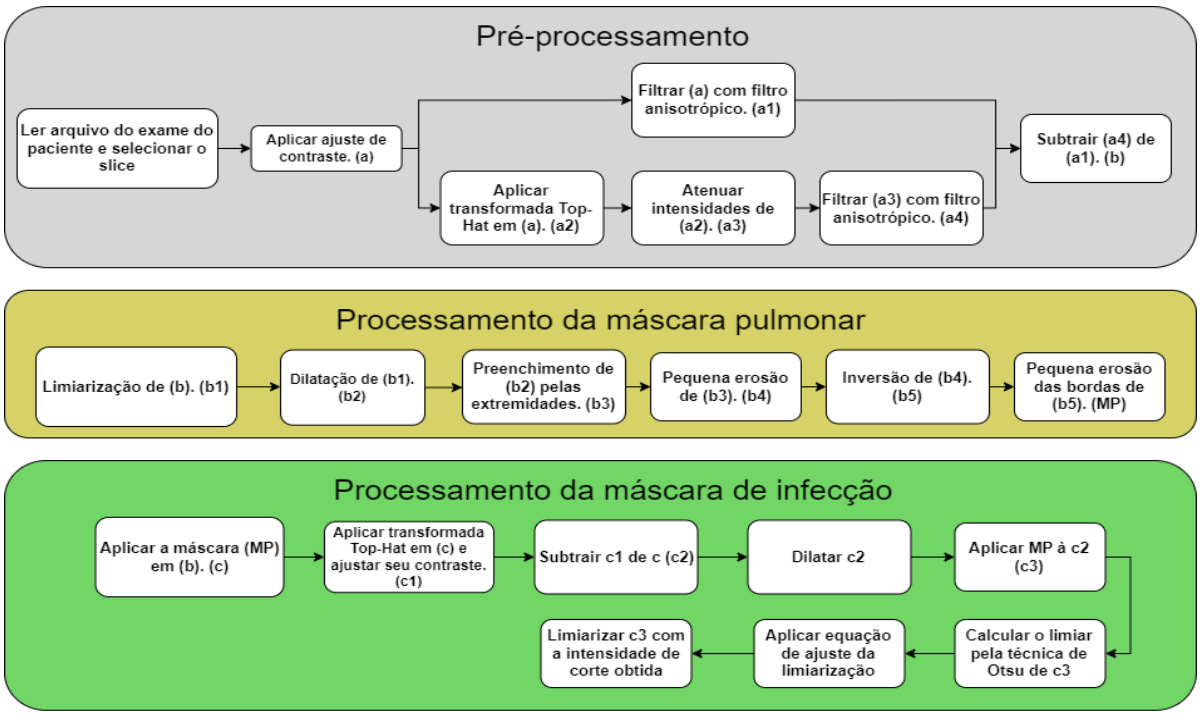

Fonte: Autor.

No pré-processamento, foi realizada desde a leitura até a obtenção de uma imagem característica que serve de base para os processamentos da máscara pulmonar e de infecção. No processamento da máscara pulmonar, são empregadas operações morfológicas que fornecem ao fim uma máscara que, se aplicada ao *slice* do exame, consegue isolar o pulmão do resto da imagem. Por fim, o processamento da máscara de infecção utiliza a máscara pulmonar aplicada à imagem característica do pré-processamento, alguns passos são então executados para que seja obtida a região da pneumonia.

4.1. BASE DE DADOS

A base de dados utilizada neste trabalho foi o *COVID-19 CT Lung and Infection Segmentation Dataset*, um banco que contém um conjunto de 10 exames de tomografia computadorizada retirados do site CORONACASES.ORG (PAIVA, 2020). Os exames foram originalmente publicados com a intenção de treinar radiologistas para a doença que, na época da publicação era nova e não tinha o seu comportamento radiológico conhecido. Os exames estão no formato *.nii* e possuem uma média de 262 *slices*, cada um com resolução de 512x512 *pixels*, oferecendo uma ótima resolução espacial longitudinal.

Somado a esses exames, Jun *et al*, (2020) produziram manualmente, com o auxílio de 2 radiologistas e um radiologista experiente, um banco com segmentações de áreas pulmonares e áreas de infecção dos exames do CORONACASES.ORG. A Figura 16, ilustra um exemplo visual das informações fornecidas pelo banco de dados. Essas informações são importantes pois servem como parâmetro como parâmetro para verificar a eficácia do algoritmo.

Figura 16: Exemplo das imagens (a) originais, (b) de máscara pulmonar e (c) máscara de infecção fornecidas pelo banco de dados do *slice* 114 do exame 9.

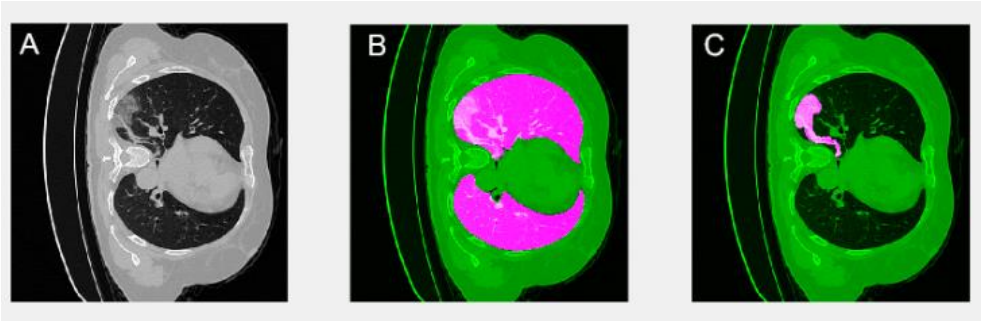

Fonte: Adaptado de Paiva (2020).

4.1.1 IMAGENS SELECIONADAS

Os exames de TC do banco escolhido também possuem *slices* que contêm pouca ou nenhuma informação sobre os pulmões e, para facilitar o trabalho do algoritmo, foram selecionados para a análise apenas os *slices* que apresentaram área pulmonar total maior que 20000 *pixels*. A Figura 17 exemplifica os tipos de *slices* que foram utilizados e que não foram.

Figura 17: Exemplos de imagens (b) utilizadas, (a) e (c) não utilizadas.

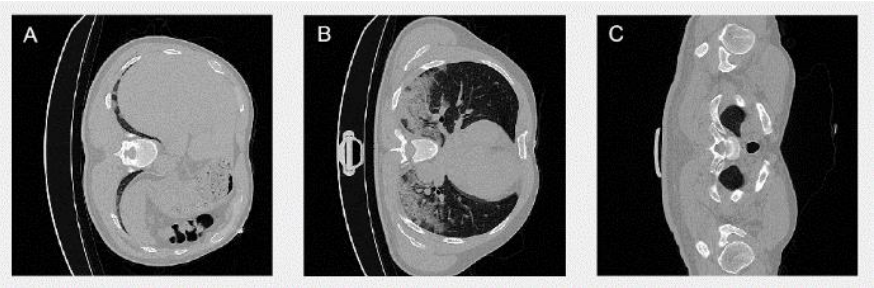

Fonte: Adaptado de Paiva (2020).

4.2. PRÉ PROCESSAMENTO

A primeira etapa, denominada pré-processamento e apresentada no diagrama de blocos da Figura 18, são realizadas a leitura das imagens, ajustes de contraste, transformações morfológicas e operações lógicas com o objetivo de alcançar uma imagem característica, que mantém as propriedades tanto do formato pulmonar, quanto das regiões com opacidade de vidro fosco da pneumonia de COVID-19. Essa imagem possui a capacidade de ser manipulada para se obter as máscaras pulmonares e de infecção.

Figura 18: Diagrama de blocos do pré-processamento.

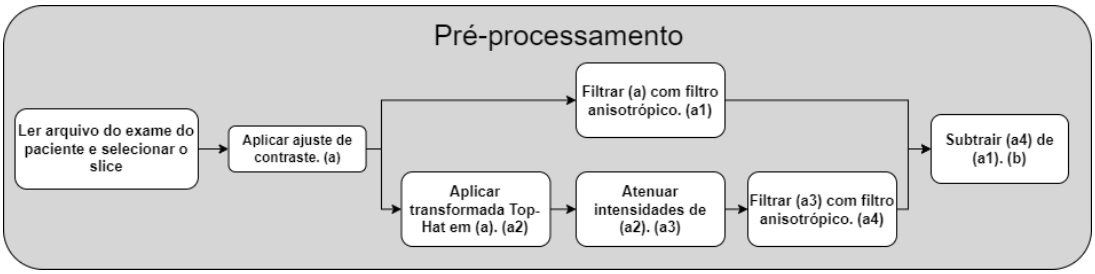

Fonte: Autor

O primeiro passo foi ler a imagem em formato *.nii* fornecida pelo banco CORONACASES. Arquivos em formato *.nii* são imagens tridimensionais, portanto, para observar um corte transversal devemos exibir todos os *pixels* das coordenadas, x e y e apenas um valor de z. Ainda assim, a imagem apresentada na leitura direta possui um baixo nível de contraste e o ajuste da Figura 19 se fez necessário.

Figura 19: Exibição de (a) corte transversal de exame de TC e (b) seu ajuste de contraste.

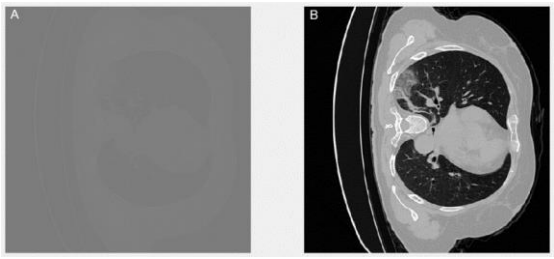

Fonte: Autor.

Em seguida, foi aplicada a transformada *top-hat* à imagem para isolar pequenos detalhes com altas intensidades. Remover esses detalhes da imagem original gera uma imagem que contém as regiões com opacidade de vidro fosco bem definidas, e reduz a intensidade dos vasos e brônquios. No entanto, executar essa subtração sem nenhum processamento prévio resulta em imagens borradas e sem nitidez (Figura 20) portanto, foi necessária a aplicação de mais duas operações nessa etapa, a atenuação de intensidades na transformada *top-hat* e a aplicação de um filtro anisotrópico na *top-hat* atenuada e na imagem original.

Figura 20: (a) Imagem original, (b) transformada *Top-Hat* sem processamento prévio e (c) sua subtração.

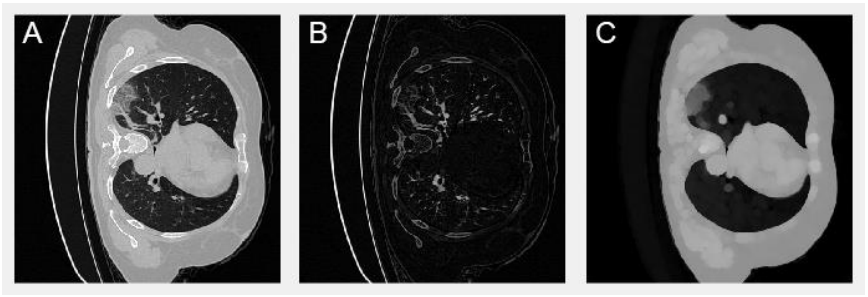

Fonte: Autor.

Ilustrada na Figura 21, foi aplicada uma atenuação na transformada *top-hat* para evitar um problema durante o processamento da máscara pulmonar no qual regiões das costelas na parede torácica possuíam intensidade baixa, semelhante ao das regiões com pneumonia, fazendo com que o algoritmo as reconhecesse como área pulmonar.

Figura 21: *Top-Hat* (A) original e (B) atenuada.

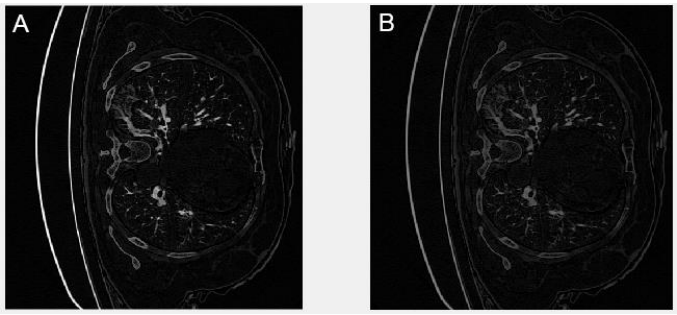

Fonte: Autor.

A atenuação foi denotada pela Equação (4.1)

$$Ni(i,j) = I(i,j) \cdot \frac{30^{0.3}}{I(i,j)^{0.3}} \tag{4.1}$$

onde $I(i,j)$ representa a intensidade dos *pixels* de posição i e j, e $Ni(i,j)$ a nova intensidade na mesma posição. O comportamento da Equação (4.1) pode ser observado na Figura 22.

Figura 22: Comportamento da equação de atenuação.

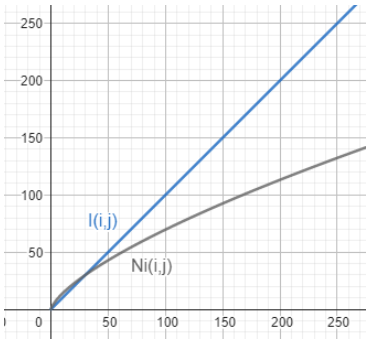

Fonte: Autor.

O filtro anisotrópico por sua vez, foi útil em aumentar a nitidez da imagem característica final, delimitando melhor as paredes da caixa torácica, reduzindo erro em que o algoritmo confundia regiões consolidadas com as paredes torácicas devido sua proximidade e semelhança de intensidade.

Com a subtração entre as imagens da *top-hat* atenuada filtrada (Figura 23(b)) e a imagem original filtrada (Figura 23(a)), foi obtida uma imagem característica que consegue delimitar bem tanto a região pulmonar quanto a da pneumonia causada por COVID-19 (Figura 23(c)).

Figura 23: (a) Imagem original filtrada, (b) *top-hat* atenuada e filtrada e a (c) subtração entre elas.

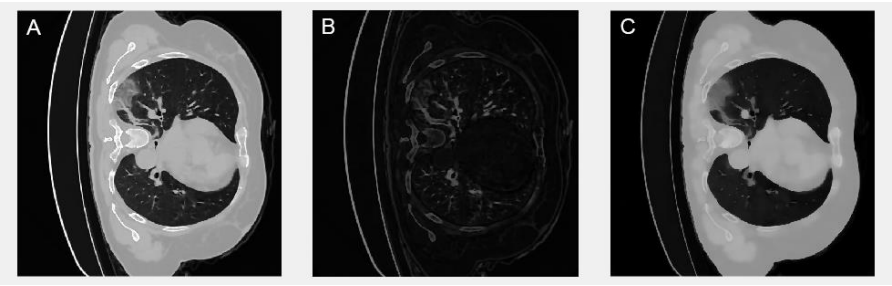

Fonte: Autor.

4.3. MÁSCARA PULMONAR

No processamento da máscara pulmonar, apresentado no diagrama de blocos (Figura 24), o algoritmo utiliza procedimentos morfológicos binários, portanto, foi necessária aplicação de uma limiarização da imagem característica obtida na fase de pré-processamento. Foram realizadas operações de erosão e dilatação entre as etapas da fase para garantir uma maior suavização das bordas da máscara.

Figura 24: Diagrama de blocos do processamento da máscara pulmonar.

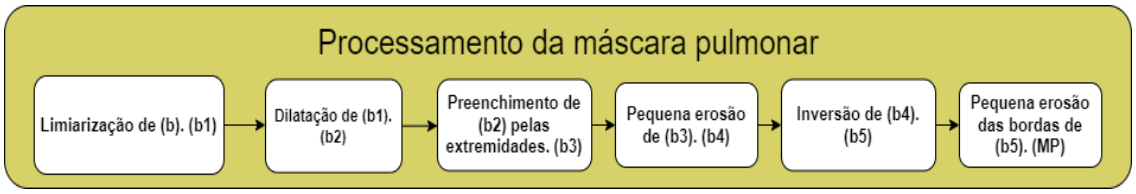

Fonte: Autor.

A limiarização utilizou o método de Otsu (1979) para calcular o valor de referência, mas para as máscaras pulmonares, foi necessário realizar a multiplicação do valor resultante do método para cada *slice* pela constante 1,67, escolhida manualmente após a análise das intensidades das imagens características e a execução de vários testes.

Após a limiarização apresentada na Figura 25(a), foi necessário isolar a região pulmonar. Para isso, foi executado o procedimento de preenchimento a partir das extremidades diagonais da imagem (Figura 25(b)), obtendo uma imagem negativa da máscara pulmonar. Então, com o objetivo de suavizar levemente o perímetro pulmonar, há a execução da operação morfológica erosão

(Figura 25(c)), uma inversão (Figura 25(d)) e mais uma erosão, finalizando com a máscara pulmonar apresentada na Figura 25(e).

Figura 25: Sequência de operações de (a) limiarização da imagem característica do pré-processamento, (b) preenchimento a partir das extremidades, (c) erosão, (d) inversão, (e) erosão.

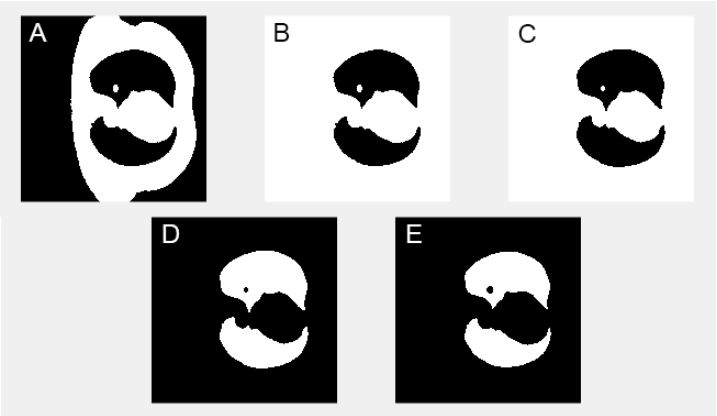

Fonte: Autor.

4.4. MÁSCARA DE INFECÇÃO

O processamento para obter a máscara de infecção de forma automática foi a etapa mais difícil de se executar, devido aos diferentes níveis de intensidades que a pneumonia pode apresentar, além dos artefatos como brônquios e vasos sanguíneos (YAO et al., 2021). Portanto, o desafio foi desenvolver um algoritmo que fosse capaz de manter as regiões com opacidade de vidro fosco e de consolidação ao mesmo tempo que remove as informações naturais da anatomia pulmonar, podendo ser confundidas com anomalias em uma limiarização. Como explicitado anteriormente, a imagem característica do pré-processamento possui algumas dessas particularidades e foi utilizada nessa fase (Figura 26).

Figura 26: Diagrama de blocos do processamento da máscara de infecção

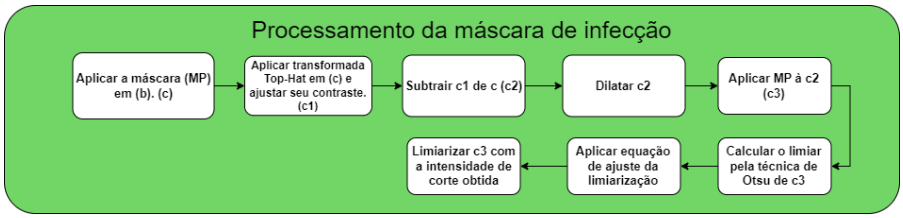

Fonte: Autor.

Para isolar apenas a região de interesse do processamento, foi aplicada a máscara pulmonar obtida na fase anterior à imagem característica obtida no pré-

processamento (Figura 27(a)), desse modo, não foi necessário observar as informações fora dos pulmões. Além disso, foi essencial a subtração da transformação *top-hat* (Figura 27(b)) para remover as informações dos brônquios, alvéolos e vasos sanguíneos, resultando na Figura 27(c).

Figura 27: (a) Máscara pulmonar aplicada à imagem característica do pré-processamento (b) sua transformada *top-hat* e (c) sua subtração.

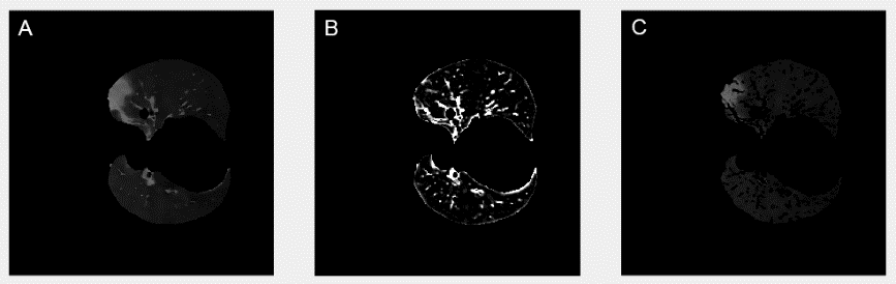

Fonte: Autor.

Após a subtração da transformada *top-hat*, foi observada a presença de buracos (Figura 27(c)). Desse modo, para restaurar a homogeneidade, foi aplicada uma operação de dilatação visualizada na Figura 28(b) e, novamente, foi empregado à máscara pulmonar (Figura 28(c)), fatiando os *pixels* de intensidade maior que 0 proveniente da dilatação que estivessem fora da região da máscara pulmonar adquirida durante o processamento anterior.

Figura 28: Sequência de operações no (a) resultado do último passo: (b) dilatação da imagem, (c) aplicação da máscara pulmonar e (d) ajuste de contraste.

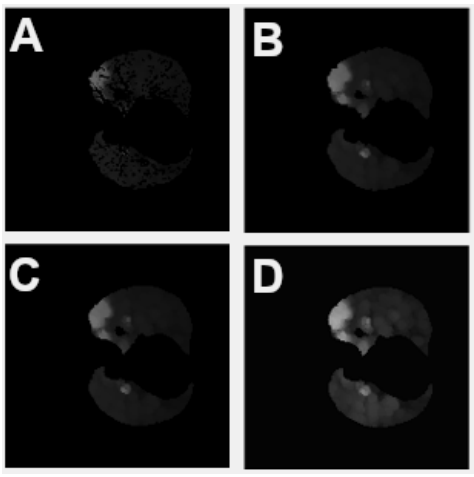

Fonte: Autor.

Assim, adaptando o contraste da Figura 28(c), temos uma imagem (Figura 28(d)) que pode ser limiarizada para obter a máscara de infecção. No entanto, foi detectado que os resultados para todos os *slices* e exames não são satisfatórios executando uma limiarização com apenas um valor de corte de intensidade. Além disso, o limiar fornecido pelo método de Otsu (1979), que varia dependendo dos histogramas das imagens dessa etapa do processamento, não realizava boas limiarizações linearmente, sendo necessário utilizá-lo como variável em uma equação polinomial para encontrar limiares mais eficientes. A Equação (4.4.1) foi utilizada com esse objetivo.

$$Nt(x) = 0.615 - 4.72x + 16.7x^2 \qquad (4.4.1)$$

Para alcançar a Equação (4.4.1), diversas limiarizações manuais foram realizadas em *slices* de vários exames aleatoriamente com o intuito de se obter dados suficientes para executar uma aproximação polinomial. Os dados dos limiares de Otsu e os limiares escolhidos manualmente foram inseridos na tabela da Figura 29(a) no programa *web Google Sheets* onde, após plotagem dos pontos no gráfico da Figura 29(b), foi encontrada a Equação (4.4.1), que relaciona os dois eixos de forma polinomial.

Figura 29: (a) tabela com valores dos limiares escolhidos e de Otsu para os exames e *slices* correspondentes, (b) gráfico com os valores da tabela e aproximação polinomial.

A

Exame	Slice	Limiar de Otsu	Limiar escolhido
9	123	0,1098	0,29
10	148	0,2078	0,35
10	197	0,1765	0,33
8	97	0,1688	0,30
7	131	0,1451	0,27
7	79	0,0902	0,33
6	77	0,1765	0,30
5	65	0,1020	0,34
5	142	0,0745	0,35
2	95	0,2275	0,40
1	147	0,1255	0,25

B

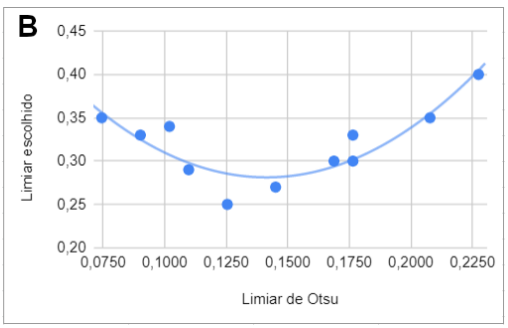

Fonte: Autor.

Aplicando o valor de *Nt(x)* da Equação (4.4.1) como limiar de binarização na Figura 30(a), foi alcançada a máscara de infecção desenvolvida, apresentada na Figura 30(b).

Figura 30: (a) Imagem a ser limiarizada para obter (b) a máscara de infecção.

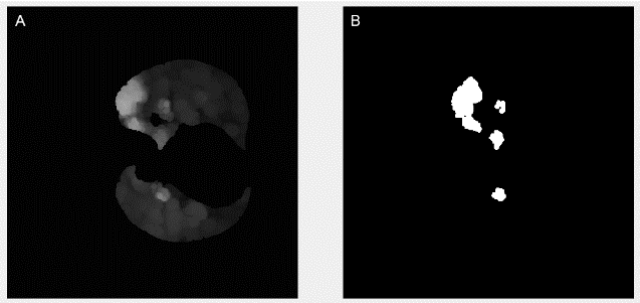

Fonte: Autor.

5. RESULTADOS E DISCUSSÕES

Concluído o processamento, se faz necessária a visualização e análise dos resultados para entender os pontos positivos e negativos do algoritmo. Para isso, foram escolhidos 2 *slices* de exemplo da base de dados para apresentação compilada de todos resultados ao longo das etapas do processamento. O primeiro deles (Figura 31), diz respeito ao *slice* 136 do paciente do exame 9, que possuía um comprometimento pulmonar de 7,325%, com presença de ambas OPV e consolidações.

Figura 31: Sequência de operações do algoritmo para o *slice* 136, paciente 9.

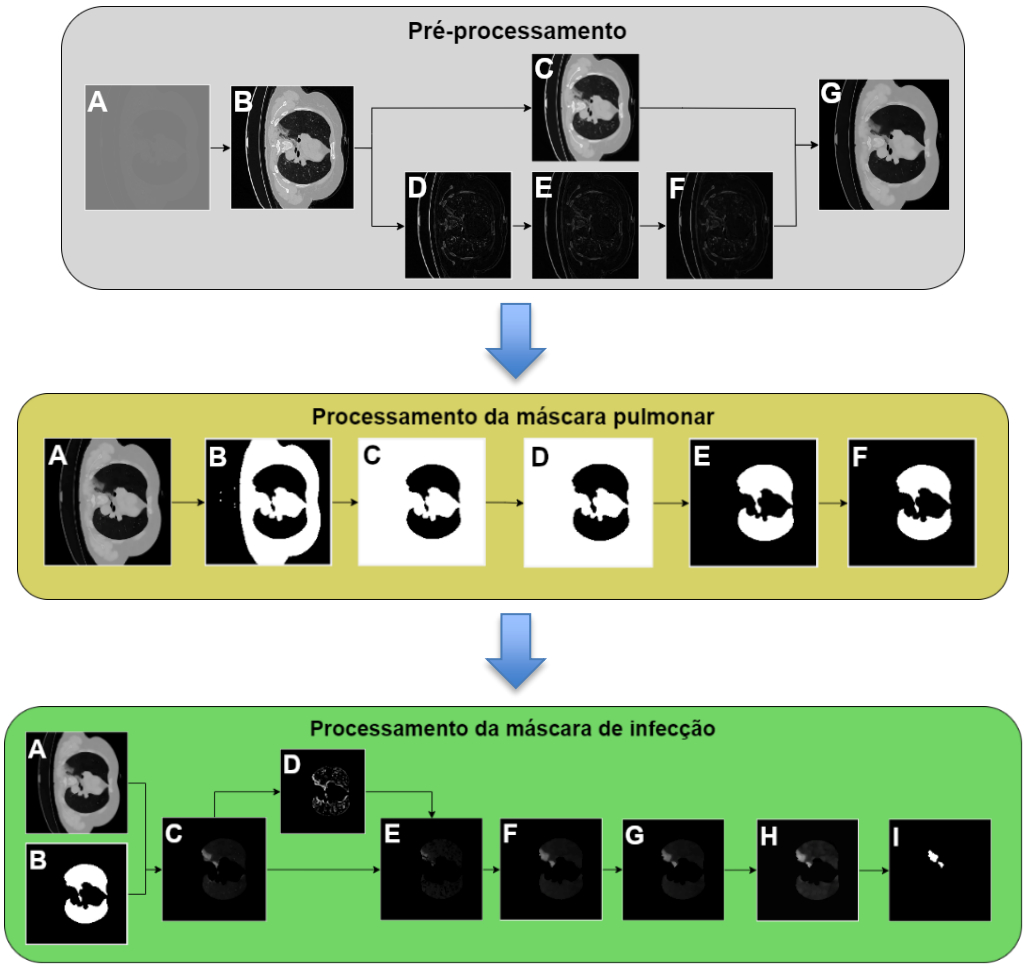

Fonte: Autor.

O segundo exemplo, apresentado na Figura 32, diz respeito ao *slice* 175 do paciente do exame 10, que possuía o segundo maior comprometimento pulmonar da base de dados, com 18,514%, com presença de intensas consolidações.

Figura 32: Sequência de operações do algoritmo para o *slice* 175, paciente 10.

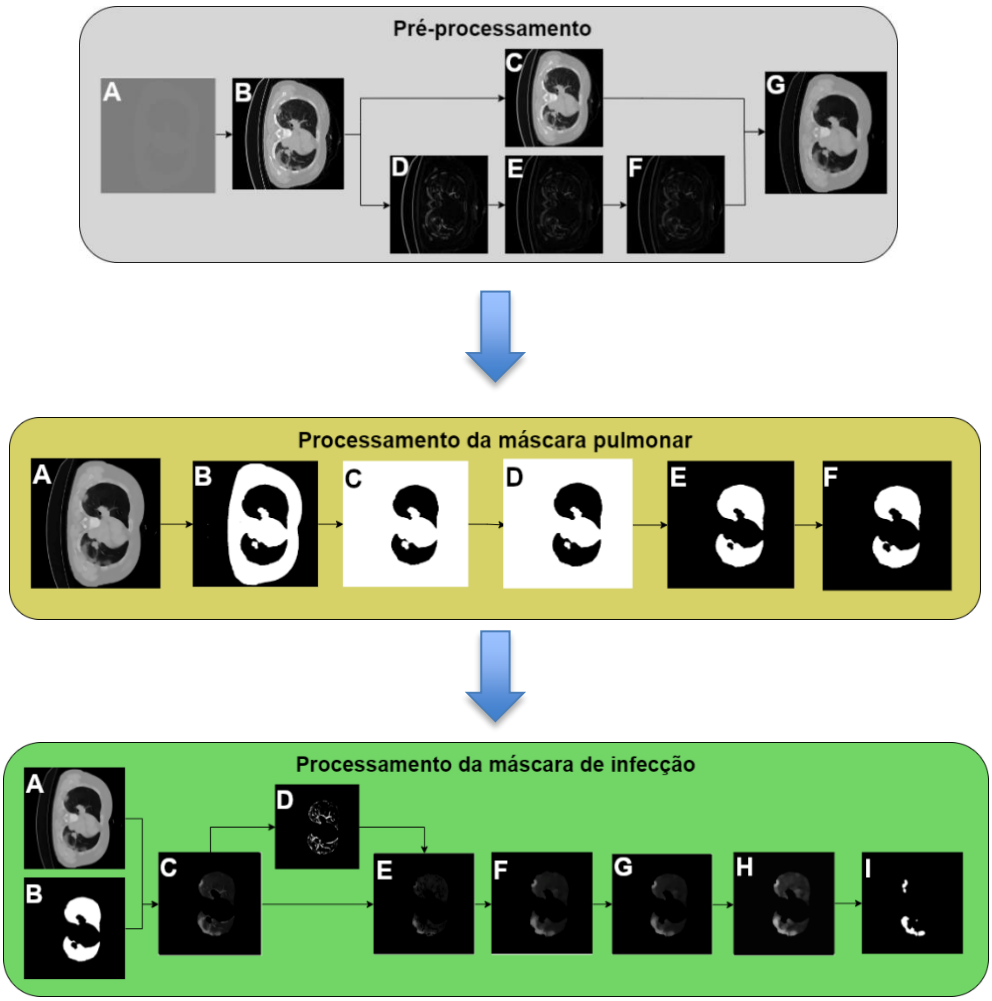

Fonte: Autor.

Na Tabela 5.1, são exemplificados resultados da máscara pulmonar para os *slices* 30 a 40 do exame 2, sendo a tabela completa com o resultado de todos os *slices* para todos os exames, fornecida no anexo. Nessa tabela de análise, foram calculados a partir do algoritmo, quantidade de *pixels* contidos nas máscaras pulmonares e de infecção originais e desenvolvidas (*AP Ori*, *AP Dev*, *AI Ori* e *AI Dev*), informações relevantes para o cálculo do nível de comprometimento pulmonar. Também foram executadas as operações lógicas descritas nas Equações 5.1 a 5.4, retornando os valores referentes a *pixels* verdadeiro positivos (*VP)*, verdadeiro negativos (*VN)*, falso positivos (*FP)* e falso negativos (*FN)*, todos descritos ainda neste capítulo.

Tabela 5.1: Tabela de resultados para o processamento da máscara pulmonar dos *slices* 30 a 40 do exame 2.

Slice	AP Dev	AP Ori	VP	VN	FP	FN
30	20026	17546	15732	240304	4294	1814
31	21053	19371	16726	238446	4327	2645
32	22128	19664	17556	237908	4572	2108
33	22440	19449	17726	237981	4714	1723
34	23024	21690	18603	236033	4421	3087
35	23645	22139	19311	235671	4334	2828
36	24895	22133	20187	235303	4708	1946
37	25303	22888	20841	234794	4462	2047
38	25701	24341	21884	233986	3817	2457
39	25893	24350	22445	234346	3448	1905
40	25611	24815	22656	234374	2955	2159

Fonte: Autor.

Na Tabela 5.2, são observados os mesmos resultados, mas para o processamento da máscara de infecção.

Tabela 5.2: Tabela de resultados para o processamento da máscara de infecção dos *slices* 30 a 40 do exame 2.

Slice	AI Dev	AI Ori	VP	VN	FP	FN
30	1665	686	634	260427	1031	52
31	2256	1011	844	259721	1412	167
32	2411	899	826	259660	1585	73
33	2346	1016	979	259761	1367	37
34	2275	1361	1067	259575	1208	294
35	2500	1222	1130	259552	1370	92
36	3071	1191	1147	259029	1924	44
37	2673	1177	1139	259433	1534	38
38	3084	1213	1185	259032	1899	28
39	2604	1264	1178	259454	1426	86
40	1566	1218	971	260331	595	247

Fonte: Autor.

Os resultados do algoritmo aplicado foram comparados com as máscaras de referência pulmonares e de infecção fornecidas pela base de dados CORONACASES. Realizando a divisão entre número de *pixels* da pneumonia e número de *pixels* da máscara pulmonar para todos os exames, foi possível comparar o grau de comprometimento pulmonar sugerido pelos especialistas do banco de dados e do algoritmo desenvolvido, sugerindo uma diferença média de 3,55% ± 4,13% (Tabela 5.3).

Tabela 5.3: Nível de comprometimento pulmonar desenvolvido comparado com o sugerido pelos radiologistas do banco CORONACASES.

Exame	Comprometimento pulmonar de referência	Comprometimento pulmonar do algoritmo	Erro
1	14,580%	4,956%	9,62%
2	4,344%	6,638%	2,29%
3	29,770%	17,081%	12,69%
4	1,479%	0,817%	0,66%
5	1,845%	2,412%	0,57%
6	3,159%	3,132%	0,03%
7	3,485%	4,354%	0,87%
8	7,735%	8,121%	0,39%
9	7,325%	11,029%	3,70%
10	18,514%	23,228%	4,71%
Média do erro	3,55%	**Desvio padrão**	4,13%

Fonte: Autor

Além desse parâmetro de comparação, a partir das operações lógicas, definidas nas Equações 5.1 a 5.4, entre as máscaras pulmonares e de infecção fornecidas (*Máscara Original*) e desenvolvidas (*Máscara Desenvolvida*), foram obtidos parâmetros referentes à *pixels VP*, *VN*, *FP* e *FN* para ambos os tipos de máscara.

$$VP = Máscara\ Original\ \cap\ Máscara\ Desenvolvida \tag{5.1}$$

$$VN = -Máscara\ Original\ \cap\ -Máscara\ Desenvolvida \tag{5.2}$$

$$FP = -Máscara\ Original\ \cap\ Máscara\ Desenvolvida \tag{5.3}$$

$$FN = Máscara\ Original\ \cap\ -Máscara\ Desenvolvidas \tag{5.4}$$

Para esse trabalho, um *pixel VP* foi representativo de uma região de pneumonia e detectado como corretamente pelo algoritmo, como destacado em branco na Figura 33(c), *VN* se trata de um *pixel* corretamente identificado como fora de uma região de pneumonia, *FP*, quando uma região detectada como pneumonia de forma equivocada, e *FN*, quando uma região de pneumonia não foi identificada (DEEKS, 1999).

Figura 33: Exemplos de (a) máscaras de infecção originais, (b) desenvolvidas e suas (c) intercessões (*pixels* verdadeiro positivos em branco).

Slice 136 – Exame 9

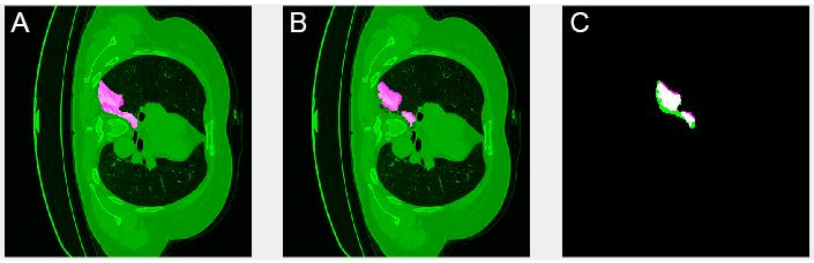

Slice 175 – Exame 10

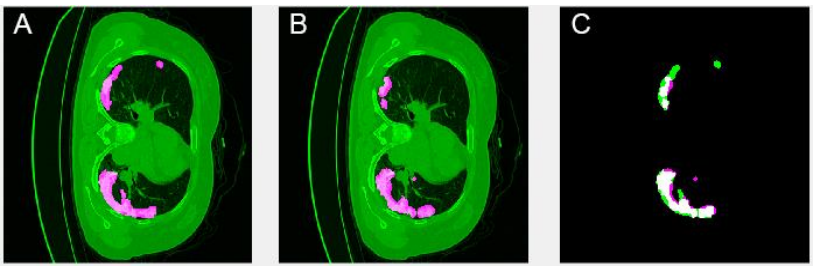

Fonte: Autor.

Operações entre esses 4 parâmetros foram realizadas para encontrar indicadores importantes para verificar a eficiência do algoritmo, são eles: a sensibilidade (SENS) (Equação 5.5), a probabilidade de uma região afetada por COVID-19 ser detectada corretamente, a especificidade (ESP) (Equação 5.6), como a probabilidade de uma região não afetada pela doença não ser detectada, a acurácia (ACC) (Equação 5.7), como a probabilidade de o algoritmo fornecer resultados corretos (DEEKS, 1999) e o de Sorensen-Dice (SDC) (Equação 5.8), que verifica o nível de similaridade entre duas amostras (YAO *et al*., 2021). Os cálculos dos indicadores de performance são dados por:

$$Sensibilidade = VP/(VP + FN) \quad (5.5)$$

$$Especificidade = VN/(VN + FP) \quad (5.6)$$

$$Acurácia = (VN + VP)/(VN + VP + FN + FP) \quad (5.7)$$

$$Sørensen - Dice = (2VP)/(2VP + FN + FP) \quad (5.8)$$

Desse modo, para obter o valor de SENS, ESP, ACC e SDC de cada exame, foi utilizado como VP, VN, FP e VN, nas Equações 5.5 a 5.8, o valor da soma de

todos os *slices* das colunas correspondentes da Tabela 5.1. Os resultados desse procedimento foram apresentados na Tabela 5.3:

Tabela 5.3: Resultado de cada exame comparado com os resultados do banco CORONACASES.

Exame	Máscara pulmonar				Máscara de infecção			
	Sensibilidade	Especificidade	Acurácia	Sorensen-Dice	Sensibilidade	Especificidade	Acurácia	Sorensen-Dice
1	92,571%	99,775%	98,886%	95,349%	22,801%	99,831%	98,447%	34,544%
2	94,069%	98,760%	97,931%	94,140%	82,437%	99,458%	99,327%	65,272%
3	91,532%	99,731%	98,518%	94,811%	48,959%	99,795%	97,557%	63,829%
4	94,464%	99,586%	98,699%	96,176%	14,399%	99,900%	99,681%	18,791%
5	94,694%	99,643%	98,750%	96,471%	66,134%	99,800%	99,688%	58,545%
6	93,497%	99,719%	98,783%	95,854%	70,303%	99,886%	99,745%	72,382%
7	92,033%	99,704%	98,680%	94,903%	61,928%	99,741%	99,565%	56,977%
8	93,386%	99,717%	98,744%	95,807%	71,281%	99,659%	99,321%	71,397%
9	93,250%	99,812%	98,714%	96,041%	85,955%	99,307%	99,144%	71,088%
10	91,502%	99,805%	98,842%	94,824%	76,610%	99,122%	98,638%	70,714%
Média	**93,100%**	**99,625%**	**98,655%**	**95,438%**	**60,081%**	**99,650%**	**99,111%**	**58,354%**
Desvio Padrão	**1,10%**	**0,30%**	**0,26%**	**0,71%**	**23,05%**	**0,25%**	**0,67%**	**17,01%**

Fonte: Autor.

O algoritmo desenvolvido apresentou indicadores médios de 93,1% de SENS, 99,625% de ESP, 98,655% de ACC e 95,438% de SDC para as máscaras pulmonares, e 60,081% de SENS, 99,65% de ESP, 99,111% de ACC e 58,354% de SDC para as máscaras de infecção. Na Tabela 5.4 esses valores são comparados com outros métodos de segmentação para infecção apresentados na literatura.

Tabela 5.4: Comparação entre métodos da literatura e o desenvolvido.

Método	SENS	ESP	ACC	SDC
U-NET (SAOOD; HATEM, 2021)	66,1%	95,8%	-	33,7%
SegNet (SAOOD; HATEM, 2021)	67,3%	95,9%	-	31,7%
Fan *et al*, (2020)	69,2%	94,3%	-	68,2%
OULEFKI *et al*., (2021)	73,3%	99,4	98,9%	71,4%
YAO *et al*., (2021)	66,2%	82,1%	-	69,8%
Método Desenvolvido	**60,08%**	**99,65%**	**99,11%**	**58,35%**

Fonte: Autor.

A SENS e o SDC do algoritmo desenvolvido possuem valores relativamente baixos devido à 3 problemas principais encontrados durante o processamento. O primeiro deles, destacado na Figura 34(c), diz respeito à perda de informação da máscara pulmonar quando há uma região de consolidação muito próxima às paredes do pulmão. Como regiões de consolidação possuem intensidades muito altas, se estiverem próximas das paredes torácicas, podem acabar sendo excluídas da máscara pulmonar, impedindo a posterior detecção da pneumonia durante o processamento da máscara de infecção.

Figura 34: Exemplo de (a) *slice* original, (b) máscara pulmonar fornecida pelo banco e (c) máscara pulmonar desenvolvida.

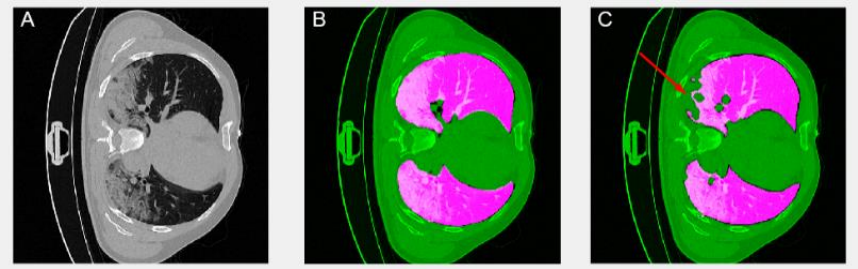

Fonte: Autor.

O segundo problema, exibido na Figura 35(c), acontece quando se tenta remover as informações referentes aos brônquios, alvéolos e vasos sanguíneos durante o processamento da máscara de infecção. Como destacado anteriormente, a subtração da transformada *top-hat* foi utilizada para remover detalhes pequenos de alta intensidade, no entanto, se informações de consolidação também são pequenas o suficiente, elas serão removidas durante o processamento, gerando falhas na máscara de infecção.

Figura 35: Exemplo de (a) *slice* original, (b) máscara de infecção fornecida pelo banco e (c) máscara de infeção desenvolvida com informações perdidas durante a subtração da *top-hat*.

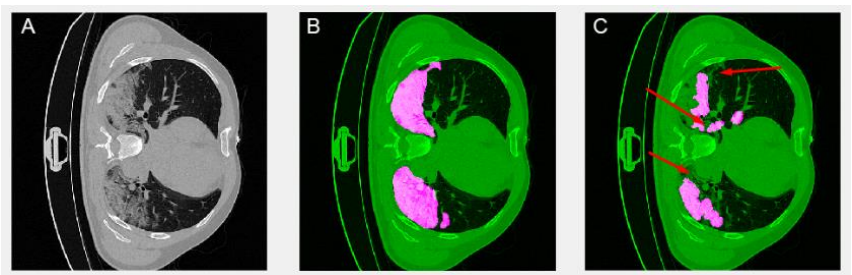

Fonte: Autor.

Além disso (Figura 35), ainda há a terceira situação, em que os artefatos presentes nos pulmões influenciam o resultado. Esse problema pode ser reduzido ao aplicar uma dilatação à transformação *top-hat* antes da subtração, contudo, realizar esse procedimento reduziria ainda mais a detecção de regiões consolidadas pequenas. Desse modo, foi escolhida uma solução, mantendo algumas regiões consolidadas ao custo de detectar alguns *pixels* FP.

6. CONCLUSÃO E TRABALHOS FUTUROS

Ao longo dos últimos 2 anos, observamos a gravidade que o despreparo diante de uma pandemia pode causar à nossa sociedade. Dado que a COVID-19 demora cerca de 10 dias para chegar em seu estado mais avançado, a evolução das técnicas de PDI possui relevância para o acompanhamento de pacientes e para a adaptação de tratamentos médicos em tempo real, devido à economia de tempo oferecida aos profissionais da saúde.

Considerando essas informações, esse trabalho apresentou um método capaz de realizar a segmentação da pneumonia causada por COVID-19, de forma automática e com processamento ágil para exames com mais de 250 *slices* de TC. Se trata de uma ferramenta para auxílio e acompanhamento no qual o profissional de saúde poderá avaliar o comprometimento pulmonar do paciente, e responder com tratamento adequado.

Diante da existência de estruturas naturais nas imagens radiológicas do pulmão com intensidades semelhantes ao da pneumonia em estado de consolidação causada por COVID-19, a segmentação aplicada apontou como uma tarefa não tão fácil nestes tipos de imagens desta base de dados. Ainda que o algoritmo tenha apresentado uma SENS de 60,08%, relativamente baixa se comparada a outros métodos especializados para o mesmo objetivo, a média de desempenho de todos os indicadores foi satisfatória, tendo em vista que o desempenho da ESP foi de 99,65% e a ACC de 99,11%, indicando que o algoritmo costuma acertar os *pixels* VN e que o desempenho geral dos VN e VP, juntos, se mostra elevada.

Além disso, a acurácia também reforça a informação de que, ainda que a interseção direta entre as máscaras originais e desenvolvidas no cálculo dos *pixels* de VP traga uma eficiência de 60,08%, os *pixels* FP e FN estão próximos à região demarcada pelas máscaras. Como o algoritmo não se trata de um programa de suporte à remoção de tumores, por exemplo, a gravidade da não identificação correta dos *pixels* FP e FN não se faz tão elevada.

Outro ponto positivo do trabalho se destaca na alta eficiência em sugerir um nível de comprometimento pulmonar. Com um erro médio de 3,55% ± 4,13%, a quantidade de *pixels* da máscara pulmonar e da máscara de infecção são semelhantes aos valores de referência fornecidos pelo banco de dados.

6.1 TRABALHOS FUTUROS

Como trabalho futuro, existe a possibilidade de seguir as tendências atuais de uso de redes neurais visto que a eficiência dessa técnica para executar a segmentação pulmonar têm exibido resultados satisfatórios. Caso implementada corretamente, a técnica poderá resolver o problema da não identificação das regiões consolidadas próximas à pleura pulmonar, aumentando a eficiência do processamento da máscara de infecção.

Outro ponto importante, a sugestão de implementação de um método de classificação capaz de separar o processamento entre imagens que possuem mais consolidação que opacidade de vidro fosco e vice-versa. Essa inclusão permitiria uma melhor escolha de métodos de processamento para cada *slice*, tendo em vista que as duas situações possuem características visuais diferentes.

A possibilidade de implementação do método de limiarização adaptativo desenvolvido no processamento da máscara de infecção também no processamento da máscara pulmonar se mostra como uma ideia viável. Essa implementação pode resolver a má formação de máscaras pulmonares em *slices* que possuem muita consolidação.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDULRAHMAN, A.; VAROL, S. **A Review of Image Segmentation Using MATLAB Environment.** 2020 8th International Symposium on Digital Forensics and Security (ISDFS). Anais...Beirut, Lebanon: IEEE, jun. 2020. Disponível em: <https://ieeexplore.ieee.org/document/9116191/>. Acesso em: 14 dez. 2022

Advice for the public: Coronavirus disease (COVID-19). Organização Mundial da Saúde, 2022. Disponível em: <https://www.who.int/emergencies/diseases/novel-coronavirus-2019/advice-for-public>. Acesso em 18 de nov. 2022.

BARUPAL, T.; TAK, P. K.; MEENA, M. **COVID-19: Morphology, Characteristics, Symptoms, Prevention, Clinical Diagnosis and Current Scenario.** Coronaviruses, v. 1, n. 1, p. 82–89, 8 set. 2020.

BEHNAZ, A. S. et al. **Quantitative CT for volumetric analysis of medical images: initial results for liver tumors.** (B. M. Dawant, D. R. Haynor, Eds.) San Diego, California, USA: 4 mar. 2010. Disponível em: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.844344>. Acesso em: 14 dez. 2022

BROADDUS, V. C. (ED.). **Murray and Nadel´s textbook of respiratory medicine.** 2 / Ed.-in-chief: V. Courtney Broaddus. 6. ed ed. Philadelphia, Pa.: Elsevier Saunders, 2016.

CHEN, X.; YAO, L.; ZHANG, Y. **Residual Attention U-Net for Automated Multi-Class Segmentation of COVID-19 Chest CT Images.** arXiv, 12 abr. 2020. Disponível em: <http://arxiv.org/abs/2004.05645>. Acesso em: 14 dez. 2022

CIOTTI, M. et al. **The COVID-19 pandemic.** Critical Reviews in Clinical Laboratory Sciences, v. 57, n. 6, p. 365–388, 17 ago. 2020.

DEEKS, J. J. **Using evaluations of diagnostic tests: Understanding their limitations and making the most of available evidence.** Annals of Oncology, v. 10, n. 7, p. 761–768, jul. 1999.

DONG, D. et al. **The Role of Imaging in the Detection and Management of COVID-19: A Review.** IEEE Reviews in Biomedical Engineering, v. 14, p. 16–29, 2021.

FAN, D.-P. et al. **Inf-Net: Automatic COVID-19 Lung Infection Segmentation From CT Images.** IEEE Transactions on Medical Imaging, v. 39, n. 8, p. 2626–2637, ago. 2020.

FIELDS, B. K. K. et al. **Imaging of COVID-19: CT, MRI, and PET.** Seminars in Nuclear Medicine, v. 51, n. 4, p. 312–320, jul. 2021.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing.** New York, NY: Pearson, 2018.

ISENSEE, F. et al. **Automated Design of Deep Learning Methods for Biomedical Image Segmentation.** Nature Methods, v. 18, n. 2, p. 203–211, fev. 2021.

JUN, M. et al. **COVID-19 CT Lung and Infection Segmentation Dataset.** Zenodo, , 20 abr. 2020. Disponível em: <https://zenodo.org/record/3757476>. Acesso em: 8 dez. 2022

KANNE, J. P. et al. **COVID-19 Imaging: What We Know Now and What Remains Unknown.** Radiology, v. 299, n. 3, p. E262–E279, jun. 2021.

LAUER, S. A. et al. **The Incubation Period of Coronavirus Disease 2019 (COVID-19) From Publicly Reported Confirmed Cases: Estimation and Application.** Annals of Internal Medicine, v. 172, n. 9, p. 577–582, 5 maio 2020.

LYTRAS, S. et al. **Exploring the Natural Origins of SARS-CoV-2 in the Light of Recombination.** Genome Biology and Evolution, v. 14, n. 2, p. evac018, 4 fev. 2022.

OTSU, N. **A Threshold Selection Method from Gray-Level Histograms.** IEEE Transactions on Systems, Man, and Cybernetics, v. 9, n. 1, p. 62–66, jan. 1979.

OULEFKI, A. et al. **Automatic COVID-19 lung infected region segmentation and measurement using CT-scans images.** Pattern Recognition, v. 114, p. 107747, jun. 2021.

PAIVA, O. **CORONACASES.ORG: Cases**, 2020. Página Inicial. Disponível em: https://coronacases.org/. Acesso em: 8, dez. 2022.

PAKRAY, A. et al. **Imaging evaluation of COVID-19 in the emergency department.** Emergency Radiology, v. 27, n. 6, p. 579–588, dez. 2020.

PAN, F. et al. **Time Course of Lung Changes at Chest CT during Recovery from Coronavirus Disease 2019 (COVID-19).** Radiology, v. 295, n. 3, p. 715–721, jun. 2020.

RAJINIKANTH, V. et al. **Harmony-Search and Otsu based System for Coronavirus Disease (COVID-19) Detection using Lung CT Scan Images.** 2020.

RAVEENDRAN, A. V.; JAYADEVAN, R.; SASHIDHARAN, S. **Long COVID: An overview.** Diabetes & Metabolic Syndrome: Clinical Research & Reviews, v. 15, n. 3, p. 869–875, maio 2021.

SAOOD, A.; HATEM, I. **COVID-19 lung CT image segmentation using deep learning methods: U-Net versus SegNet.** BMC Medical Imaging, v. 21, n. 1, p. 19, dez. 2021.

SARANGI, M. K. et al. **Diagnosis, prevention, and treatment of coronavirus disease: a review.** Expert Review of Anti-infective Therapy, v. 20, n. 2, p. 243–266, 1 fev. 2022.

SOLOMON, C.; BRECKON, T. **Fundamentals of digital image processing: a practical approach with examples in Matlab.** Chichester, West Sussex ; Hoboken, NJ: Wiley-Blackwell, 2011.

WANG, G. et al. **A Noise-Robust Framework for Automatic Segmentation of COVID-19 Pneumonia Lesions From CT Images.** IEEE Transactions on Medical Imaging, v. 39, n. 8, p. 2653–2663, ago. 2020.

World Health Organization. **COVID-19 Weekly Epidemiological Update Edition 101**, de 21 de setembro de 2022. Disponível em: https://apps.who.int/iris/handle/10665/354259. Acesso em: 19/05/2022.

WOROBEY, M. et al. **The Huanan Seafood Wholesale Market in Wuhan was the early epicenter of the COVID-19 pandemic.** Science, v. 377, n. 6609, p. 951–959, 26 ago. 2022.

YAO, Q. et al. **Label-Free Segmentation of COVID-19 Lesions in Lung CT.** IEEE Transactions on Medical Imaging, v. 40, n. 10, p. 2808–2819, out. 2021.