UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

Trabalho de Conclusão de Curso

SEGMENTAÇÃO DE IMAGENS DE TC DO TORÁX PARA ANÁLISE DA PNEUMONIA ACOMETIDA PELA COVID-19

João Lucas de Castro Batista

Natal/RN
2022

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

SEGMENTAÇÃO DE IMAGENS DE TC DO TORÁX PARA ANÁLISE DA PNEUMONIA ACOMETIDA PELA COVID-19

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

Graduando: João Lucas de Castro Batista
Orientadora: Prof.ª Dra. Heliana Bezerra Soares

Natal/RN
2020

UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA BIOMÉDICA

SEGMENTAÇÃO DE IMAGENS DE TC DO TORÁX PARA ANÁLISE DA PNEUMONIA ACOMETIDA PELA COVID-19

Banca Examinadora do Trabalho de Conclusão de Curso:

Prof.ª Dra. Heliana Bezerra Soares _____
Orientadora

Profa. Dra. Adriana Cláudia Câmara da Silva _____
Avaliadora Externar – IFRN

Enga. Luíza Christina de Souza _____
Avaliadora Externa

Natal/RN
2020

DEDICATÓRIA

Dedico este trabalho a minha família e meus amigos que tiveram paciência com minha ausência e sempre me incentivaram ao longo desta monografia.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter concedido forças para continuar durante toda minha trajetória acadêmica. Como também, a bênção das grandes oportunidades e experiências que tive no curso em que escolhi como parte da minha vida.

Agradeço também a Universidade Federal do Rio Grande do Norte, por mostrar o caminho profissional no qual pretendo seguir por toda minha vida. Pelos professores que tanto me ensinaram. Sou grato também ao departamento de engenharia biomédica e o LABSIM que me deram suporte durante todo meu crescimento como pesquisador.

Agradeço em especial a minha orientadora e professora Heliana Bezerra Soares, que tanto me ensinou não só em termos de conteúdo como em lições de vida que vou levar por toda minha carreira profissional.

As amizades feitas durante meu caminho por ciências e tecnologia e Engenharia Biomédica. Foram essenciais a me dar apoio e motivação, como também deixar os dias estressantes mais leves.

E por último a minha família que me deu suporte em todos os quesitos, apesar de parte dela estar longe. Me apoiando em cada decisão acadêmica e sendo pacientes, mesmo com saudades, em cada ausência em reuniões família

SUMÁRIO

LISTA DE FIGURAS viii
LISTA DE TABELAS ix
LISTA DE EQUAÇÕES x
LISTA DE ABREVIAÇÕES, SIGLAS E SÍMBOLOS xi
RESUMO xii
ABSTRACT xiii
1.1. OBJETIVOS 2
1.1.1. OBJETIVOS GERAL 2
1.1.2. OBJETIVOS ESPECÍFICOS 2
1.2. ESTADO DA ARTE 3
1.3. ESTRUTURA DO TRABALHO 4
2. FUNDAMENTAÇÃO TEÓRICA 6
2.1. CARACTERÍSTICAS GERAIS 6
2.2. SINTOMAS 7
2.3. DIAGNÓSTICO 8
2.4. CARACTERÍSTICAS DE EXAMES VISUAIS 9
3. PROCESSAMENTO DIGITAL DE IMAGENS 12
3.1. IMAGEM DIGITAL 12
3.2. TRANSFORMAÇÕES DE INTESIDADE 13
3.2.1. FILTRO DA MEDIANA 14
3.3. PROCESSAMENTO MORFOLÓGICO 14
3.4. REALCE DE IMAGEM 15
3.4.1. HISTOGRAMA EQUALIZADO 16
3.5. LIMIARIZAÇÃO 16
3.6. SEGMENTAÇÃO 17
4. SEGMENTAÇÃO DE IMAGENS DO TÓRAX 19
4.1. SOFTWARE DE IMPLEMENTAÇÃO 19
4.2. BASE DE DADOS 20
4.3. SELEÇÃO DE IMAGENS 21
4.4. PRÉ PROCESSAMENTO 22
4.4.1. SEGMENTAÇÃO JLS 22
4.4.2. FILTRO 25

4.4.3. SELEÇÃO DE IMAGENS A PARTIR DOS EXAMES 26
4.4.4. SEGMENTACAO JLS2 28
4.5. SEGMENTAÇÃO 30
4.6. PÓS-PROCESSAMENTO 30
4.6.1. LIMIARIZAÇÃO 30
4.6.2. PROCESSAMENTO MORFOLÓGICO 31
5. RESULTADOS E DISCUSSÕES 33
5.1. RESULTADOS DA SEGMENTAÇÃO DO PULMÃO 33
5.1.1. ERRO MÉDIO QUADRÁTICO 33
5.1.2. COMPARATIVOS VISUAIS ENTRE IMAGEM 34
5.2. RESULTADOS DA EXCLUSÃO DE IMAGENS 36
6. CONCLUSÃO 38
6.1. TRABALHOS FUTUROS 39
REFERÊNCIAS BIBLIOGRÁFICAS 40

LISTA DE FIGURAS

Figura 1: Formas de transmissão do COVID-19. 6
Figura 2: Frequência dos sintomas em pacientes com COVID-19. 7
Figura 3: Distribuição de idade de acordo com a severidade dos sintomas. 8
Figura 4: a) Opacidade de vidro fosco; b) Consolidação; c) Padrão em árvore; d) Padrão reticular e f) Padrão de pavimentação. 11
Figura 5: Imagem em tons de cinza. 13
Figura 6: Imagem RGB 13
Figura 7: Filtro da mediana: (a) Imagem Original e (b) Imagem filtrada. 14
Figura 8: Operadores básicos: (a) Erosão; (b) Dilatação e (c) Abertura. 15
Figura 9: Histograma equalizado da imagem. 16
Figura 10: Limiarização da imagem: (a) Imagem original e (b) Imagem limiarizada. 17
Figura 11: Segmentação com o algoritmo *K-means*: (a) Imagem original e (b) Imagem segmentada 18
Figura 12: Diagrama de blocos da estratégia desenvolvida 19
Figura 13: Exemplo de um exame da base de dados: (a) Imagem com exame normal; (b) Imagem com exame apresentando pneumonia; (c) Imagem do exame com COVID-19 e (d) Imagem modelo delimitada pelo especialista. 21
Figura 14: Exemplo de um exame de TC do tórax: (a) *Slices* inicial do exame, (b) *Slices* analisados e (c) *Slices* finais do exame. 22
Figura 15: Caminho percorrido pela segmentação JLS. 23
Figura 16: Exemplo da análise: (a) Primeira situação, (b) Segunda situação, (c) Terceira situação e (d) Quarta situação. 24
Figura 17: Exemplo da análise: (a) Imagem original e (b) Imagem segmentada. 25
Figura 18: Exemplo dos filtros: (a) Imagem segmentada e (b) Imagem filtrada. 25
Figura 19: Resultado da seleção da imagem. 26
Figura 20: Exemplo da seleção do exame: a) Primeiro quarto selecionado; b) Segundo quarto selecionado. 27
Figura 21: Exemplo da segmentação JLS2. 28
Figura 22: Exemplo da ordem de análise no *slice*. 29
Figura 23: Exemplo da segmentação: (a) Imagem filtrada e (b) Segunda segmentação. 29
Figura 24: Exemplo da segmentação com o algoritmo *K-means*: (a) Segunda segmentação e (b) *K-means*. 30
Figura 25: Exemplo do processo da limiarização: (a) Resultado do algoritmo *K-means* e (b) Imagem binarizada. 31
Figura 26: Exemplo da limiarização nas imagens modelo: (a) Imagem modelo e (b) Imagem binária. 31
Figura 27: Exemplo do processamento morfológico: (a) Imagem binarizada e (b) Operação morfológica de abertura. 32
Figura 28: Exemplo de exames e os modelos manuais. 32
Figura 29: Exemplo: (a) Imagem original e (b) Imagem segmentada automaticamente. 35
Figura 30: Exemplo: (a) Imagem modelo binarizada e (b) imagem segmentada automaticamente. 35
Figura 31: Exemplo: (a) Imagem original e (b) Imagem modelo. 36

LISTA DE TABELAS

Tabela 1: Lista de identificação da base de dados. 20
Tabela 2: Resultado obtido do cálculo do erro..... 34
Tabela 3: Dados de exclusão..... 37

LISTA DE EQUAÇÕES

Equação 3.1: Valor de limiar. 17
Equação 3.2:Cálculo da distância entre dois pontos. 18
Equação 5.1: Taxa de erro. 34
Equação 5.2: Taxa de acerto. 34

LISTA DE ABREVIAÇÕES, SIGLAS E SÍMBOLOS

PDI – Processamento Digital de Imagem

TC – Tomografia Computadorizada

RGB – *Red, Green and Blue*

MATLAB – MATrix LABoratory

WHO – *World Health Organization*

RT-PCR – *Real Time Polymerase Chain Reaction*

RM – Ressonância Magnética

GGO – *Ground Glass Opacity*

JPEG – *Joint Photographic Experts Group*

PNG – *Portable Network Graphic*

JLS – João Lucas *Segmentation*

JLS2 – João Lucas *Segmentation* 2

MSE – *Mean Square Error*

MET – Máximo Erro Teórico

ECE – Erro em Cada Exame

TA – Taxa de Acerto

TE – Taxa de Erro

Batista, João Lucas de Castro. **Segmentação de Imagens de TC para Análise da Pneumonia Acometida pela Covid-19**. Trabalho de Conclusão de Curso, Graduação em Engenharia Biomédica, Universidade Federal do Rio Grande do Norte, 55p., 2022.

RESUMO

A pandemia atual está matando milhões de pessoas ao redor do mundo, originada do vírus chamado SARS-CoV-2, a doença relacionada a ela recebeu o nome, COVID-19. O SARS-CoV-2 tem sua possível origem na China em mercados de animais silvestres na cidade de Wuhan, onde foram detectados os primeiros casos. Os sintomas desta doença são variados, indo de casos leves e assintomáticos aos mais graves como perda de funcionalidade de pulmão, a partir disso uma grande variedade de diagnósticos foram criados ou adaptados para tentar controlar este vírus. Uma delas, a tomografia computadorizada (TC), cujo funcionamento está relacionado a ondas de raio-x para captar tecidos de áreas do corpo humano. Para este fim foi utilizado técnicas de processamento digital de imagens, como segmentação e filtros, para selecionar as características das imagens da área pulmonar, em exames que buscam identificar o diagnóstico de COVID-19. Na avaliação do algoritmo, foi utilizado o erro quadrático médio para realizar a comparação dos resultados obtidos da segmentação automática da estratégia desenvolvida, com as imagens segmentadas manualmente pelo especialista disponibilizadas na base de dados. Os resultados obtidos na segmentação obtiveram resultados significativos, onde alcançou valores importantes tanto no cálculo do erro quanto na análise comparativa das imagens.

Palavras-chave: COVID-19, Tomografia Computadorizada, Processamento Digital de Imagem, segmentação, análise de imagens.

Batista, Joao Lucas de Castro. **Segmentation of CT Images for Analysis of Pneumonia Affected by Covid-19**. Conclusion Work Project, Graduation in Biomedical Engineering, Federal University of Rio Grande do Norte, 55p., 2022.

ABSTRACT

The current pandemic is killing millions of people around the world, originating from the virus called SARS-CoV-2, the disease related to it was named, COVID-19. SARS-CoV-2 has its possible origin in China in wild animal markets in the city of Wuhan, where the first cases were detected. The symptoms of this disease are varied, ranging from mild and asymptomatic cases to more serious ones such as loss of lung functionality, from which a wide variety of diagnoses have been created or adapted to try to control this virus. One of them, computed tomography (CT), whose operation is related to x-ray waves to capture tissues from areas of the human body. Thus, this work aimed to treat CT scans for a more efficient diagnosis of lung diseases. For this purpose, digital image processing techniques, such as segmentation and filters, were used to select the characteristics of the images of the pulmonary area, in exams that seek to identify the diagnosis of COVID-19. In the evaluation of the algorithm, the mean squared error was used to compare the results obtained from the automatic segmentation of the developed strategy, with the images manually segmented by the specialist made available in the database. The results obtained in the segmentation obtained significant results, where it reached important values both in the error calculation and in the comparative analysis of the images.

Keywords: COVID-19, Computed Tomography, Digital Image Processing, segmentation, image analysis.

1. INTRODUÇÃO

Historicamente o mundo sempre foi assolado por problemas que poderiam possivelmente dizimar a humanidade, como também toda a vida na terra, e um desses terrores se chama pandemia. A este respeito, uma doença pode evoluir para uma pandemia quando ela atinge uma escala global de infecção, expandindo por vários continentes e com fácil contaminação de pessoa para pessoa. Nesse sentido, inúmeras doenças foram um dia consideradas pandemia, como a Peste Negra que teve seu início na Ásia, em meados de 1300, se expandindo até a Europa matando 20 milhões de pessoas, aproximadamente 25% da população mundial e a gripe espanhola, na sua época infectou em torno de 500 milhões de pessoas, teve um período de ação entre 1918 a 1920, com o número estimado de mortos de 50 milhões de pessoas (SCHUELER, 2021).

Infelizmente, estamos vivenciando uma nova pandemia chamada de COVID-19, causada pelo vírus SARS-CoV-2, originado possivelmente de animais silvestres localizados no território China. Pouco tempo depois da sua descoberta, esta doença assolava a maioria dos continentes, matando milhões de pessoas. Os seus sintomas podem variar de leve (febre e dor na garganta) ao crítico (síndrome respiratória aguda grave, parada respiratória, entre outros) (BALUT, 2020).

Portanto, para que um problema biológico de escala mundial como esse seja controlável, existe a necessidade de ter uma via eficiente de diagnósticos. Pois, só pode usar métodos preventivos em larga escala quando se tem a informação de quantas pessoas estão sendo infectadas e como acontece. Exame de sangue, detecção de anticorpos, detecção de RNA, exames de imagens, são alguns dos tipos de diagnósticos mais comuns utilizados no controle do COVID-19. Em específico, os exames de imagens utilizados para este diagnóstico, podem ser de ultrassom, ressonância magnética, raio-x e tomografia computadorizada (TC) (KEVADIYA, 2021).

Os diagnósticos por imagens, só foram possíveis por causa de uma vasta evolução e inovação em várias áreas da ciência. Uma forma de analisar computacionalmente essas imagens vem sendo bastante utilizadas através das técnicas de processamento digital de imagem (PDI).

Uma das técnicas de PDI utilizada na literatura denominada segmentação, foi definida como um conjunto de técnicas aplicadas em uma imagem ou sinal, realçando ou separando algumas características específicas, tendo como objetivo a extração de

informações importantes que talvez não seria possível com o dado original. Propriedade interessante na obtenção das informações significativas na imagem, como uma avaliação inicial para fornecer ao especialista (KHAN, 2013).

Portanto, o uso de técnicas de PDI para ajudar no auxílio ao diagnóstico precoce do COVID-19 se torna relevante. Por ser uma patologia nova, muitos estudos nesta área estão sendo realizados para tentar amenizar a crise mundial que esse vírus causou.

Diante deste contexto, este trabalho visa o uso dessas técnicas para realçar e tratar características pulmonares originadas das imagens de tomografia computadorizada do tórax, através de uma estratégia algorítmica automática, com o intuito de auxiliar no diagnóstico.

1.1. OBJETIVOS

1.1.1. OBJETIVOS GERAL

O objetivo deste trabalho foi o desenvolvimento de uma estratégia algorítmica de segmentação automática, para realçar as características significativas nas imagens de TC do tórax de pessoas acometidas pela COVID-19.

1.1.2. OBJETIVOS ESPECÍFICOS

Para o desenvolvimento deste trabalho, foi necessário discorrer dos seguintes pontos, relacionado ao projeto:

1. Realizar a revisão bibliográfica, nas áreas envolvidas no trabalho.
2. Selecionar uma base de dados.
3. Estudar técnicas de processamento digital de imagens.
4. Selecionar linguagem de programação a ser utilizada no projeto.
5. Estudar e implementar uma estratégia algorítmica.
6. Testar e validar o algoritmo.
7. Comparar o resultado obtido com modelos da base de dados.

1.2. ESTADO DA ARTE

Rajinikanth. (2020), usou técnicas relacionadas a processamento digital de imagens para extrair características do COVID-19 de exames de tomografia computadorizada. Para o estudo foi usado uma base de dados da Organização Radiopaedia com imagens variadas. Os métodos de PDI usados para realçar a imagem visa somar o filtro OTSU com o *Harmony Search Optimization* e para segmentar a região infectada foi utilizado a técnica *watershed*. Com os resultados, foi possível também calcular a situação do pulmão em relação à porcentagem dele ocupado pela infecção.

Makaju. (2018), identificou quais são os melhores métodos para a segmentação e pré-processamento de imagens de câncer obtidas por tomografia computadorizada. De acordo com os autores o método mais usado e prevalente na época, apresentava muitos erros nas imagens resultantes, por isso foi proposto um outro método de segmentação, usando mediana, gaussiana, e *watershed*, obtendo acurácia de 92%.

Tripathi. (2019), comparou diferentes tipos de segmentação para a detecção de câncer pulmonar, utilizando exames de tomografia computadorizada. As técnicas utilizadas nesse trabalho foram: *Otsu*, detecção de bordas, *watershed*, binarização simples, e segmentação baseada em Equação Diferencial Parcial (PDE). Foi observado nos resultados que a tomografia computadorizada tornou o exame em que o tumor foi segmentado mais facilmente e a técnica que obteve resultados relevantes foi a segmentação *watershed*.

Yao. (2021), propôs métodos de segmentação para tomografia computadorizada de pulmão, utilizando de referência padrões normais e anormais de *voxel* (*pixel* com três dimensões). O autor utilizou da seguinte premissa, se todos os *voxels* que se comportam de forma normal forem identificados, os *voxels* anormais serão as áreas afetadas por alguma patologia. A rede neural denominada *NormNet* foi a utilizada para fazer a classificação. Em seus resultados obteve um aumento em sua eficiência comparado a outros modelos, com a possibilidade de expansão para outras doenças pulmonares.

Shariaty. (2019), apresentou o reconhecimento e a segmentação de nódulos pulmonares vindas de tomografia computadorizada. No pré-processamento foi utilizado a técnica *threshold* para separar o que era tecido pulmonar dos restos das estruturas. Fez uso do processamento morfológico e um algoritmo de reconstrução. Os autores observaram

que o sistema criado teve resultado semelhante aos algoritmos mais complexos em relação a sua eficiência e velocidade de processamento.

Raj. (2020), fez uso do *Fuzzy C-means* para a segmentação de doenças no pulmão. Este trabalho separou o *background* da área pulmonar em imagens de tomografia computadorizada, onde utilizaram a segmentação baseada em *clustering* e morfologia matemática para realçar algumas características de borda. Foi descrito pelos autores o desafio de segmentar exames de pulmão, por existir similaridade entre os tecidos, um baixo contraste e possuir ruído na imagem. Com o algoritmo desenvolvido as imagens resultantes obtiveram uma melhora de 1.67%, considerando as características das doenças pulmonares observadas nos exames.

Li. (2021), em seu trabalho desenvolveu um algoritmo usando técnicas de aprendizado de máquina denominado *Hybrid Adaptive Feature Selection (HAFS)* para o reconhecimento de lesões causadas pela doença COVID-19 em exames de tomografia computadorizada. Esse algoritmo procurou destacar as quatro lesões mais comuns nesse tipo de imagem. A base de dados utilizada, possuía 319 pacientes, somando 3734 lesões por todos os *slices*. Como resultado obteve acurácia de, 93.06%, 96.84%, 99.58% e 94.30%, dentre as 4 principais lesões.

Zhao. (2021), descreveu o desenvolvimento de um algoritmo de segmentação para detectar automaticamente lesões em imagens radiológicas do tórax em pessoas acometidas com o COVID-19, para isso foi usado 112 *scans* de tomografia computadorizada. A rede escolhida para a extração de características foi a 3D *V-net*, comparando seu resultado com uma segmentação realizada manualmente pelo especialista. Os resultados obtidos mostraram uma especificidade de 0.92 e uma sensibilidade de aproximadamente 0.96%.

1.3. ESTRUTURA DO TRABALHO

Para a implementação dessa metodologia, foram realizadas pesquisas para compreender melhor algumas condições pulmonares que possam trazer risco ao paciente, com a finalidade de idealizar um método computacional capaz de auxiliar no diagnóstico e facilitar o acompanhamento de pacientes em tais situações. Portanto, este trabalho está organizado em 5 seções, descritas a seguir. A seção 2 descreve a patologia a ser estudada, em relação a sua origem, forma de tratar, diagnóstico e características em exames de imagem. A seção 3 descreve as técnicas de processamento digital de imagens usadas no

trabalho. A seção 4, apresenta a base de dados selecionada, como também, detalha a estratégia algorítmica criada. A seção 5 aborda e discute os resultados obtidos a partir do processamento das imagens dos exames de TC do tórax. Por fim, a secção 6 expõem a conclusão e trabalhos futuros.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. CARACTERÍSTICAS GERAIS

O vírus SARS-CoV-2 foi inicialmente identificado no final de 2019, onde alguns casos de uma pneumonia atípica foram reconhecidos em cidadãos chineses, em específico na cidade de Wuhan. Com a propagação desse vírus, em março de 2020 foi declarada pandemia pela Organização Mundial de Saúde (WHO) (SANTOS, 2020).

Ainda há incerteza com relação à origem do SARS-CoV-2, portanto, foi investigado um mercado em Wuhan, onde se vendia animais silvestres como morcegos, cobras e outros animais. Essa investigação expôs a proximidade do genoma do SARS-CoV-2 com alguns vírus típicos de morcegos (LOTFI, 2022; SANTOS, 2020).

Ao analisar esse genoma do vírus foi possível notar uma similaridade de 88% com os vírus bat-SL-CoZ C 45 e bat-SL-CoZ XC21, no caso do vírus CoV RaTG13 a semelhança chega a ser de 92%. Pela proximidade dos primeiros casos a essa feira em Wuhan, não foi descartada a possibilidade de um portador intermediário, sendo o mais suspeito o animal da espécie pangolim, outros possíveis portadores seriam cobras e tartarugas (LOTFI, 2022).

Ademais a transmissão dessa doença pode ocorrer de diferentes formas (Figura 1), sendo a mais comum pelo ar, como espirro, tosse e fluidos corporais. O SARS-CoV-2 consegue ficar suspenso no ar por aproximadamente 3 horas. Outra forma bastante comum de transmissão pelo ar foi atribuída aos procedimentos odontológicos, onde esses casos necessitam de um cuidado maior tanto para o paciente quanto para o profissional. Contato em superfícies e subsequente na sua própria mucosa (nariz, boca e olhos) também se considera uma forma de propagação, neste caso o vírus tende a permanecer em objetos de 4 a 72 horas dependendo do material da superfície (KARIA, 2020).

Figura 1: Formas de transmissão do COVID-19.

Fonte: (SINDMEDICO, 2021)

2.2. SINTOMAS

O período de incubação do COVID-19 gira em torno de aproximadamente 5.2 dias, podendo se estender até 14 dias. Com estudos de exames usando tomografia computadorizada pode se perceber alguns padrões na evolução da doença sendo, até 4 dias equivale ao estágio inicial, de 5 a 8 dias começa a progressão dos sintomas, o pico sendo entre 9 e 13 dias de infectado (NICOLA, 2020).

O grau de severidade dos sintomas tem uma variância grande, justificado pela quantidade de variáveis que altera como o vírus irá se comportar dentro do corpo humano. Os sintomas (Figura 2), e sua gravidade podem ser divididos em (BULUT, 2020):

- Assintomático: Sem nenhum tipo de sintoma clínico.
- Leve: Febre, dor na garganta, tosse, coriza nasal etc.
- Moderado: Pneumonia, febre e tosse.
- Severo: Progressão rápida da doença, hipoxemia e saturação do oxigênio abaixo de 92%.
- Crítico: Síndrome respiratória aguda grave, parada respiratória, entre outros.

Figura 2: Frequência dos sintomas em pacientes com COVID-19.

Fonte: Adaptado de (SHOAIB, 2021)

Uma característica importante dessa nova pandemia tange a relação entre a severidade dos sintomas e algumas condições que acometem a população, chamadas de comorbidades. Nesse conjunto de comorbidades existe uma grande variedade de condições, sendo algumas delas, doenças nos rins, obesidade, condições neurológicas, diabetes, entre outras. Por tanto, pessoas que sofrem com isso, devem tomar um cuidado extra para que não haja nenhum tipo de complicação vinda de um teste positivo para essa nova doença (CDC, 20222).

Outra comorbidade bastante grave está relacionada com a faixa etária (Figura 3). A maioria dos casos de COVID-19 foram de pessoas entre 30 e 40 anos, contudo os casos mais severos foram em pessoas acima de 50 anos e em relação a parte mais jovem da população teve mais casos assintomáticos (SHOAIB, 2021).

Figura 3: Distribuição de idade de acordo com a severidade dos sintomas.

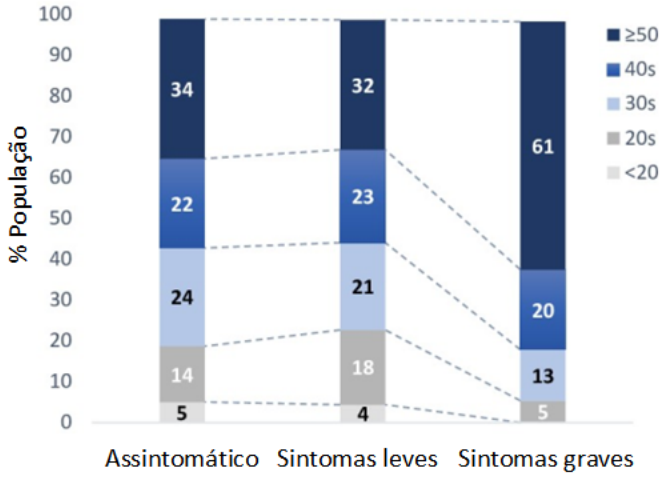

Fonte: Adaptado de (SHOAIB, 2021)

2.3. DIAGNÓSTICO

Por ser uma nova patologia, diferentes tipos de métodos de detecção foram rapidamente criados, com o objetivo de iniciar o tratamento de forma mais eficaz e para o controle da quantidade de pessoas infectadas dentro de uma população.

O RT-PCR, teste que utiliza um cotonete para retirar uma amostra da mucosa nasal que será analisado para saber se existe a presença do vírus no corpo (LIU, 2020). Outro tipo de teste laboratorial pode ser referido através de anticorpos, onde são feitos utilizando uma amostra do sangue de uma pessoa para saber a presença de anticorpos o qual estão ou estiveram combatendo o vírus podendo ser feito com no mínimo uma semana da presença de sintomas (KEVADIYA, 2021).

Outra forma de examinar um paciente pode ser através de uma imagem, como por exemplo o raio x. Esse exame pode vir somado a outros tipos de teste para obter um diagnóstico definitivo da doença, caso tenha sido apresentado sintomas (DENNIE, 2020). Apesar de muito usado em problemas respiratórios, tende a ser mais útil com casos mais graves da doença, visto que as características visuais de um exame são mais proeminentes nesta fase. Contudo, o raio-x não exclui outras doenças respiratórias no qual apresentam as mesmas características do COVID-19 (AI, 2020).

A tomografia como o raio-x tem uma sensibilidade baixa em diferenciar entre uma pneumonia comum e a causada pelo COVID-19. Este fato pode ser confirmado pela grande variação no período em que as características da doença são achadas no paciente. Pode tanto vir a aparecer depois dos sintomas, como também em pacientes assintomáticos (ZHOU, 2020). Contudo ver se necessário o uso desses exames radiográficos para acompanhar a evolução e a severidade da doença, pois uma grande gama de pacientes acometidos pelo COVID-19 sofrerá alteração pulmonar, número chegou a 97% (MINISTÉRIO DA SAÚDE, 2020).

Enquanto a ressonância magnética (RM) normalmente tem uma visualização de tecidos moles bem maior do que a tomografia computadorizada. Por tanto a observação de células inflamatórias, causadas por substâncias liberadas pelo vírus, tende a ser mais indicada neste tipo de exame (KEVADIYA, 2021). Todavia, não tem recomendação para exames de pacientes com COVID-19, pois a dedetização de uma RM tem complicações intrínsecas ao uso e leva mais tempo, diminuindo a eficiência e a segurança desse tipo de exame (ACR, 20222).

Outro exame bastante usado foi o ultrassom, por possuir algumas vantagens comparado aos outros tipos como: o custo-benefício e a portabilidade. Esse exame pode ser usado como um método rápido para ver qual local do pulmão está sendo atingido pela doença. E para algumas características pulmonares, pode obter resultados tão sensíveis quanto a tomografia e o raio-x (CONVISSAR, 2020).

A metodologia ideal para um diagnóstico preciso, tange a soma de vários métodos, sendo preciso somar o resultado laboratorial (sangue e RT-PCR) e o do exame por imagem (ultrassom e tomografia computadorizada). Só assim o escopo completo da situação do paciente e de uma população pode ser analisada.

Seguindo os mesmos passos rápidos da produção dos métodos de diagnósticos, múltiplas empresas estavam com suas vacinas na etapa de produção. Em novembro de 2021, existiam160 vacinas sendo pesquisadas e 8 foram aprovadas para uso emergencial pela WHO (Liu, 2022).

2.4. CARACTERÍSTICAS DE EXAMES VISUAIS

Algumas características são procuradas ao fazer um exame de imagens, são aspectos no qual um profissional da saúde pode identificar uma possível doença, sua gravidade e o local do órgão afetado. Por tanto, se faz necessário um bom sistema de diagnóstico e uma boa qualidade de imagem, para que a sensibilidade do método não sofra alteração. Em relação a exames de COVID-19, por exemplo, existe um certo padrão relacionado aos achados como também o seu estágio.

Ademais, a maioria das regiões pulmonares acometida por alterações vindas do COVID-19 são as subpleurais, região mais periférica do pulmão próxima a caixa toráxica, dentro desse conjunto de áreas a uma prevalência maior na área subpleural do lóbulo inferior (FARIAS, 2020).

Assim sendo, quando o profissional analisa um exame para obter um diagnóstico, procura por alguns padrões na imagem, como: cor, forma e local. Alguns padrões, mostrados na Figura 4, se destacam, como (HANSELL, 2008):

- Opacidade de vidro fosco ou *Ground Glass Opacity* (GGO): Uma opacidade de pouca densidade, Figura 4(a).
- Consolidação: mais denso do que a opacidade de vidro fosco, por tanto se ver com um branco mais intenso, Figura 4(b).
- Padrão em árvore: definida por sua semelhança a uma árvore e seus galhos, Figura 4(c).
- Padrão reticular: Pequenas opacidades lineares, assemelhando a uma rede, Figura 4(d).
- Padrão de pavimentação: Semelhante a paralelepípedos irregulares, geralmente ficam no plano de fundo de uma opacidade de vidro fosco, Figura 3(e).

Figura 4: (a) Opacidade de vidro fosco, (b) Consolidação, (c) Padrão em árvore, (d) Padrão reticular e f) Padrão de pavimentação.

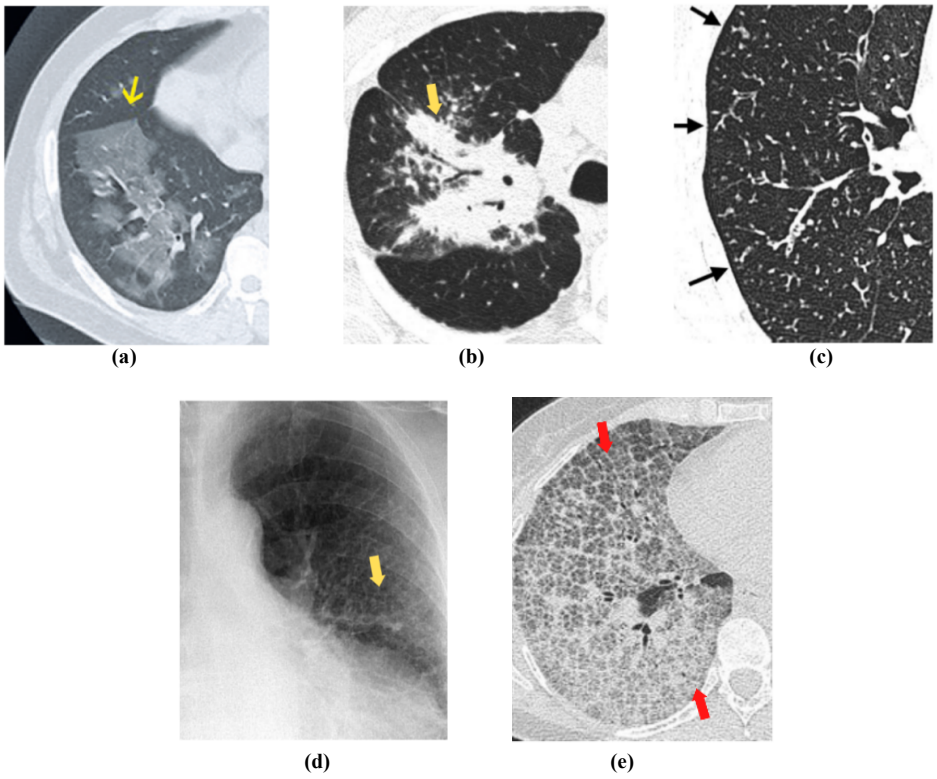

Fonte: Adaptado de (MATOS, 2021) e (HANSELL, 2008).

Em termos estatísticos pode ser subdividido as alterações no pulmão pela frequência em que aparece em exames do tórax: (KWEE, 2020)

- Alta frequência: Ocorre em 70% dos pacientes com COVID-19.
- Frequência intermediárias: Entre 10% a 70%.
- Frequência baixa: Anormalidades com incidência menor do que 10%.

As características identificadas na imagem de forma automática através do algoritmo desenvolvido, são relevantes para discernir uma possível pneumonia causada por esta patologia. Portanto, técnicas laboratoriais precisam vir somadas aos exames de imagens para entender o estado do paciente.

3. PROCESSAMENTO DIGITAL DE IMAGENS

O processamento digital de imagem (PDI), tem como definição o uso de técnicas processadas em um computador, com a finalidade de estudar imagens, realçando ou extraindo características específicas, como por exemplo, reconhecimento de rostos, segmentação de imagens médicas, restauração de imagem, entre outras. Dessa forma, PDI abrange inúmeras áreas da ciência, desde cálculo e álgebra até ciências biológicas (DEWANGAN, 2016).

Gonzalez (2009), descreve todas as etapas que envolve o tratamento de imagens, desde o processo de aquisição, estudo da imagem, tratamento e o realce ou extração de atributos, tendo como o objetivo principal as características significativas da imagem. Dessa forma podem ser utilizados os processos computacionais, como: 1) Baixo nível: Processos simples como, equalização e redução de ruído. Englobando tudo que envolve o pré-processamento, 2) Médio nível: Envolve o reconhecimento de padrões, a extração e a classificação de características e 3) Alto nível: Tem como objetivo interpretar os dados extraídos do nível médio, tentando simular a função do sistema visual humano. Dessa forma, diante da quantidade de técnicas existentes, este trabalho irá descrever apenas as técnicas utilizadas para o desenvolvimento da estratégia algorítmica.

O estudo de imagens médicas se dá na procura de padrões para auxiliar no diagnóstico. Por tanto, todas as etapas que envolvem o processamento de imagem têm um significado importante para ajudar o especialista em um diagnóstico mais rápido e preciso, seja este processo de forma automática ou semiautomática.

3.1. IMAGEM DIGITAL

Uma imagem pode ser considerada um espectro de luz captado pelo o olho e processado pelo sistema visual (ZHANG, 2006). Para que o computador gere uma informação de forma gráfica para que o olho humano assimile, a imagem será separada em blocos pequenos chamados de *pixels* com valores de posição (x, y) e intensidade de cores (KHAN, 2013). A partir dessas informações de *pixels*, o computador gera uma matriz de duas dimensões, valores de posição x e y, com valores de intensidade com tons de cinza, ou de três dimensões, além de posição x e y, temos a posição z onde será dado valores de cores com diferentes intensidades para formar imagens coloridas. As imagens em tons de cinza têm valores de 0 (preto) a 255 (branco) (Figura 5) (GONZALEZ, 2009).

Figura 5: Imagem em tons de cinza.

Fonte: (KURAUCHI, 2016).

A distribuição de cor mais comum se chama RGB (*Red, Green, Blue*), onde 3 matrizes de valores de cor vermelho, verde e azul se juntam em uma matriz de 3 dimensões para formar uma imagem colorida (Figura 6).

Figura 6: Imagem RGB

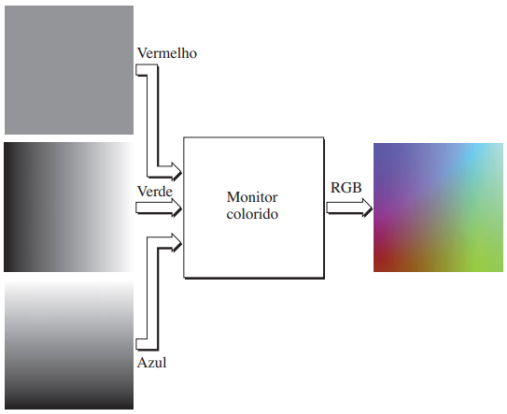

Fonte: Gonzalez, 2009.

Entretanto, o padrão de cor usado e como esse arquivo de imagem vai ser decodificado e interpretado por um computador, muda de acordo com o objetivo para qual esse arquivo foi criado para um compartilhamento mais fácil, edição etc. Por isso, houve a necessidade de criar inúmeras extensões de arquivo para separar cada tipo de imagem como por exemplo, *Joint Photographic Experts Group* (JPEG), *Portable Network Graphic* (PNG) e *Digital Imaging and Communications in Medicine* (DICOM). Neste trabalho as imagens da base de dados possuíam formato JPEG (GONZALEZ, 2009).

3.2. TRANSFORMAÇÕES DE INTENSIDADE

Nessa etapa as técnicas se fundamentam na modificação direta de *pixel* na imagem. Os dois principais grupos do processamento espacial são as transformações de intensidade e filtragem espacial, onde as transformações de intensidade atuam individualmente nos *pixels* de uma imagem, principalmente para fins de operação de contraste e limiarização da

imagem. Enquanto a filtragem espacial atua com a manipulação como o realce de imagens, trabalhando na vizinhança de cada *pixel* de uma imagem (GONZALEZ, 2009).

Os filtros têm o intuito de suavizar a imagem, remover ruídos, borrões, entre outros. Podem ser separados em filtros lineares e não lineares (KUSHWAHA, 2020). Sendo o não linear uma forma de mudar os valores de cada *pixels* em resposta às características dos *pixels* vizinhos (YAROSLAVSKY, 2004).

3.2.1. FILTRO DA MEDIANA

O filtro de mediana funciona envolvendo um número retirado de um conjunto de valores, onde o *pixel* será substituído pelo valor médio de seus vizinhos. Se por acaso a matriz desse filtro for par, considera o valor da mediana, o valor da média dos dois valores centrais (Figura 7).

Figura 7: Filtro da mediana: (a) Imagem Original e (b) Imagem filtrada.

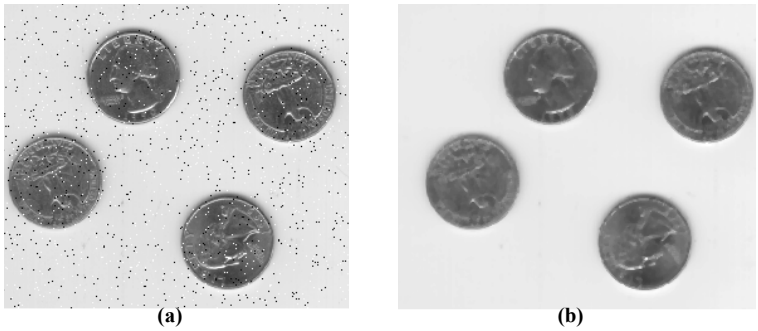

Fonte: (MATHWORKS, 2022).

3.3. PROCESSAMENTO MORFOLÓGICO

A morfologia matemática vem da biologia e estuda estruturas básicas de corpos biológicos. Após sua descoberta, esse termo foi adotado pela matemática para descrever características de objetos como, forma, área, fronteira etc. Muito utilizado em PDI para caracterizar e modificar objetos presentes em uma imagem (GONZALEZ, 2009).

Por se tratar de métodos matemáticos, muito relacionado à álgebra linear, inúmeras formas de aplicação surgiram. Muito dos tipos de técnicas morfológicas, utilizam de um elemento estruturante, sendo um objeto de formas diversas, sendo menor do que a imagem original, onde os cálculos matemáticos são feitos, percorrendo por toda a imagem, como ilustrado na Figura 8 (GONZALEZ, 2009). As operações básicas deste processo aplicada no trabalho são bastantes utilizadas na literatura dentre eles:

- Erosão: Tem a função de erodir a imagem, integrando *pixels* ao plano de fundo, seguindo a forma do elemento estruturante, Figura 8(a) (GONZALEZ, 2009).
- Dilatação: Expande a forma de objetos da imagem, integrando *pixels* a uma área de interesse, usando o elemento estruturante como guia, Figura 8(b) (GONZALEZ, 2009).
- Abertura: Suaviza o contorno de objetos, eliminando protuberâncias destacadas dentro da imagem. Podendo ser interpretada como uma erosão seguida de uma dilatação. Figura 8(c). (GONZALEZ, 2009)

Figura 8: Operadores básicos: (a) Erosão; (b) Dilatação e (c) Abertura.

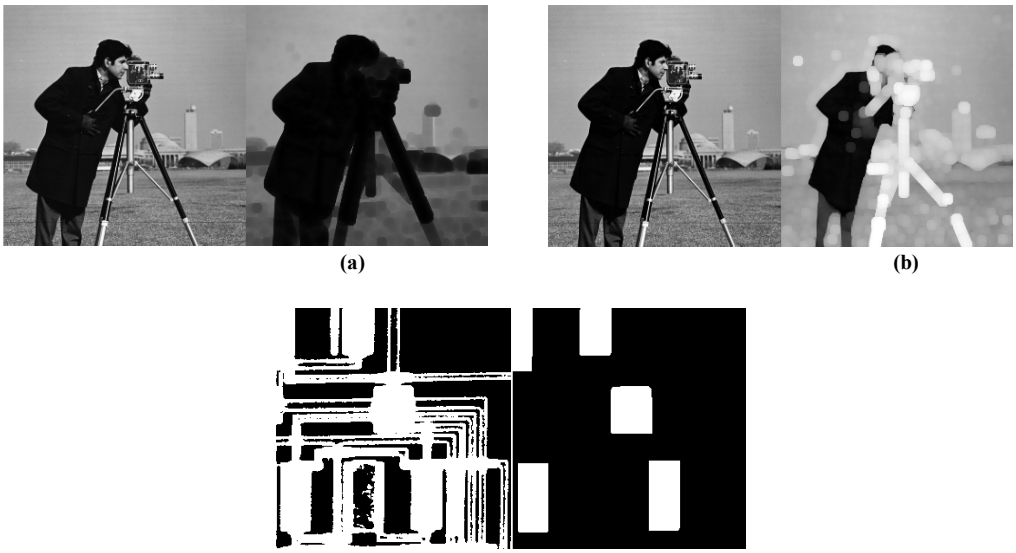

(a) **(b)**

(c)

Fonte: adaptado de (MATHWORKS, 2022).

3.4. REALCE DE IMAGEM

Segundo Gonzalez (2009), realce de uma imagem ou *image enhancements*, foi descrita como técnicas que são capazes de acentuar algumas das suas características expressivas para uma aplicação específica. As operações praticadas encontradas na literatura são: a melhoria da qualidade da imagem, aumento do contraste e uma forma de facilitar algum processamento adicional, como a detecção de regiões e bordas.

As técnicas de realce estão classificadas em espaciais e espectrais. As técnicas espaciais levam em consideração o espaço como domínio da imagem, ou seja, como funções de luminância I (u, v) de cada *pixel* (u, v). Um exemplo de aplicação, o histograma que analisa a distribuição de ocorrência de níveis de cinza (cores) em uma imagem e define os novos valores para cada *pixel*. Em contrapartida, as técnicas espectrais entendem que as

imagens são moldadas de acordo com a frequência (w_u, w_v) de variação das luminâncias entre os *pixels* ao longo da linha u e ao longo da coluna da matriz que compõe a imagem, ou seja, $\mathrm{F}(I(u,v)) = I(w_u, w_v)$ (GONZALEZ, 2009).

3.4.1. HISTOGRAMA EQUALIZADO

As imagens de tons de cinza por ter poucas informações de cores, sofrem com pouco contraste, dificultando a sua interpretação. A equalização de histograma (gráfico de intensidade de cinza e suas frequências) realça as imagens utilizando de cálculos para suavizar seus histogramas (Figura 9), diminuindo tons de cinza com picos de frequência abruptos, reorganizando em outros tons de cinza (GONZALEZ, 2009).

Figura 9: Histograma equalizado da imagem

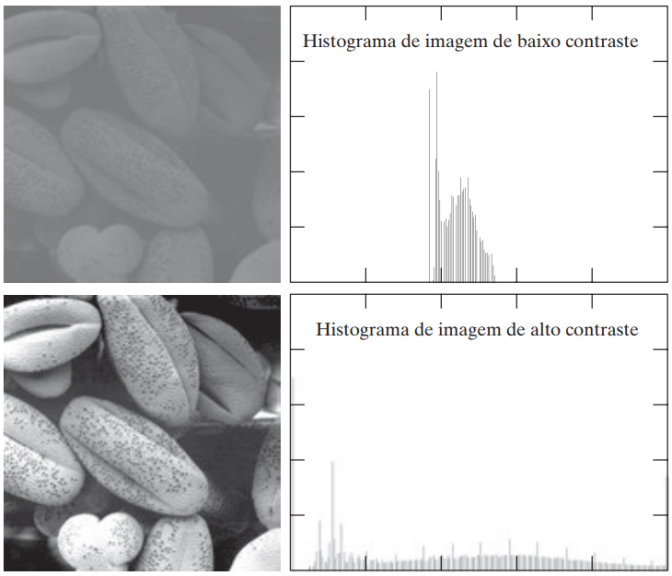

Fonte: Adaptado de (GONZALEZ, 2009).

3.5. LIMIARIZAÇÃO

A limiarização objetiva separar os grupos de cinza de uma imagem utilizando um limiar, de forma que grupos de *pixels* com intensidades parecidas sejam separados de outros (GONZALEZ, 2009). Um ponto determinante no processo acontece na escolha do valor do limiar. Esse valor pode ser selecionado na observação do histograma, onde apresenta as intensidades e a quantidade dos *pixels* da imagem. Dessa forma, pode perceber a formação de vales. O valor do limiar pode ser indicado nestes vales, sendo este o mais próximo do meio da escala dos níveis de cinza da imagem analisada.

O valor do limiar (T) pode ser definido pela Equação (3.1):

$$s = T(r) \tag{3.1}$$

onde *s* representa a intensidade de uma imagem segmentada *g* e *r* descreve a intensidade de uma imagem original *f* em qualquer ponto (*x, y*) (GONZALEZ, 2009). De forma prática *os pixels* com valor 1 fazem parte do objeto e os com valor 0 representam o fundo da imagem (Figura 10).

Figura 10: Limiarização da imagem: (a) Imagem original e (b) Imagem limiarizada.

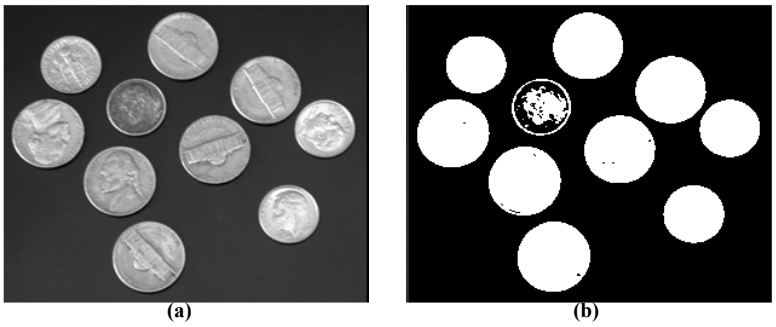

Fonte: adaptado de (MATHWORKS, 2022).

3.6. SEGMENTAÇÃO

A segmentação estabelecida pela extração de características abstratas ou não abstratas. Segundo Gonzalez (2009), a segmentação pode ser separada em dois principais tópicos, a descontinuidade e a similaridade. Na descontinuidade a segmentação se baseia em dividir a imagem em múltiplos objetos utilizando uma diferença de intensidade. Ao passo que a similaridade divide a imagem, mas utilizando padrões ao invés de diferenças entre as intensidades dos *pixels*.

A clusterização, determina uma das maneiras de segmentar imagens, sendo o processo de reorganizá-las em grupos com determinados padrões. O algoritmo *K-means* (Figura 11), Busca organizar, de forma iterativa, os dados de um conjunto em *k* centros de forma que as variáveis com alguma característica em comum permaneçam mais próximos. Levando em conta um conjunto $X = \{p_{1,}p_{2,} \dots, p_n\}$ e uma distância entre seus dados, o algoritmo *K-means* inicia a escolha dos *k* centros $\{C_1, C_2, \dots, C_k\}$ para o agrupamento, associando cada variável do conjunto *X* a um centro mais próximo, segundo a distância *d* formando assim os *k* grupos. A etapa seguinte do algoritmo acontece com a atualização dos centros. Os centros são escolhidos como sendo o ponto que minimiza a soma do erro

quadrático da Distância Euclidiana, d, sobre todos os k grupos. Para calcular a distância entre dois pontos assume os pontos A e B como as coordenadas X_1 e Y_1 para o ponto A e X_2 e Y_2 para o ponto B. Aplicando o cálculo da distância dada pela raiz quadrada do quadrado da subtração das coordenadas X, mais o quadrado da subtração das coordenadas Y, determinada pela Equação 3.2. Assim, o cálculo determina quais *pixels* da imagem pertencem a cada classe. (GONG, 2019).

$$d = \sqrt{((X_1 - X_2)^2 + (Y_1 - Y_2)^2)} \tag{3.2}$$

Figura 11: Segmentação com o algoritmo *K-means*: (a) Imagem original e (b) Imagem segmentada

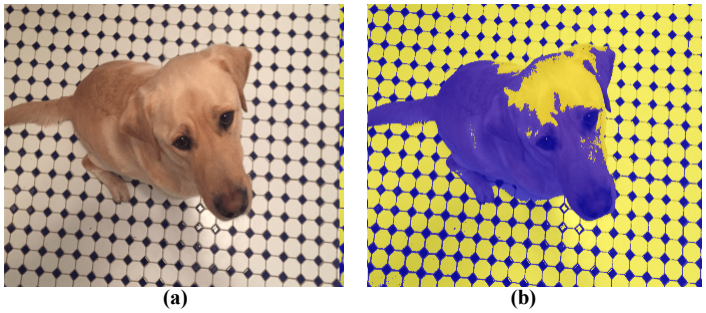

Fonte: adaptado de (MATHWORKS, 2022).

4. SEGMENTAÇÃO DE IMAGENS DO TÓRAX

O trabalho presente, teve como finalidade o uso de técnicas de processamento digital de imagens para o tratamento e a segmentação de imagens de tomografia computadorizada do tórax em pessoas acometidas pelo COVID-19. O algoritmo foi desenvolvido em três etapas: 1) o pré-processamento, visando melhorar a qualidade da imagem, removendo ruídos e realizando correções na imagem provocada pelo processo da aquisição; 2) a segmentação com o objetivo de destacar o pulmão nas imagens; e 3) o pós-processamento aperfeiçoando e potencializando a capacidade de extrair a informação significativa da imagem. Ao finalizar o processamento automático do algoritmo, uma análise comparativa foi realizada, equiparando as imagens resultantes com as imagens modelos, segmentadas manualmente pelos especialistas. A Figura 12 ilustra o diagrama de blocos da estratégia algorítmica desenvolvida.

Figura 12: Diagrama de blocos da estratégia desenvolvida

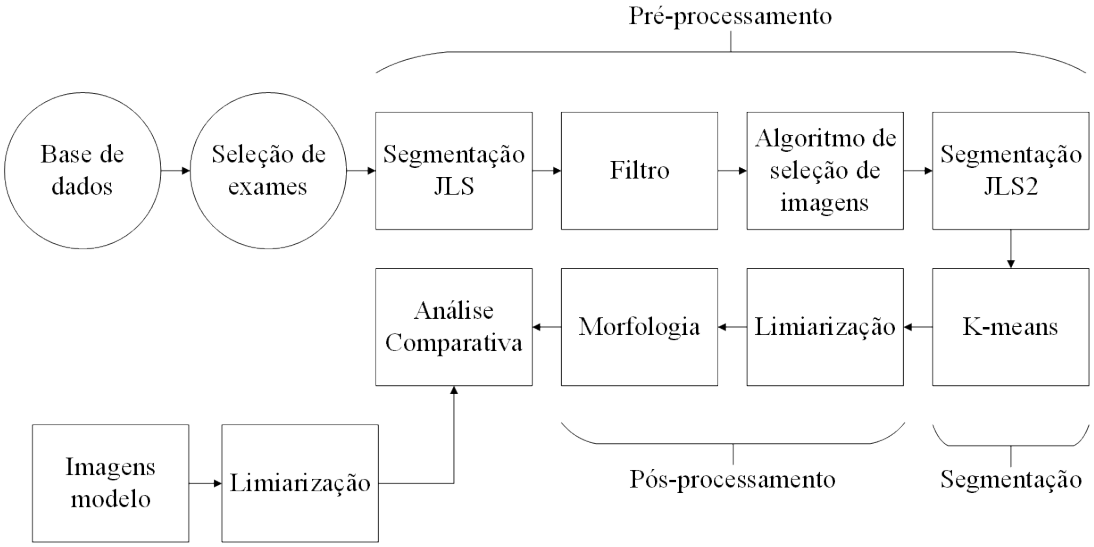

Fonte: Autor.

4.1. SOFTWARE DE IMPLEMENTAÇÃO

Para o desenvolvimento do projeto, foi utilizado o *software* MATLAB (*MATrix LABoratory*), utilizado frequentemente em diversas áreas da ciência, por sua intuitividade, programação simples e com uma excelente eficiência computacional para algoritmos que envolve cálculos matemáticos (MATLAB, 2022).

O MATLAB inclui ferramentas importantes para facilitar a manipulação e a análise de imagens, como sua caixa de ferramentas para PDI chamada de *Image Processing Toolbox* (MATLAB, 2022). Essa caixa de ferramentas inclui uma gama de funções relacionadas a processamento digital de imagens, facilitando assim algumas etapas do trabalho.

4.2. BASE DE DADOS

A base de dados utilizada para o desenvolvimento deste trabalho teve sua origem na organização chinesa, *China Consortium of Chest CT Image Investigation* (CC-CCII). Para este banco de dados foram adquiridos exames de 2743 pacientes (ZHANG, 2020B).

O banco de dados contém aproximadamente 50 *gigabytes* de arquivos separados em pastas *zip*, uma tabela com todas as informações dos pacientes que participaram do consórcio, mantendo sua privacidade (ZHANG, 2020B). Dessa forma a base possui 411529 imagens adquiridas a partir do consórcio, separada por exames, com resolução de 512 x 512 e extensões do tipo PNG e JPG. Em relação ao espectro de cores, todas as imagens estão em tons de cinza (ZHANG, 2020C).

Os exames de TC são classificadas em nova pneumonia por COVID-19, chamada de NCP, pneumonia por causas mais comuns (CP) e exames ditos saudáveis (NORMAL), como apresentado na (Tabela 1) (ZHANG, 2020A).

Tabela 1: Lista de identificação da base de dados.

zip_file	label	patient_id	scan_id	n_slice
CP-1.zip	CP	0	3131	285
CP-1.zip	CP	1	3143	300
CP-1.zip	CP	10	3152	297
CP-1.zip	CP	1065	3104	58
CP-1.zip	CP	1066	3105	59
CP-1.zip	CP	1067	3106	62
CP-1.zip	CP	1068	3107	62

Fonte: Adaptado de (ZHANG, 2020C).

Nesta base de dados existem algumas imagens retiradas de exame que foram manualmente separadas e segmentadas, chamadas de imagens modelo. Nesta separação diferentes partes da imagem foram demarcadas com cores diferentes pelos especialistas como: plano de fundo, campo pulmonar, características de vidro fosco e consolidação

(Figura 13) (ZHANG, 2020A; ZHANG, 2020B). Para essa pesquisa foram utilizados apenas os exames saudáveis e acometidos pela COVID-19.

Figura 13: Exemplo de um exame da base de dados: (a) Imagem com exame normal; (b) Imagem com exame apresentando pneumonia; (c) Imagem do exame com COVID-19 e (d) Imagem modelo delimitada pelo especialista.

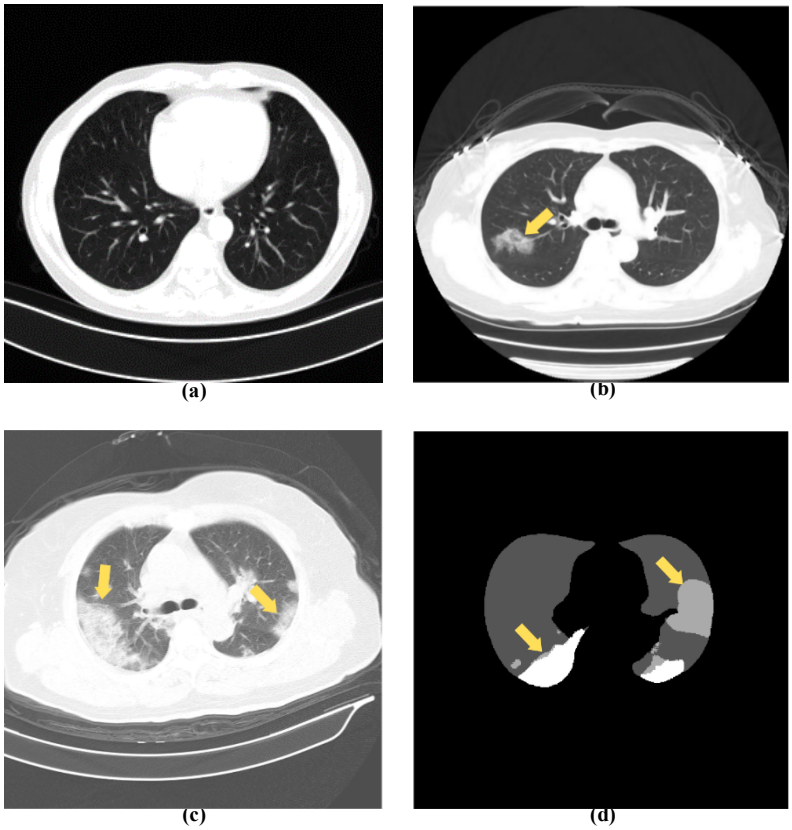

Fonte: Autor.

A base de dados apresenta 150 exames com COVID-19, dentre esses exames selecionaram apenas 5 *slices* de cada um, com a segmentação manual separadas por pastas numeradas, totalizando 750 imagens segmentadas no formato JPG.

4.3. SELEÇÃO DE IMAGENS

Ao passar por um exame de tomografia computadorizada, o paciente tem a maioria do torso "fotografada", por isso muitos dos *slices* salvos do exame não estão dentro da área de interesse analisados pelo profissional. Os critérios de exclusão utilizados para a seleção dos *slices* das imagens nos exames de TC do tórax, foram todas as imagens que não apresentavam a área pulmonar (Figura 14).

Figura 14: Exemplo de um exame de TC do tórax: (a) *Slices* inicial do exame, (b) *Slices* analisados e (c) *Slices* finais do exame.

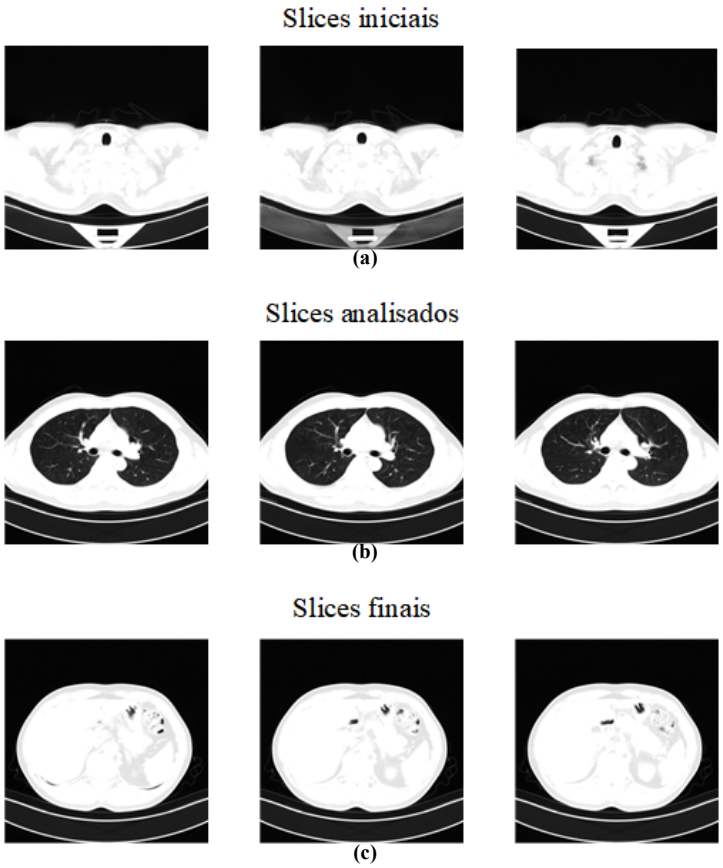

Fonte: Autor, 2022.

4.4. PRÉ PROCESSAMENTO

A etapa de pré-processamento teve como objetivo a retirada de algumas imperfeições ou irregularidade que podem aparecer na imagem durante a aquisição do exame. Imperfeições essas, de origens diversas que variam entre cada *slices* e realçam uma aleatoriedade dentro do mesmo exame. Portanto, a retirada dessa irregularidade promove uma padronização, facilitando sua análise. Irregularidades essas que têm origem diversas como, objetos de metais presentes na hora do exame, movimentação do paciente, defeitos no próprio maquinário, erros na impressão ou digitalização de exames, entre outros.

4.4.1. SEGMENTAÇÃO JLS

O método de segmentação utilizado nas imagens foi denominado João Lucas *Segmentation* (JLS). Estuda a intensidade dos *pixels*, limpando a imagem de qualquer irregularidade. Com a análise das imagens do banco de dados, foi percebido que

irregularidades ou artefatos encontrados nos exames estão com uma intensidade em tons de cinza entre 0 a 195.

O algoritmo percorre a imagem analisando a intensidade de cinza e a localização em que se encontra o *pixel*, realizando a eliminação desses *pixels* e substituindo pela intensidade 0. No sentido de melhorar a qualidade do algoritmo, esse processo foi feito quatro vezes com diferentes condições de localização: 1) o algoritmo percorre a imagem de cima para baixo e da esquerda pra direita, 2) da direita para esquerda e de baixo para cima, 3) da esquerda pra direita de cima para baixo e 4) percorrendo da direita pra esquerda de baixo para cima, como demonstrado na Figura 15.

Figura 15: Caminho percorrido pela segmentação JLS.

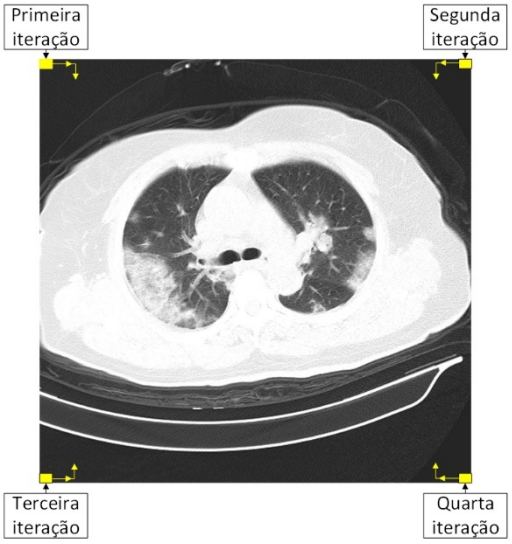

Fonte: Autor.

Foi observado durante esse processamento que alguns tecidos e outras características dentro do pulmão possuem a mesma intensidade. Dessa forma, foi definido um limiar de parada no algoritmo para que o algoritmo de análise de exclusão não eliminasse as características consideradas fundamentais no exame. O limiar de parada foi baseado em uma frequência alta de valores de cinza com uma intensidade maior do que 195, constituído em sua maioria por tecidos corporais como ossos e órgãos, localizados ao redor do pulmão. A partir do momento em que o algoritmo reconhece a alta repetição desses valores na imagem acima do limiar, a limpeza para e segue a análise na próxima linha ou coluna da imagem.

A Figura 16, mostra exemplos de quatro situações, antes e depois da análise que podem acontecer quando esse algoritmo percorre toda a imagem. Essas situações foram resolvidas aplicando o algoritmo de segmentação JLS:

- 1) Existem diferentes valores de *pixels* com valores de intensidade abaixo de 195, sendo estes substituídos pelo valor de intensidade 0, Figura 16(a).
- 2) A Figura 16(b) mostra um exemplo onde parte da imagem apresenta alguns valores de intensidade acima de 195, mas com uma repetição baixa, por isso esses valores foram ignorados e transformados em intensidade 0.
- 3) O terceiro exemplo demonstra valores de intensidade do limiar de 195, com uma repetição alta, ocasionando a parada do algoritmo. Assim que esses valores são encontrados o algoritmo interrompe a análise, eliminando apenas os valores anteriores com o limiar abaixo de 195 (Figura 16(c)).
- 4) No último exemplo há valores de intensidade frequentes acima do limiar, mas diferente do terceiro exemplo esses valores aparecem primeiro, como o algoritmo percorre toda a imagem em sentidos diferentes, apenas os últimos valores que estão abaixo do limiar são substituídos pela intensidade de 0, Figura 16(d).

Figura 16: Exemplo da análise: (a) Primeira situação, (b) Segunda situação, (c) Terceira situação e (d) Quarta situação.

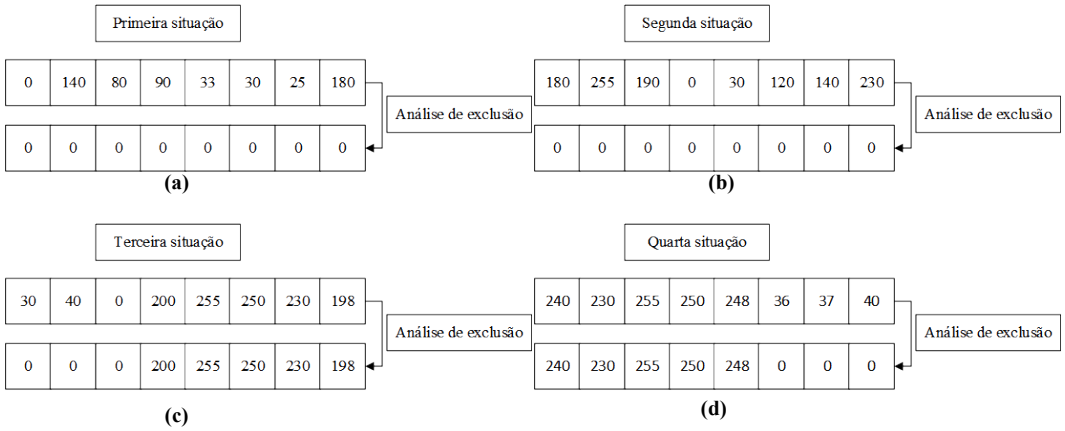

Fonte: Autor.

Após o algoritmo percorrer a imagem por completo eliminando irregularidades, foi obtido resultados análogos ao exemplo da Figura 17.

Figura 17: Exemplo da análise: (a) Imagem original e (b) Imagem segmentada.

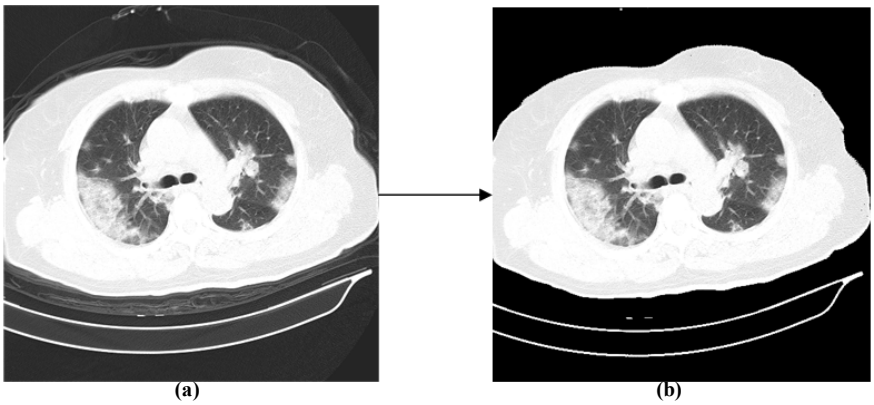

Fonte: Autor.

4.4.2. FILTRO

Nesta etapa foi utilizado duas técnicas: a equalização de histograma adaptativa e o filtro da mediana (Figura 18). O objetivo foi uniformizar a imagem, realçando alguns aspectos necessários para os próximos passos, como:

- Equalização de histograma adaptativa: Suaviza o contraste relacionado aos tons de cinza da imagem, adaptativamente, ou seja, pegando pequenas porções do histograma de forma separada. Com um valor do limiar de contraste 0.002.
- Filtro da mediana: Substitui o valor de um *pixel* pela mediana dos valores dos *pixels* ao seu redor, em forma de matriz. A configuração do tamanho da matriz de vizinhança utilizada para este trabalho foi de [2 2].

Figura 18: Exemplo dos filtros: (a) Imagem segmentada e (b) Imagem filtrada.

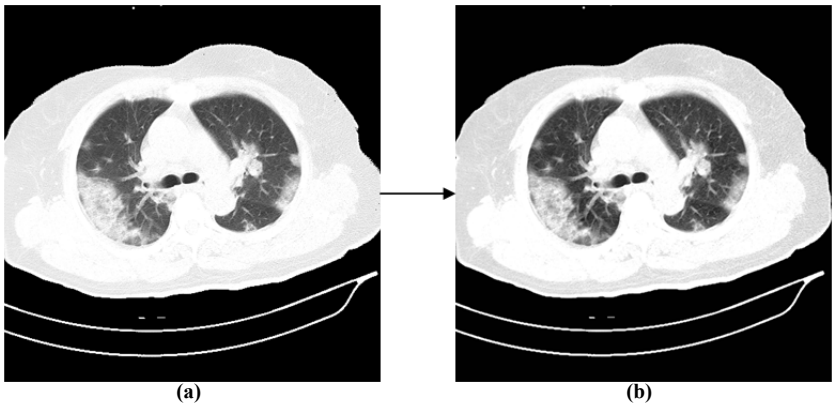

Fonte: Autor.

4.4.3. SELEÇÃO DE IMAGENS A PARTIR DOS EXAMES

A seleção de imagem propriamente, calcula o crescimento de tons de cinza de um *range* específico, durante a sequência de imagens de um exame. Com a análise do gráfico abaixo (Figura 19), foi observado que tanto as imagens do início quanto do final do exame, tendem a ter menos *pixels* com tonalidade de cinza entre 60 e 140. Apesar das imagens com algum tipo de patologia aparecer com tonalidade mais brancas, ainda existe um crescimento de tons mais escuro nas imagens, justificado pela anatomia do pulmão que tem um crescimento em sua área e um decaimento ao chegar mais próximo do seu final.

Figura 19: Resultado da seleção da imagem.

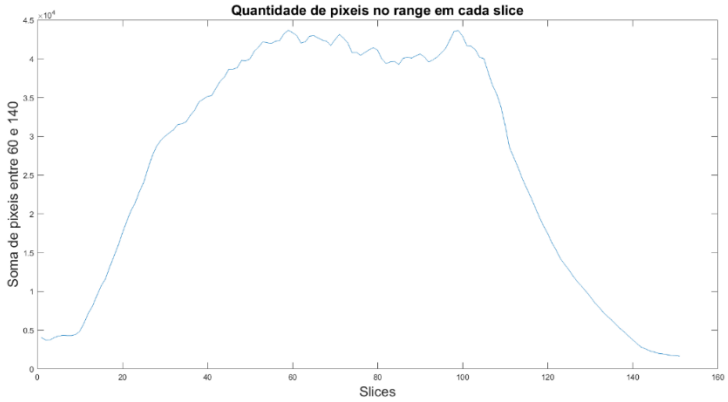

Fonte: Autor.

Com essas informações, o cálculo de exclusão das imagens desnecessárias pode ser realizado. Dessa forma, observando o gráfico da Figura 19, foi separado em seu primeiro quarto e último quarto relacionado ao número de *slices* do exame. Após esta separação, foi feita uma análise de qual imagem nesses intervalos representa a menor soma de *pixels*. Em seguida, este número total de *pixels* no *range* foi multiplicado por uma constante de 1.5 (Equação 4.1) e (Equação 4.2), e com esse novo valor o algoritmo procura a imagem que tem a soma total de *pixels* pretos (0) de maior proximidade do valor calculado.

$$PQ = Vpm * 1.5 \tag{4.1}$$

$$UQ = Vum * 1.5 \tag{4.2}$$

onde *PQ* representa os valores escolhidos para o primeiro quarto, *Vpm* dado pela imagem do primeiro quarto com menor incidência de *pixels* pretos, *UQ* definido pelo valor escolhido para o último quarto e *Vum* pela imagem do último quarto com menor incidência de *pixels* pretos.

A Figura 20 ilustra um exemplo de como foi aplicado. No primeiro quarto de imagens, a imagem com menor soma de *pixels* no *range* foi a imagem de número 3 com o valor de 2335, quando multiplicado pela constante o valor obtido foi aproximadamente 3502, a imagem (*slice*) que mais se aproxima desse valor foi a de número 6 do exame (Figura 20(a)). Enquanto no último quarto do exame, o mínimo tem valor de 2569 (*slice* de número 150), multiplicado pela constante, o resultado se iguala a aproximadamente 3853, com a análise algorítmica a imagem escolhida foi de número 144 no exame (Figura 20(b)).

Figura 20: Exemplo da seleção do exame: a) Primeiro quarto selecionado; b) Segundo quarto selecionado.

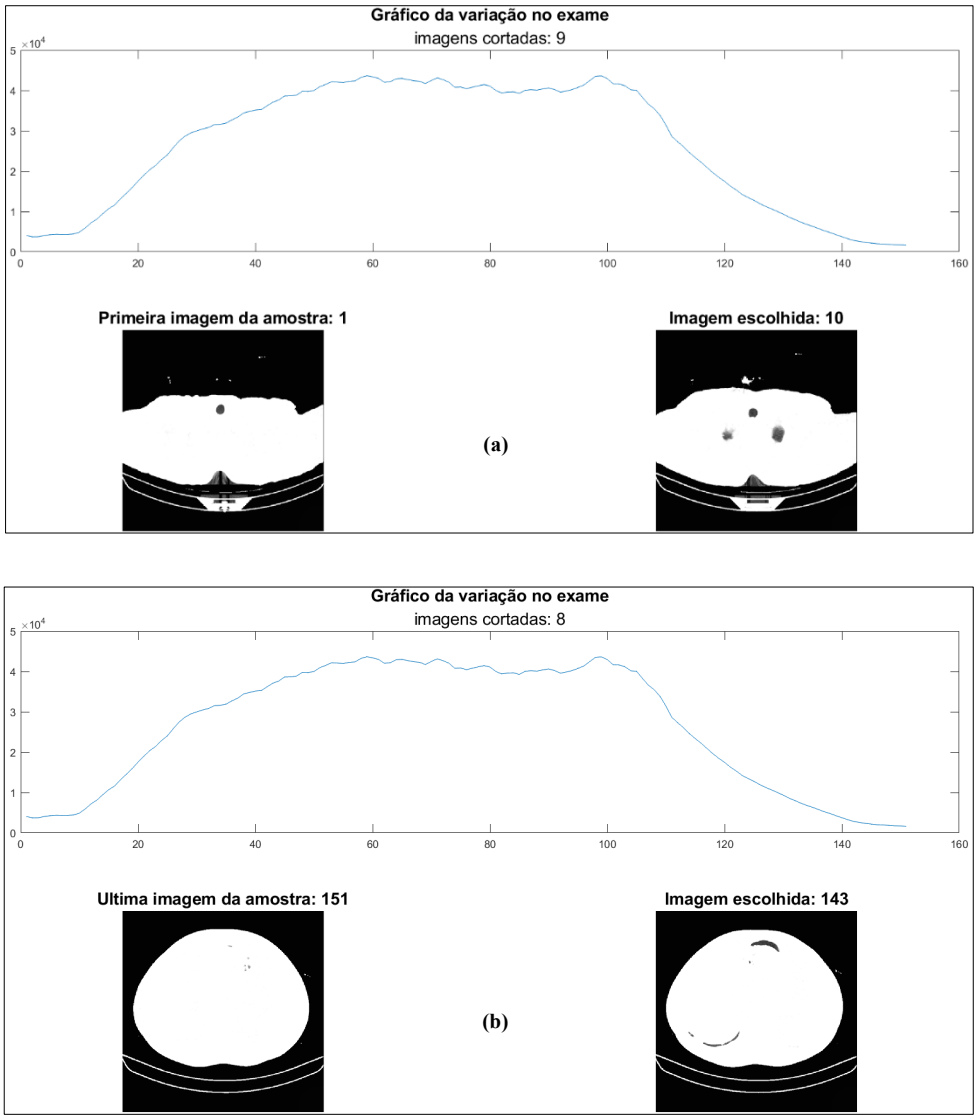

Fonte: Autor.

A quantidade de *slices* retiradas do exame, depende de como se comporta a análise do algoritmo e das características inerentes do próprio. Seja pela configuração do maquinário utilizado ou pela natureza anatômica do paciente, o número de imagens excluídas pode ser um número grande ou ter poucas variações.

4.4.4. SEGMENTACAO JLS2

A segunda segmentação JLS2, visa a retirada de partes da imagem com o objetivo de tornar a etapa da segmentação do algoritmo *K-means* mais eficiente. Por causa das tonalidades similares na imagem, o *K-means* tende a organizar as classes de forma errônea e fora do lugar esperado. Apesar de não ser um processo visualmente perfeito, teve um resultado essencial para a metodologia final da estratégia algorítmica criada.

O JLS2 baseia seu funcionamento na intensidade do *pixel*, sua vizinhança e a localização em que ele se encontra na imagem. Apesar de semelhante ao JLS algumas diferenças são pertinentes destacar, a primeira delas está no fracionamento da imagem de forma adaptativa e vetorial ao invés de ser *pixel* a *pixel*, ou seja, vetores de tamanho 1 x 20 contendo parte da imagem foi retirado e analisado separadamente. O algoritmo analisa esse vetor, muda os *pixels* que tem as intensidades de *pixels* maiores do que 210 e menores do que 246 estabelecido pelo algoritmo. Ao realizar a mudança nos *pixels* analisados, coloca essa parte extraída de volta na imagem (Figura 21).

Figura 21: Exemplo da segmentação JLS2.

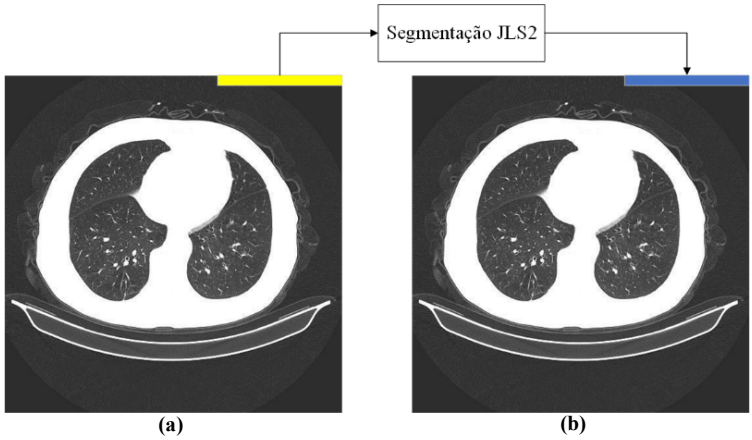

Fonte: Autor.

Outra diferença nesta segmentação está no fato do algoritmo analisar o *slice* do exame 5 vezes, com o vetor percorrendo no total de quatro sentidos com direções diferentes. Foi necessário passar de baixo para cima, da esquerda para direita duas vezes

devido o detalhe da maca que fica abaixo do paciente e aparece na imagem (Figura 22). Foi preciso analisar essa porção da imagem duas vezes com atributos diferentes para retirar tanto a cama do paciente quanto outras especificidades, como tecidos corporais que são identificados com as mesmas intensidades da informação do pulmão.

Figura 22: Exemplo da ordem de análise no *slice*.

Fonte: Autor.

Nem todas as características possíveis de serem extraídas pelo algoritmo serão vistas nas imagens do exame, pois cada imagem possui características distintas. A imagem segmentada pode ser observada na (Figura 23).

Figura 23: Exemplo da segmentação: (a) Imagem filtrada e (b) Segunda segmentação.

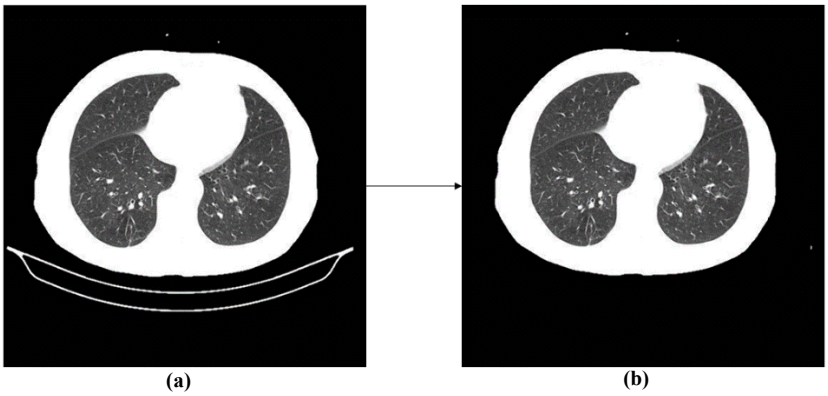

Fonte: Autor.

4.5. SEGMENTAÇÃO

O próximo passo consiste na segmentação do pulmão. Esta etapa fez uso da segmentação através do algoritmo *K-means* para separar a imagem em diferentes regiões.

O objetivo do *K-means* neste trabalho foi agrupar as imagens em diferentes classes, visando o destaque do pulmão. Para isto, após alguns testes, foi escolhido o uso de três classes para realizar a separação das regiões de interesse na imagem, agrupando em plano de fundo, áreas com uma alta tonalidade de cinza e área pulmonar (Figura 24).

Figura 24: Exemplo da segmentação com o algoritmo *K-means*: (a) Segunda segmentação e (b) *K-means*.

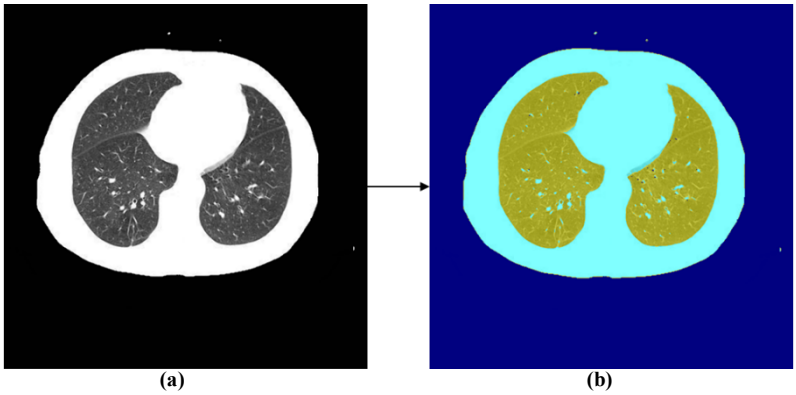

(a) **(b)**

Fonte: Autor.

4.6. PÓS-PROCESSAMENTO

Nesta etapa, algumas características importantes nas imagens são extraídas, resultando em algum tipo de discriminação entre as classes de objetos (GONZALEZ, 2009).

4.6.1. LIMIARIZAÇÃO

Por definição na configuração do algoritmo *K-means*, ocorre algumas mudanças na tonalidade dos *clusters* em diferentes imagens, dificultando a padronização dos resultados. Dessa forma, foi necessário padronizar utilizando a limiarização, onde foi comparado a localização dos *cluster* resultante do algoritmo *k-means*, com a tonalidade do *pixel* dos centros, resultando em uma imagem binária. Este processo também teve o propósito de excluir as porções, que não foram consideradas áreas de pulmão determinadas pelo *K-means* como mesma área e determinada como plano de fundo (Figura 25).

Figura 25: Exemplo do processo da limiarização: (a) Resultado do algoritmo *K-means* e (b) Imagem binarizada.

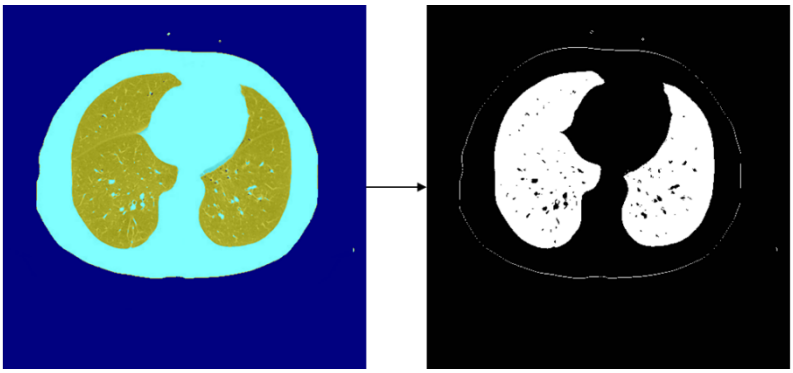

(a) **(b)**

Fonte: Autor.

Nesta etapa também foi aplicado a limiarização nas imagens modelo, transformando-a em uma imagem binária contendo o plano de fundo e a área pulmonar (Figura 26).

Figura 26: Exemplo da limiarização nas imagens modelo: (a) Imagem modelo e (b) Imagem binária.

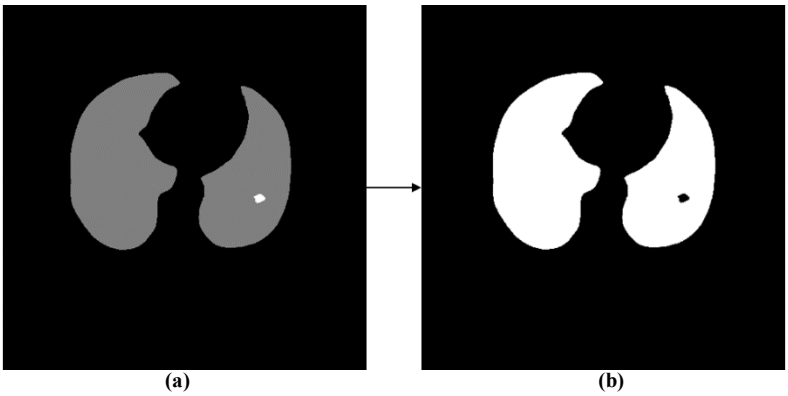

(a) **(b)**

Fonte: Autor.

4.6.2. PROCESSAMENTO MORFOLÓGICO

A técnica de morfologia escolhida foi a abertura e o elemento estrutural utilizado foi o retângulo de tamanho [2 2]. Na etapa anterior, alguns ruídos fora da área do pulmão ainda prevalecem, e esta operação aplicada nas imagens eliminou esses ruídos sem alterar as características essenciais da região do pulmão (Figura 27).

Figura 27: Exemplo do processamento morfológico: (a) Imagem binarizada e (b) Operação morfológica de abertura.

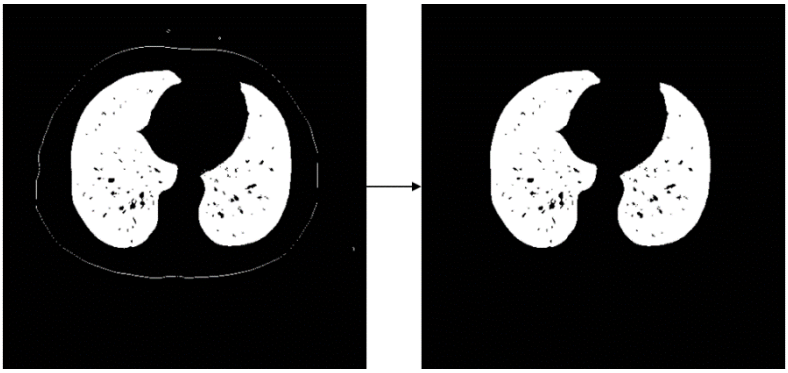

Fonte: Autor.

No pós-processamento foi feita limiarização e morfologia nas imagens dos exames, como também uma limiarização nas imagens modelos para facilitar a análise comparativa.

Na etapa de comparação, todas as imagens utilizadas na segmentação automática foram as mesmas utilizadas na confecção das imagens segmentadas manualmente. Em específico foi aplicado no exame de numeração 111 e para exemplos de cada etapa a imagem de número 92 deste exame foi selecionada. A Figura 28 ilustra as imagens dos exames na primeira fila e as imagens modelos na segunda linha.

Figura 28: Exemplo de exames e os modelos manuais.

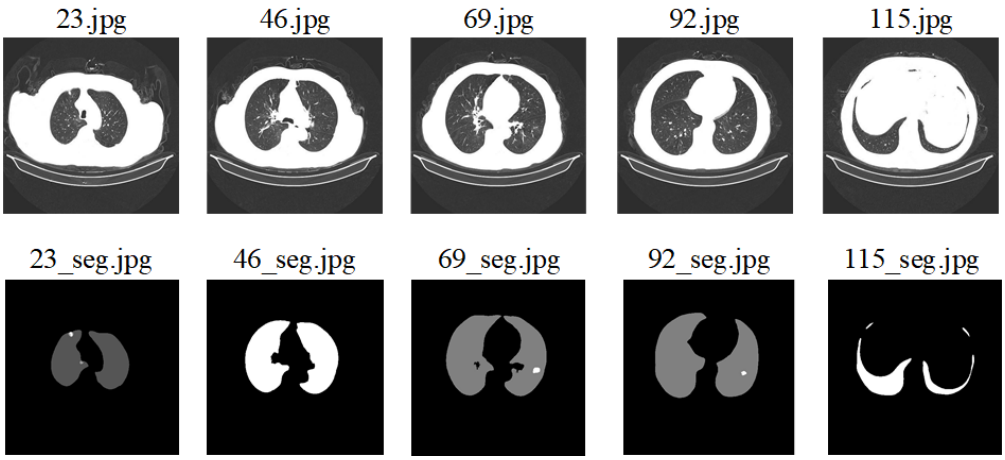

Fonte: Autor.

5. RESULTADOS E DISCUSSÕES

Os resultados obtidos são descritos a seguir. Para isto, essa seção foi dividida entre o estudo dos resultados da segmentação do pulmão e os resultados da seleção de imagens.

5.1. RESULTADOS DA SEGMENTAÇÃO DO PULMÃO

A análise dos resultados da segmentação do pulmão consiste em erro médio quadrático, comparativo entre a imagem original e a segmentada automaticamente, por fim uma comparação com as imagens modelos.

5.1.1. ERRO MÉDIO QUADRÁTICO

O Erro Médio Quadrático ou *Mean Square Error* (MSE) tem a função de calcular o índice de similaridade de um experimento com seu valor ideal (Hodson, 2021). Sendo o valor zero do erro quando o experimento tem valor igual ao ideal e o erro máximo, onde os dois diferem por completo.

Em PDI o MSE utiliza a distância de tonalidades de cinza entre dois *pixels* de mesma coordenada para verificar a similaridade entre duas imagens. Esta distância tem como cálculo a subtração entre o valor da tonalidade de *pixel* de uma imagem, com a tonalidade de *pixel* de outra imagem, percorrendo por toda a imagem. Após este cálculo, foi aplicada a média entre todas as distâncias, para obter um valor de erro único por comparação de imagens. Esta técnica de erro não leva em consideração a resolução da imagem. Os valores mínimos e máximos do MSE em imagens de tons de cinza são 0 (erro ideal teórico, mas não alcançável, imagens idênticas) até 65025 (erro máximo teórico, onde a imagem difere totalmente da outra).

O erro médio quadrático foi utilizado em todos os exames contendo imagens modelos. As imagens consideradas ideais na comparação feita pelo MSE, vêm do resultado do algoritmo de limiarização dos modelos manuais. Como este método compara imagem por imagem, foi calculada a média entre os erros de todas em cada exame. Outro cálculo realizado foi a regra de três com o Máximo Erro Teórico (MET) e os Erros em Cada Exame (ECE), com o objetivo de descobrir a Taxa de Acerto (TA) e a Taxa de Erro (TE) de cada exame, demonstrado na (Equação 5.1) e (Equação 5.2), obtendo os resultados ilustrados na (Tabela 2) que representa uma amostragem dos testes aplicados nas imagens da base de dados:

- O exame com o menor erro foi o 48 que obteve um índice MSE de 517.78, obtendo uma porcentagem de acerto de 99.2% enquanto a porcentagem de erro foi de 0.8%.
- O exame 108 obteve o maior erro quadrático, 2541.79, com uma taxa de acerto de 96.09% e uma taxa de erro de 3.91%.
- No total a base de dados teve uma média de 1149.51 em relação ao MSE e uma taxa de acerto de 98.24% resultando em uma taxa de erro de 1.76%.

$$TE = (ECE \times 100) \div MET \tag{5.1}$$

$$TA = 100 - ((ECE \times 100) \div MET) \tag{5.2}$$

Tabela 2: Resultado obtido do cálculo do erro.

Exame	qtd imagens	qtd modelos	Média do MSE por exame	% de erro	% de acerto
0	138	5	817,4223747	1,257089	98,742911
1	156	5	749,8047592	1,153102	98,846898
2	139	5	933,166951	1,43509	98,56491
3	134	5	1416,154572	2,177862	97,822138
4	148	5	1160,905103	1,785321	98,214679
5	177	5	905,7514793	1,392928	98,607072
6	150	5	879,3707428	1,352358	98,647642
7	141	5	1131,109942	1,7395	98,2605
8	173	5	981,8892639	1,510018	98,489982
9	146	5	1509,106097	2,320809	97,679191
10	139	5	616,3885933	0,947926	99,052074
11	152	5	1238,608612	1,904819	98,095181
12	139	5	920,6523766	1,415844	98,584156
13	145	5	860,5396248	1,323398	98,676602
14	135	5	1010,795182	1,554472	98,445528
15	129	5	1508,665552	2,320132	97,679868
16	121	5	1341,610648	2,063223	97,936777
17	139	5	1434,630221	2,206275	97,793725
18	144	5	1007,868379	1,549971	98,450029
19	168	5	2207,552569	3,394929	96,605071
20	147	5	1048,383234	1,612277	98,387723

Fonte: Autor.

5.1.2. COMPARATIVOS VISUAIS ENTRE IMAGEM

O próximo comparativo feito foi entre a imagem original e a segmentada automaticamente. Foi observado algumas áreas dentro do pulmão no qual foram

consideradas outros tipos de classe, determinada pelo algoritmo *K-means*, ao contrário de estar dentro da classe do pulmão (Figura 29). Essas áreas podem ser tanto de estruturas anatômicas do próprio pulmão ou áreas acometidas pelo COVID-19.

Figura 29: Exemplo: (a) Imagem original e (b) Imagem segmentada automaticamente.

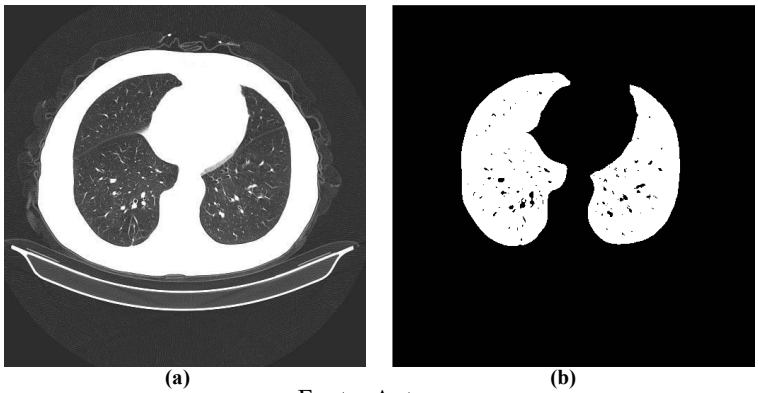

(a) **(b)**

Fonte: Autor

Em contraste, o algoritmo criado obteve sucesso em destacar a área do pulmão em termos de perímetro, em pulmões sem características de pneumonia encontrados na sua borda. Apesar da imagem utilizada não ter tais características, alguns outros exames tinham algumas manchas que alteraram o funcionamento do algoritmo, aumentando por sua vez o valor do MSE.

Na comparação com a imagem modelo, foi observado que os pontos não considerados pulmões, quando são estruturas anatômicas ou parte de uma característica do COVID-19, de área pequena, a alteração do erro tende a ser baixa (Figura 30).

Figura 30: Exemplo: (a) Imagem modelo binarizada e (b) imagem segmentada automaticamente.

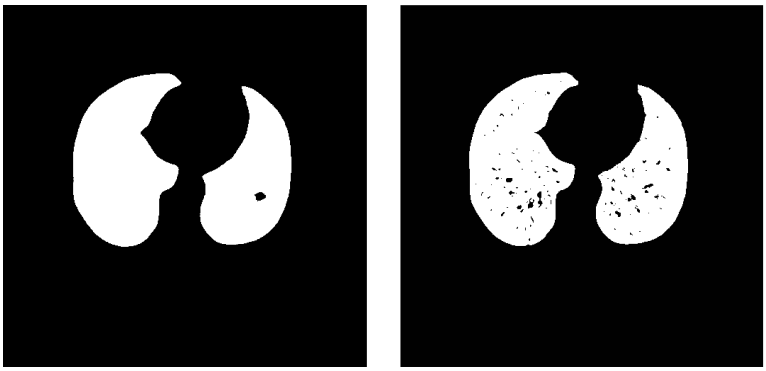

(a) **(b)**

Fonte: Autor.

A comparação da imagem modelo binarizada e a não utilização do modelo sem alteração, se dá pela não especificidade na demarcação dos locais acometidos pela doença. Em alguns casos, a imagem escolhida como exemplo dos processos, na área colocada como acometida por COVID-19, não aparenta visualmente ter características de pneumonia (Figura 31). Portanto, a lógica de comparação entre a imagem modelo e a segmentada pelo sistema, se resume apenas em analisar a diferença entre a área do pulmão sem considerar os possíveis achados de pneumonia.

Figura 31: Exemplo: (a) Imagem original e (b) Imagem modelo.

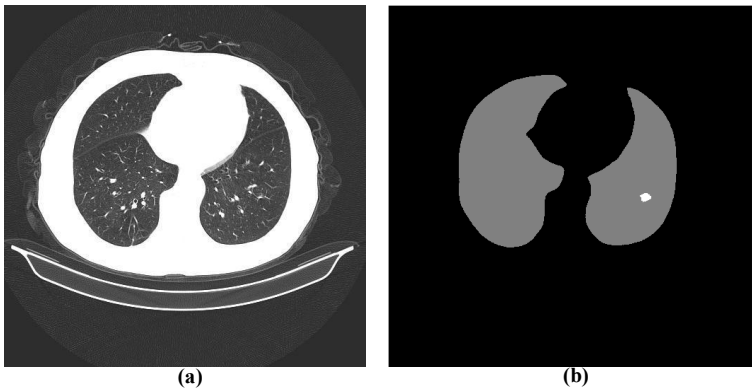

(a) **(b)**

Fonte: Autor.

5.2. RESULTADOS DA EXCLUSÃO DE IMAGENS

Na análise de resultados da exclusão de imagem, não foi possível usar uma grande variedade de exames contidos na base de dados por causa de alguns problemas, como a falta de organização das pastas, onde algumas possuía múltiplos exames, dificultando a identificação da ordem. Outro fator está nas pastas dos exames separadas, por ter imagens modelos. A ordem numérica dos *slices*, se encontra em um modelo diferente da lógica de organização do algoritmo, dificultando na identificação da primeira e da última imagem.

Alguns exames têm sua ordem dos *slices* trocadas, o que era para ser o último está no início e vice-versa. Contudo, o algoritmo usa a mesma constante para o cálculo de seleção, tanto para o começo quanto para o final. Dessa maneira, este problema de organização da base não impede que a estratégia criada possa ser executada normalmente.

Foram selecionados dez exames com COVID-19 sem os problemas listados anteriormente, para demonstrar a quantidade de *slices* excluídos da análise. (Tabela 3).

Tabela 3: Dados de exclusão

Tipo	Numeração	Qtd de imagens	Nova imagem inicial	Nova imagem final	Total de imagens retiradas
NCP	41	151	10	143	17
NCP	42	146	7	139	13
NCP	100	139	7	127	18
NCP	101	136	10	128	17
NCP	102	132	5	124	12
NCP	103	150	6	144	11
NCP	104	139	3	134	7
NCP	105	145	9	141	12
NCP	106	150	6	144	11
NCP	107	146	2	140	7
Total		1434			125

Fonte: Autor.

Analisando as imagens excluídas pela etapa de seleção das imagens, alguma delas ainda apresentavam a área pulmonar mesmo que ínfima, dificultando assim a análise pelo algoritmo desenvolvido

6. CONCLUSÃO

Existe uma grande dificuldade em segmentar imagens de tomografia computadorizada, por causa da tonalidade de cor em diferentes tecidos que envolve ou inserido no pulmão, pouco contraste no exame e uma elevada frequência de ruídos. Por isso os tons de cinza de algumas áreas da imagem são bastante próximos e uniformes, justificando o imenso trabalho na utilização das técnicas de PDI para tentar destacar esse órgão.

Outro ângulo que corrobora com a dificuldade de se trabalhar com esse tipo de exame, está no fato da raridade de pesquisas que trabalham apenas com PDI na segmentação de imagens. A maioria dos projetos atuais, não só relacionados à doença tratada neste projeto, usam aprendizado profundo como objeto principal de estudo, utilizando as técnicas de PDI apenas no pré e no pós-processamento. A escolha de trabalhar apenas com PDI ao invés de inteligência artificial se dá por inúmeros fatores como pouco poder computacional e uma base de dados com imagens com pouca variação.

A segmentação de imagens do tórax, com o intuito de destacar o pulmão, precisa ser refinada, para que seja possível uma diferenciação maior entre o pulmão e os outros aspectos da imagem. Apesar disso, a binarização do pulmão no final do algoritmo, deixou evidente a eficiência do algoritmo para o destaque do pulmão em termos de perímetro.

Na análise de imagens não necessárias, pode ser observado uma diminuição de *slices* em um exame que ajuda na procura por estruturas relacionadas a doenças pulmonares. Como comentado na seção 4, algumas imagens com pequenas áreas pulmonares acabaram sendo excluídas pelo algoritmo, caso isso seja consertado, o algoritmo criado pode também oferecer uma possível ferramenta aos hospitais para diminuir a quantidade de imagens armazenadas no seu banco de dados, minimizando a falta de armazenamento de dados no futuro.

Dessa forma, a metodologia aplicada neste trabalho teve o objetivo de ajudar os profissionais da saúde a obter resultados mais eficazes e rápido, visando não substituir as técnicas mais tradicionais de se avaliar um exame, mas sim em adicionar mais ferramentas para o analisador.

6.1. TRABALHOS FUTUROS

Para dar sequência a esta pesquisa, existe a necessidade de continuar o desenvolvimento de algoritmos mais eficientes. Como proposta para a melhoria do sistema temos:

- Refinamento do algoritmo de segmentação, com técnicas mais robustas.
- A utilização de outros tipos de técnicas relacionados ao processamento digital de imagens.
- Adicionar parâmetros mais robustos na seleção de imagens em um exame.
- Criar um sistema de destaque para imagens apenas com algum tipo de área acometida por doenças pulmonares.
- Estudar o uso de métodos mais simples de inteligência artificial para a classificação de doenças pulmonares, como a regressão linear.

REFERÊNCIAS BIBLIOGRÁFICAS

Ai, T., Yang, Z., Hou, H., Zhan, C., Chen, C., Lv, W., Tao, Q., Sun, Z., & Xia, L. (2020). Correlation of Chest CT and RT-PCR Testing for Coronavirus Disease 2019 (COVID-19) in China: A Report of 1014 Cases. Radiology, 296(2), E32–E40. https://doi.org/10.1148/radiol.2020200642

BULUT, Cemal. Epidemiology of COVID-19. Turkish Journal Of Medical Sciences, Ankara, p. 563-570, abr. 2020.

Centers For Disease Control And Prevention (org.). People with Certain Medical Conditions. 2022. Disponível em: https://www.cdc.gov/. Acesso em: 30 maio 2022.

CONVISSAR, David L. Application of Lung Ultrasound During the COVID-19 Pandemic: A Narrative Review. International Anesthesia Research Society, Massachusetts, v. 131, n. 2, p. 345-350, abr. 2020.

De Farias, L. de P. G., Fonseca, E. K. U. N., Strabelli, D. G., Loureiro, B. M. C., Neves, Y. C. S., Rodrigues, T. P., Chate, R. C., Nomura, C. H., Sawamura, M. V. Y., & Cerri, G. G. (2020). Imaging findings in COVID-19 pneumonia. Clinics, 75, 1–8. https://doi.org/10.6061/clinics/2020/e2027

Dennie, C., Hague, C., Lim, R. S., Manos, D., Memauri, B. F., Nguyen, E. T., & Taylor, J. (2020). Canadian Society of Thoracic Radiology/Canadian Association of Radiologists Consensus Statement Regarding Chest Imaging in Suspected and Confirmed COVID-19. Canadian Association of Radiologists Journal, 71(4), 470–481. https://doi.org/10.1177/0846537120924606

Dewangan, S. K. (2016). Importance and Applications of Digital Image Processing. International Journal of Computer Science & Engineering Technology, 7(07), 2229–3345. http://www.ijcset.com/docs/IJCSET16-07-07-003.pdf

Dos Santos, W. G. (2020). Natural history of COVID-19 and current knowledge on treatment therapeutic options. Biomedicine and Pharmacotherapy, 129(May), 110493. https://doi.org/10.1016/j.biopha.2020.110493

Gong, S., Liu, C., & Ji, Y. (2019). Advanced Image and Video Processing Using MATLAB. In Springer International Publishing AG (Vol. 2). http://link.springer.com/10.1007/978-3-319-01520-0

GONZALEZ, Rafael. Processamento Digital de Imagens. 3. ed. São Paulo: Pearson Education, 2009. 644 p.

Hansell, D. M., Bankier, A. A., MacMahon, H., McLoud, T. C., Müller, N. L., & Remy, J. (2008). Fleischner Society: Glossary of terms for thoracic imaging. Radiology, 246(3), 697–722. https://doi.org/10.1148/radiol.2462070712,

Hodson, T. O., Over, T. M., & Foks, S. S. (2021). Mean Squared Error, Deconstructed. Journal of Advances in Modeling Earth Systems, 13(12), 1–10. https://doi.org/10.1029/2021MS002681

Karia, R., Gupta, I., Khandait, H., Yadav, A., & Yadav, A. (2020). COVID-19 and its Modes of Transmission. SN Comprehensive Clinical Medicine, 2(10), 1798–1801. https://doi.org/10.1007/s42399-020-00498-4

KEVADIYA, Bhavesh D. Diagnostics for SARS-CoV-2 infections. Nature Materials, Nebraska, v. 20, p. 593-605, mai. 2021.

Khan, a. M. (2013). Image Segmentation Methods: A Comparative Study. *International Journal of Soft Computing and Engineering (IJSCE)*, *3*(4), 84–92.

KURAUCHI, Andrew. Means, Medians and Images. 2016. Disponível em: http://kurauchi.com.br/. Acesso em: 11 jul. 2022.

Kushwaha, U., Jha, S., & Desai, B. (2020). Image Filtering - Techniques, Algorithm and Applications. GIS Science Journal, 7(11), 970–975. https://www.researchgate.net/publication/346583845

Kwee, T. C., & Kwee, R. M. (2020). Chest ct in covid-19: What the radiologist needs to know. Radiographics, 40(7), 1848–1865. https://doi.org/10.1148/rg.2020200159

Li, W., Cao, Y., Yu, K., Cai, Y., Huang, F., Yang, M., & Xie, W. (2021). Pulmonary lesion subtypes recognition of COVID-19 from radiomics data with three-dimensional texture characterization in computed tomography images. BioMedical Engineering OnLine, 20(1), 123. https://doi.org/10.1186/s12938-021-00961-w

Liu, J., Han, P., Wu, J., Gong, J., & Tian, D. (2020). Positive rate of RT-PCR detection of SARS-CoV-2 infection in 4880 cases from one hospital in Wuhan, China, from Jan to Feb 2020. Journal of Infection and Public Health, 13(January), 1224–1228.

Liu, K., & Lou, Y. (2022). Optimizing COVID-19 vaccination programs during vaccine shortages. Infectious Disease Modelling, 7(1), 286–298. https://doi.org/10.1016/j.idm.2022.02.002

LOTFI, Melika. COVID-19: Transmission, prevention, and potential therapeutic opportunities. Sciencedirect, Theran, p. 254-266, abr. 2020.

MAKAJU, Suren; PRASAD, P.W.C.; ALSADOON, Abeer; SINGH, A.K.; ELCHOUEMI, A. Lung Cancer Detection using CT Scan Images. Procedia Computer Science, [S.L.], v. 125, p. 107-114, 2018. Elsevier BV. http://dx.doi.org/10.1016/j.procs.2017.12.016.

MATLAB. Image Processing Toolbox. 2022. Disponível em: https://www.mathworks.com/. Acesso em: 06 jul. 2022.

Matos, M. J. R. de, Rosa, M. E. E., Brito, V. M., Amaral, L. T. W., Beraldo, G. L., Fonseca, E. K. U. N., Chate, R. C., Passos, R. B. D., Silva, M. M. A., Yokoo, P., Sasdelli Neto, R., Teles, G. B. da S., Silva, M. C. B. da, & Szarf, G. (2021). Diagnósticos diferenciais de opacidade em vidro fosco aguda na tomografia computadorizada de tórax: ensaio pictórico. Einstein (São Paulo), 19, 1–8. https://doi.org/10.31744/einstein

Ministério da Saúde. (2020). Diagnóstico e Tratamento da COVID-19 TRATAMENTO. Secretaria De Ciência, Tecnologia, Inovação E Insumos Estratégicos Em Saúde, 1, 1–398.

MURPHY, Andrew. CT artifacts. 2022. Disponível em: https://radiopaedia.org/articles/ct-artifacts.

Nicola, M., O'Neill, N., Sohrabi, C., Khan, M., Agha, M., & Agha, R. (2020). Evidence based management guideline for the COVID-19 pandemic - Review article. International Journal of Surgery, 77(April), 206–216. https://doi.org/10.1016/j.ijsu.2020.04.001

Prefeitura Municipal Santo Antônio de Posse (org.). Guia de Prevenção. 2020. Disponível em: https://pmsaposse.sp.gov.br/coronavirus/. Acesso em: 01 jun. 2022.

RADIOLOGY, American College Of (org.). ACR Guidance on COVID-19 and MR Use. Disponível em: www.acr.org. Acesso em: 30 maio 2022.

Raj, S., Vinod, D. S., Mahanand, B. S., & Murthy, N. (2020). Intuitionistic Fuzzy C Means Clustering for Lung Segmentation in Diffuse Lung Diseases. Sensing and Imaging, 21(1), 1–16. https://doi.org/10.1007/s11220-020-00300-8

RAJINIKANTH, V. Harmony-Search and Otsu based System for Coronavirus Disease (COVID-19) Detection using Lung CT Scan Images. Applied Sciences, 6 abr. 2020.

SCHUELER, Paulo. O que é uma pandemia. 2021. Disponível em: https://www.bio.fiocruz.br/index.php/br/noticias/1763-o-que-e-uma-pandemia. Acesso em: 16 dez. 2021.

Shariaty, F., Hosseinlou, S., & Rud, V. Y. (2019). Automatic lung segmentation method in computed tomography scans. Journal of Physics: Conference Series, 1236(1). https://doi.org/10.1088/1742-6596/1236/1/012028

Shoaib, N., Noureen, N., Munir, R., Shah, F. A., Ishtiaq, N., Jamil, N., Batool, R., Khalid, M., Khan, I., Iqbal, N., & Zaidi, N. (2021). COVID-19 severity: Studying the clinical and demographic risk factors for adverse outcomes. PLoS ONE, 16(8 August), 1–10. https://doi.org/10.1371/journal.pone.0255999

Tripathi, P., Tyagi, S., & Nath, M. (2019). A Comparative Analysis of Segmentation Techniques for Lung Cancer Detection. Pattern Recognition and Image Analysis, 29(1), 167–173. https://doi.org/10.1134/S105466181901019X

Wiggins, R. H., Davidson, H. C., Harnsberger, H. R., Lauman, J. R., & Goede, P. A. (2001). Image file formats: past, present, and future. Radiographics: A Review Publication of the Radiological Society of North America, Inc, 21(3), 789–798. https://doi.org/10.1148/radiographics.21.3.g01ma25789

Yao, Q., Xiao, L., Liu, P., & Zhou, S. K. (2021). Label-Free Segmentation of COVID-19 Lesions in Lung CT. IEEE Transactions on Medical Imaging, 40(10), 2808–2819. https://doi.org/10.1109/TMI.2021.3066161

Yaroslavsky, L. (2004). Digital Holography and Digital Image Processing. In Digital Holography and Digital Image Processing (Vol. 54, Issue June). https://doi.org/10.1007/978-1-4757-4988-5

Zhang, K., Liu, X., Shen, J., Li, Z., Sang, Y., Wu, X., Zha, Y., Liang, W., Wang, C., Wang, K., Ye, L., Gao, M., Zhou, Z., Li, L., Wang, J., Yang, Z., Cai, H., Xu, J., Yang, L., … Wang, G. (2020A). Clinically Applicable AI System for Accurate Diagnosis, Quantitative Measurements, and Prognosis of COVID-19 Pneumonia Using Computed Tomography. Cell, 181(6), 1423-1433.e11. https://doi.org/10.1016/j.cell.2020.04.045

ZHANG, Kang (2020C). Data from China National Center for Bioinformation. China Consortium of Chest CT Image Investigation.

ZHANG, Kang. AI Diagnosis. (2020B). Disponível em: http://ncov-ai.big.ac.cn. Acesso em: 08 jul. 2022.

Zhang, Y. J. (2006). An overview of image and video segmentation in the last 40 years. *Advances in Image and Video Segmentation*, 1–15. https://doi.org/10.4018/978-1-59140-591-7.ch001

Zhao, C., Xu, Y., He, Z., Tang, J., Zhang, Y., Han, J., Shi, Y., & Zhou, W. (2021). Lung segmentation and automatic detection of COVID-19 using radiomic features from chest CT images. Pattern Recognition, 119, 108071. https://doi.org/10.1016/j.patcog.2021.108071

Zhou, Z., Guo, D., Li, C., Fang, Z., Chen, L., Yang, R., Li, X., & Zeng, W. (2020). Coronavirus disease 2019: initial chest CT findings. European Radiology, 30(8), 4398–4406. https://doi.org/10.1007/s00330-020-06816-7