



Kaique Rijkaard de Sousa Oliveira

Segmentação Pulmonar em Imagens de Radiografias de Tórax Utilizando Redes Neurais Convolucionais

João Pessoa – PB

Março/2023



Kaique Rijkaard de Sousa Oliveira

Segmentação Pulmonar em Imagens de Radiografias de Tórax Utilizando Redes Neurais Convolucionais

Dissertação de Mestrado submetida à Coordenação do Programa de Pós-Graduação em Engenharia Elétrica do Instituto Federal da Paraíba, como requisito necessário à obtenção do grau de Mestre em Ciências no Domínio da Engenharia Elétrica.

Área de Concentração: Telecomunicações.

Linha de Pesquisa: Processamento de Sinais.

Carlos Danilo Miranda Regis, Prof. Dr.

Orientador

João Pessoa - PB, Março de 2023

© Kaique Rijkaard de Sousa Oliveira – kaiquerijkaardcc@gmail.com

Dados Internacionais de Catalogação na Publicação (CIP)
Biblioteca Nilo Peçanha do IFPB, *campus* João Pessoa

O48s Oliveira, Kaique Rijkaard de Sousa.

Segmentação pulmonar em imagens de radiografias de tórax utilizando redes neurais convolucionais / Kaique Rijkaard de Sousa Oliveira. – 2023.

81 f. : il.

Dissertação (Mestrado em Engenharia Elétrica) - Instituto Federal de Educação da Paraíba / Programa de Pós-Graduação em Engenharia Elétrica (PPGEE), 2023.

Orientação : Profº D.r Carlos Danilo Miranda Regis.

1. Processamento de sinais. 2. Rede neural convolucional.
3. Radiografia. 4. Covid. 5. Pulmão. I. Título.

CDU 004.932:615.849(043)



MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA

PROGRAMA DE PÓS-GRADUAÇÃO *STRICTO SENSU*

MESTRADO EM ENGENHARIA ELÉTRICA

KAIQUE RIJKAARD DE SOUSA OLIVEIRA

**SEGMENTAÇÃO PULMONAR EM IMAGENS DE RADIOGRAFIAS DE TÓRAX UTILIZANDO REDES
NEURAIS CONVOLUCIONAIS**

Dissertação apresentada como requisito para obtenção do título de Mestre em Engenharia Elétrica, pelo Programa de Pós- Graduação em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba – IFPB - Campus João Pessoa.

Aprovado em 31 de março de 2023.

Membros da Banca Examinadora:

Dr. Carlos Danilo Miranda Regis

IFPB - PPGEE

Dr. Suzete Elida Nobrega Correia

IFPB - PPGEE

Dr. Luiz Guedes Caldeira

IFPB - Membro Externo

João Pessoa/2023

Documento assinado eletronicamente por:

- **Carlos Danilo Miranda Regis**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 31/03/2023 11:22:35.
- **Suzete Elida Nobrega Correia**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 31/03/2023 11:24:11.
- **Luiz Guedes Caldeira**, PROFESSOR DE ENSINO SUPERIOR NA ÁREA DE ORIENTAÇÃO EDUCACIONAL, em 31/03/2023 11:29:23.

Este documento foi emitido pelo SUAP em 22/03/2023. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código 407392
Verificador: eecc17f87f
Código de Autenticação:



Av. Primeiro de Maio, 720, Jaguaribe, JOÃO PESSOA / PB, CEP 58015-435
<http://ifpb.edu.br> - (83) 3612-1200

Dedico a minha mãe, esposa, família e amigos, por todo suporte, incentivo e amizade.

Agradecimentos

- ▣▣▣ Agradeço primeiramente a Deus por toda saúde e perseverança para superar todos obstáculos e alcançar mais esta realização. O senhor abençoou e protegeu toda essa trajetória para a conquista deste sonho!
- ▣▣▣ A minha mãe Iracema de Sousa Oliveira por todas orações e apoio, e a minha esposa Vangerlândia dos Santos Sousa por estar sempre comigo no suporte, incentivando e aconselhando durante esta caminhada.
- ▣▣▣ Ao meu pai Geraldo da Silva Oliveira (*in memoriam*) que apesar da sua ausência física, esteve sempre presente em meu coração concedendo força para superar as dificuldades.
- ▣▣▣ A Maria José, Larissa e Luís Henrique por estarem sempre presentes em minha trajetória.
- ▣▣▣ Aos demais familiares e amigos que me ajudaram e motivaram para mais esta conquista.
- ▣▣▣ Ao meu professor e orientador Carlos Danilo Miranda Regis pela amizade e orientações por toda caminhada. Muito agradecido por todos os ensinamentos, confiança e paciência para alcançar este sonho.
- ▣▣▣ A banca examinadora pela avaliação desta pesquisa, contribuindo com seus conhecimentos para agregar mais relevância para este trabalho.
- ▣▣▣ Ao IFPB pela excelência na formação acadêmica e profissional.
- ▣▣▣ E por fim a todos aqueles que de alguma maneira auxiliaram na minha vida. Agradeço!

“Deus é nosso refúgio e a nossa fortaleza, auxílio sempre presente na adversidade.”

(Salmos 46:1)

Resumo

As redes neurais convolucionais são comumente aplicadas em imagens médicas como radiografia, tomografia computadorizada, entre outras, com intuito de classificar ou segmentar patologias. Contudo em procedimentos nas imagens de radiografia de tórax para segmentar as regiões pulmonares, ocorrem falhas que podem ser por causa das características externa as regiões de interesse. Dessa forma, esta dissertação tem o objetivo de analisar as segmentações das regiões dos pulmões, utilizando as redes UNet e MultiResUNet nas classes saudável, com COVID-19 e não COVID, verificando sua performance com as medidas de desempenho de Índice de Jaccard e Coeficiente Dice. Os estudos são realizados por categorias para identificar os comportamentos dos modelos para cada classe, e posteriormente avaliar processamentos que possam otimizar a rede neural. Nos resultados entre as classes, a categoria não COVID teve mais dificuldade na identificação dos modelos do que nas demais classes. A média das métricas de desempenho das classes sem pré-processamento obteve os melhores resultados, nos quais a UNet alcançou o Índice de Jaccard de 94,29% e Coeficiente Dice de 97,00% e a MultiResUNet conseguiu o Índice de Jaccard de 94,15% e Coeficiente Dice de 96,93%. Nos cenários analisados, ambos os modelos obtiveram valores de medidas de desempenho semelhantes, entretanto a UNet apresentou maior eficiência devido as suas execuções, tanto no treinamento quanto nas detecções, ocorrerem em um período de tempo inferior ao da MultiResUNet.

Palavras-Chave: Processamento de sinais; Rede neural convolucional; Radiografia; Covid; Pulmão.

Abstract

Convolutional neural networks are commonly applied in medical images such as radiography, computed tomography, among others, in order to classify or segment pathologies. However, in procedures on chest X-ray images to segment the lung regions, failures occur that may be due to the external characteristics of the regions of interest. Thus, this dissertation aims to analyze the segmentations of the regions of the lungs, using the UNet and MultiResUNet networks in the healthy, with COVID-19 and non-COVID classes, verifying their performance with the performance measures of Jaccard Index and Dice Coefficient. The studies are performed by categories to identify the behavior of the models for each class, and later evaluate processing that can optimize the neural network. In the results between classes, the non-COVID category had more difficulty in identifying the models than in the other classes. The average of the performance metrics of the classes without pre-processing obtained the best results, in which the UNet reached the Jaccard Index of 94,29% and the Dice Coefficient of 97,00% and the MultiResUNet reached the Jaccard Index of 94,15% and the Coefficient Dice of 96,93%. In the analyzed scenarios, both models obtained similar performance measurement values, however the UNet showed greater efficiency due to its executions, both in training and in detections, occurring in a shorter period of time than MultiResUNet.

Key-Words: Signal processing; Convolutional neural network; Radiography; Covid; Lung.

Lista de Siglas e Abreviaturas

RT-PCR – Transcrição Reversa de Ensaios de Reação em Cadeia da Polimerase; do inglês, *Reverse Transcription of Polymerase Chain Reaction*

RM – Ressonância Magnética

ML – Aprendizado de máquina; do inglês, *Machine Learning*

DL – Aprendizado profundo; do inglês, *Deep Learning*

CNN – Redes neurais convolucionais; do inglês, *Convolutional Neural Network*

GPU – Unidade de processamento gráfico; do inglês, *Graphics Processing Unit*

RNN – Redes neurais recorrentes; do inglês, *Recurrent Neural Network*

ROI – Região de interesse; do inglês, *Region of Interest*

OAR – Órgãos de risco; do inglês, *Organs at Risk*

CXR – Radiografia de tórax; do inglês, *Chest X-ray*

IoU – Interserção sobre união; do inglês, *Intersection-Over-Union*

OMS – Organização mundial da saúde

SARS-CoV-2 – Síndrome Respiratória Aguda Grave Coronavírus 2; do inglês, *Severe Acute Respiratory Syndrome Coronavirus 2*

TC – Tomografia computadorizada

DWT – Transformação *wavelet* discreta; do inglês, *Discrete Wavelet Transform*

FPN – do inglês, *Feature Pyramid Networks*

IA – Inteligência artificial

RL – Aprendizado por reforço; do inglês, *Reinforcement Learning*

RNA – Redes neurais artificiais

FCN – Rede totalmente convolucional; do inglês, *Fully Convolutional Network*

ReLU – Unidade linear retificada; do inglês, *Rectified Linear Unit*

MRI – Imagem por ressonância magnética; do inglês, *Magnetic Resonance Imaging*

QU – Universidade do Qatar; do inglês, *Qatar University*

TU – Universidade de Tampere; do inglês, *Tampere University*

DSC – Coeficiente de similaridade de dados; do inglês, *Dice Similarity Coefficient*

Lista de Figuras

2.1	Habilidades da Inteligência Artificial.	9
2.2	Categorias do aprendizado de máquina.	10
2.3	Estrutura genérica da rede neural artificial	13
2.4	Arquitetura da U-Net.	17
2.5	Arquitetura da MultiResUNet.	18
2.6	Estrutura do bloco <i>MultiRes</i>	19
2.7	Estrutura do <i>Res Path</i>	19
3.1	Exemplos das radiografias e suas respectivas máscaras da base de imagem para os pulmões normal, acometido por COVID-19 e não COVID-19.	21
3.2	Metodologia para o treinamento das redes neurais convolucionais na segmentação pulmonar utilizando métricas para mensurar seu desempenho. . .	21
3.3	Processo de previsão e cálculo das medidas de desempenho em uma imagem individual.	23
3.4	Exemplo da estrutura de exibição para análise visual da segmentação.	23
4.1	Imagens dos pulmões saudáveis de número (677) e (680) que obtiveram valores satisfatórios nas previsões da UNet.	27
4.2	Imagens dos pulmões saudáveis de número (398) e (601) que obtiveram falhas de similaridades nas previsões da UNet.	28
4.3	Imagens dos pulmões com COVID-19 de número (557) e (637) que obtiveram valores satisfatórios nas previsões da UNet.	28
4.4	Imagens dos pulmões com COVID-19 de número (179), (375) e (157) que obtiveram falhas de similaridades nas previsões da UNet.	29

4.5	Imagens dos pulmões com COVID-19 de número (132), (268) e (311) com posicionamentos diferentes que obtiveram falhas de similaridades nas previsões da UNet.	30
4.6	Imagens dos pulmões não COVID de número (492) e (693) que obtiveram valores satisfatórios nas previsões da UNet.	31
4.7	Imagens dos pulmões não COVID de número (487), (554) e (573) que obtiveram falhas de similaridades nas previsões da UNet.	31
4.8	Imagens dos pulmões não COVID de número (298), (391) e (572) com posicionamentos diferentes que obtiveram falhas de similaridades nas previsões da UNet.	32
4.9	Gráfico da classe saudável com os resultados das medidas de desempenho de cada imagem de teste da UNet.	34
4.10	Gráfico da classe com COVID-19 com os resultados das medidas de desempenho de cada imagem de teste da UNet.	34
4.11	Gráfico da classe não COVID com os resultados das medidas de desempenho de cada imagem de teste da UNet.	35
4.12	Imagens dos pulmões saudáveis de número (4) e (8) que obtiveram valores satisfatórios nas previsões da MultiResUNet.	36
4.13	Imagens dos pulmões saudáveis de número (275), (372) e (398) que obtiveram falhas de similaridades nas previsões da MultiResUNet.	37
4.14	Imagens dos pulmões com COVID-19 de número (120) e (127) que obtiveram valores satisfatórios nas previsões da MultiResUNet.	38
4.15	Imagens dos pulmões com COVID-19 de número (179), (256) e (139) que obtiveram falhas de similaridades nas previsões da MultiResUNet.	39
4.16	Imagens dos pulmões com COVID-19 de número (121), (132) e (268) com posicionamentos diferentes que obtiveram falhas de similaridades nas previsões da MultiResUNet.	39
4.17	Imagens dos pulmões não COVID de número (469) e (693) que obtiveram valores satisfatórios nas previsões da MultiResUNet.	40
4.18	Imagens dos pulmões não COVID de número (238), (421) e (391) que obtiveram falhas de similaridades nas previsões da MultiResUNet.	41

4.19	Imagens dos pulmões não COVID de número (453) e (572) com posicionamentos diferentes que obtiveram falhas de similaridades nas previsões da MultiResUNet.	42
4.20	Gráfico da classe saudável com os resultados das medidas de desempenho de cada imagem de teste da MultiResUNet.	43
4.21	Gráfico da classe com COVID-19 com os resultados das medidas de desempenho de cada imagem de teste da MultiResUNet.	43
4.22	Gráfico da classe não COVID com os resultados das medidas de desempenho de cada imagem de teste da MultiResUNet.	44
4.23	Imagens dos pulmões não COVID de número (146), (261) e (421) com infecções nas regiões dos pulmões, bem como a imagem (73) com baixo contraste, que resultaram em baixas medidas de desempenho.	46
4.24	Imagens dos pulmões não COVID de número (146), (261) e (421) com infecções nas regiões dos pulmões e suas equalizações, bem como a imagem (73) com baixo contraste e sua equalização.	46
4.25	Imagens dos pulmões do COVID-19 de números (132) e (311) com parte dos pulmões ocultados e radiografias do não COVID de números (131) e (487) com alta infecção nas regiões dos pulmões.	47
4.26	Imagens dos pulmões saudáveis e COVID-19 de número (81) e (425) que obtiveram valores satisfatórios nas previsões por modelos treinado com equalização.	49
4.27	Imagens dos pulmões saudáveis e COVID-19 de números (601) e (375) que obtiveram falhas nas previsões por modelos treinado com equalização.	50
4.28	Imagens dos pulmões de COVID-19 de número (132) com posicionamento diferente que obtiveram falhas nas previsões por modelos treinado com equalização.	50
4.29	Imagens dos pulmões não COVID de número (492), (54) e (693) que obtiveram valores satisfatórios nas previsões por modelos treinados com equalização.	51
4.30	Imagens dos pulmões não COVID de número (132) e (146) que obtiveram falhas nas previsões por modelos treinado com equalização.	52

4.31	Imagens dos pulmões não COVID de número (391) e (298) com posicionamentos diferentes que obtiveram falhas nas previsões por modelos treinado com equalização.	52
4.32	Comparativo dos resultados satisfatórios dos treinamentos sem e com equalização das redes neurais UNet e MultiResUNet das classes COVID-19 e Não COVID.	55
4.33	Comparativo dos resultados com falhas dos treinamentos sem e com equalização das redes neurais UNet e MultiResUNet das classes Normal e COVID-19.	55
4.34	Comparativo dos resultados com falhas e diferentes posições dos treinamentos sem e com equalização das redes neurais UNet e MultiResUNet das classes Não COVID e COVID-19.	55

Lista de Tabelas

1.1	Medidas de desempenho das pesquisas do estado da arte.	5
3.1	Divisão das imagens para treinamento, validação e teste.	22
3.2	Configurações dos treinamentos.	22
3.3	Separação da quantidade de imagens para geração dos resultados de teste. . . .	23
4.1	Média dos resultados das medidas de desempenho da UNet para imagens saudáveis.	26
4.2	Média dos valores das medidas de desempenho da UNet para imagens com COVID-19.	27
4.3	Média dos valores das medidas de desempenho da UNet para imagens não COVID.	30
4.4	Duração em segundos das segmentações da UNet nas imagens de teste por classe.	33
4.5	Comparativo das médias das medidas de desempenho das segmentações da UNet nas imagens de teste por classe.	33
4.6	Média dos resultados das medidas de desempenho da MultiResUNet para imagens saudáveis.	36
4.7	Média dos valores das medidas de desempenho da MultiResUNet para imagens com COVID-19.	38
4.8	Média dos valores das medidas de desempenho da MultiResUNet para imagens não COVID.	40
4.9	Duração em segundos das segmentações da MultiResUNet nas imagens de teste por classe.	42
4.10	Comparativo das médias das medidas de desempenho das segmentações da MultiResUNet nas imagens de teste por classe.	42

4.11	Duração dos treinamentos entre as redes neurais convolucionais.	44
4.12	Duração em segundos das previsões das redes neurais convolucionais nas imagens de testes por classe.	45
4.13	Média dos resultados das medidas de desempenho por rede neural convolucional.	45
4.14	Duração dos treinamentos entre as redes neurais convolucionais treinadas com equalização.	48
4.15	Duração em segundos das previsões das redes neurais convolucionais treinadas com equalização nas imagens de testes por classe.	48
4.16	Média dos resultados das medidas de desempenho por rede neural convolucional treinadas com equalização.	48
4.17	Duração dos treinamentos entre as redes neurais convolucionais para os cenários com e sem equalização.	53
4.18	Duração em segundos das previsões entre as redes neurais convolucionais nas imagens de testes por classe para os cenários com e sem equalização.	54
4.19	Média dos resultados das medidas de desempenho por redes neurais convolucionais nas imagens de testes por classe para os cenários com e sem equalização.	54

Sumário

1	Introdução	1
1.1	Motivação	2
1.2	Estado da Arte	3
1.3	Objetivos	5
1.3.1	Objetivo Geral	5
1.3.2	Objetivos Específicos	5
1.4	Organização do Trabalho	6
2	Fundamentação Teórica	7
2.1	Radiografia	7
2.2	Inteligência Artificial	8
2.2.1	Aprendizado de Máquina	9
2.2.2	Aprendizado Profundo	11
2.2.3	Redes Neurais Artificiais	12
2.3	Redes Neurais Convolucionais	14
2.3.1	U-Net	15
2.3.2	MultiResUNet	17
3	Metodologia	20
3.1	Base de Dados	20
3.2	Treinamento para Segmentação Pulmonar	20
3.3	Métricas de Avaliação	24
3.3.1	Coefficiente de similaridade de dados	24
3.3.2	Índice de <i>Jaccard</i>	24

4	Resultados das Segmentações	26
4.1	Segmentação com UNet	26
4.1.1	Identificação das máscaras nas imagens saudáveis	26
4.1.2	Identificação das máscaras nas imagens com COVID-19	27
4.1.3	Identificação das máscaras nas imagens não COVID	30
4.1.4	Comparativo entre os resultados das classes	32
4.2	Segmentação com MultiResUNet	36
4.2.1	Identificação das máscaras nas imagens saudáveis	36
4.2.2	Identificação das máscaras nas imagens com COVID-19	37
4.2.3	Identificação das máscaras nas imagens não COVID	40
4.2.4	Comparativo entre os resultados das classes	41
4.3	Comparativo entre as Redes Neurais Convolucionais	44
4.4	Segmentações das Redes Neurais com Equalização	47
4.4.1	Análise das imagens saudáveis e COVID-19	49
4.4.2	Análise das imagens não COVID	51
4.5	Comparativo dos Modelos Treinados com Equalização	53
5	Conclusão	56
6	Artigos Publicados	58
	Referências Bibliográficas	62

A doença do coronavírus 2019 (COVID-19) provocada pela Síndrome Respiratória Aguda Grave Coronavírus 2 (SARS-CoV-2) é uma enfermidade bastante contagiosa que foi rapidamente disseminada ao redor do mundo, de modo que a Organização Mundial da Saúde (OMS), em março de 2020, a declarou como pandemia (Degerli *et al.*, 2021). Essa doença ocasionou muitas mortes em todo o mundo, chegando a mais de 6,2 milhões de óbitos, em 7 de julho de 2022 (OMS, 2022).

O diagnóstico da COVID-19 não é simples, devido aos seus sintomas serem difíceis de diferenciar de outras infecções virais. Comumente para a sua detecção são utilizados: o exame de sangue RT-PCR (*Reverse Transcription of Polymerase Chain Reaction*) e métodos utilizando imagens de tórax, como as radiografias e tomografia computadorizada (TC) (Degerli *et al.*, 2021). As quatro técnicas de testes identificadas e normalmente incentivadas são o swab nasofaríngeo, saliva, escarro e sangue (Rajah & Lee, 2021).

A imagem de radiografia consiste em um exame dos pulmões que tem um custo acessível e não invasivo (Kundu *et al.*, 2021). A maior parte dos laboratórios e hospitais proporcionam dispositivos de TC e sistemas de imagens de radiografia, sendo isso uma vantagem na utilização desses exames (Rahimzadeh & Attar, 2020).

Os laudos mais frequentes em radiografias do tórax e TC de pessoas com COVID-19 contém opacidades em vidro fosco e consolidação pulmonar. Contrariamente a pneumonia bacteriana, essa possui uma tendência em ser unilateral e envolve apenas um lobo, as opacidades pulmonares na COVID-19 e diversas pneumonias virais comumente geram em uma quantidade maior de lobos (Jacobi *et al.*, 2020).

Realizar a segmentação nos órgãos de risco é um processo demorado e cansativo para os médicos. Automatizar esse processo diminui o tempo de horas para minutos para realizar a segmentação. Assim, os médicos podem investir maior tempo aperfeiçoando de forma manual a acurácia segundo as segmentações automáticas (Zhu *et al.*, 2019).

O aprendizado de máquina (*Machine Learning - ML*) ou aprendizado profundo (*Deep Learning - DL*) é uma subárea da inteligência artificial (IA) que busca assemelhar capacidades de aprendizado em máquinas. Atualmente, com o progresso acelerado da inteligência artificial, o DL tem sido bastante usado para o processamento de imagens médicas, por causa da sua eficiência na representação das características (Yan *et al.*, 2020).

Vários pesquisadores tem se esforçado ativamente para implementar sistemas que automatizem os diagnósticos. A segmentação e o diagnóstico são as duas atividades de uma ferramenta de exame de imagens médicas que possui suporte de um computador (Ibtehaz & Rahman, 2020).

Em um problema de segmentação, o intuito é conseguir segmentar uma imagem em uma coleção de regiões sem se sobrepor, permitindo o agrupamento dos *pixels* semelhantes. Contudo, se tratando de imagens médicas, a preferência é na maioria das vezes diferenciar algumas regiões de interesse na imagem, tal como as áreas tumorais, órgãos, entre outras. Isto habilita aos médicos a analisarem somente os fragmentos importantes das imagens médicas. Além do mais, as imagens segmentadas muitas das vezes são utilizadas para computar várias características que conseguem ser utilizadas no diagnóstico de patologias (Ibtehaz & Rahman, 2020).

1.1 – Motivação

A presente pesquisa realiza um estudo das segmentações entre as redes neurais convolucionais UNet e MultiResUNet, para segmentar as regiões dos pulmões em radiografias de tórax saudáveis, com COVID-19, com pneumonia viral ou bacteriana. O intuito é analisar a identificação dos pulmões, considerando estarem acometidos por alguma patologia especificada.

A pesquisa realizada por Costa *et al.* (2021), identificou na segmentação dos pulmões em imagens de radiografias que o modelo segmentou uma parte da imagem no exterior da região pulmonar. Desse modo, realizar a segmentação dos pulmões antes dos algoritmos de identificação da COVID-19, pode contribuir para a diminuição dos erros na detecção da patologia.

1.2 – Estado da Arte

Na pesquisa realizada por Costa *et al.* (2021), diante das dificuldades devido a COVID-19, foi usada a MultiResUNet como proposta para segmentação da região do pulmão, bem como a classificação binária utilizando três diferentes modelos em imagens de radiografia de tórax, tendo em vista os pacientes com indícios das patologias por COVID-19 no momento da triagem. Os resultados obtidos na segmentação utilizando a MultiResUNet foram de 93,34% de Índice de Jaccard e 96,53% de Coeficiente Dice. Entre os modelos de classificação, os de aprendizado profundo, redes neurais convolucionais (*Convolutional Neural Network - CNN*) e a COVNet, atingiram desempenhos mais relevantes em relação aos resultados da SVM, entretanto, a CNN foi levemente acima da COVNet.

O trabalho de Rahman *et al.* (2021) busca propor um modelo novo para a U-Net e compara-lo com o modelo padrão da U-Net em segmentar os pulmões. Os autores utilizaram uma extensa base de dados reunida pelos mesmos, o qual se referem como COVQU, contendo uma quantidade de 18.479 de imagens de radiografia de tórax (*Chest X-ray - CXR*) em 15.000 ocorrências de pacientes. Foram analisados em imagens de radiografia de pulmão simples e segmentado por seis CNNs distintas pré-treinadas, como a ResNet18, ResNet50, ResNet101, InceptionV3, DenseNet201 e ChexNet, bem como uma CNN superficial (*shallow CNN*). O modelo proposto, na segmentação pulmonar, atingiu uma precisão de 98,63%, interserção sobre união (*Intersection-Over-Union - IoU*) de 94,3% e coeficiente *Dice* de 96,94%. A classificação em imagens de radiografia simples foi moderadamente mais elevada que as radiografias segmentadas em performance, contudo a confiança da performance da rede é consideravelmente otimizada com as imagens dos pulmões segmentadas, o qual foi examinado com o método de visualização. Nas imagens que foram segmentadas dos pulmões obtiveram os seguintes resultados nas métricas, uma acurácia de 95,11%, sensibilidade de 94,56%, especificidade de 95,59%, precisão de 94,55% e F1-score de 94,53%.

Nos estudos realizado por Tahir *et al.* (2021), foi proposto um método unificado e sistemático em imagens de radiografia para segmentar as áreas dos pulmões, bem como encontrar a COVID-19 e quantificar a infecção. Construíram a base de imagem de referência contendo 33.920 imagens de raio-x, sendo 11.956 de COVID-19. As máscaras de segmentação da região do pulmão é efetuada em imagens de CXRs por um procedimento colaborativo sofisticado homem-máquina. Uma grande coleção de experimentos foi executado utilizando

redes de segmentação avançada, sendo elas a U-Net, U-Net++ e *Feature Pyramid Networks (FPN)*. Depois de um técnica iterativa a rede atingiu um desempenho elevado para segmentar a localização dos pulmões conseguindo IoU de 96,11% e um coeficiente de similaridade de dados (*Dice Similarity Coefficient - DSC*) de 97,99%. Além de que as regiões das infecções da COVID-19 foram identificadas de modo confiável com o IoU de 83,05% e DSC de 88,21%. E por fim, o método apresentado obteve o resultado em seu desempenho na detecção da COVID-19 com valores acima de 99% para sensibilidade e especificidade.

O trabalho de Degerli *et al.* (2021) apresenta uma nova abordagem para localização conjunta, classificação da intensidade e identificação da COVID-19 nas imagens de radiografia, reproduzindo os mapas de infecção. Para esse fim, foi compilado a coleção de imagens de CXR com 119.316 imagens, onde 2.951 são de COVID-19. As máscaras de segmentação são geradas das imagens de radiografia por um processo colaborativo homem-máquina. Para a segmentação foram utilizados três modelos de segmentações distintos, sendo eles U-Net, U-Net++ e DLA, com quatro estruturas de codificador divergentes, tais como CheXNet, DenseNet-121, Inception-V3 e ResNet-50. Os experimentos detalhados realizados demonstram que as redes de segmentação avançada conseguem aprender a identificar a infecção da COVID-19, resultando em uma pontuação F1 (Com a precisão e sensibilidade a pontuação F1 é a média harmônica entre elas) com 83,20%. Além disso o método mostrado atingiu um desempenho na identificação da COVID-19 com uma sensibilidade de 94,96% e especificidade de 99,88%.

Na pesquisa realizada por Yang *et al.* (2020), foi utilizado a MultiResUNet aprimorada, indicando um modelo apropriado para uma coleção de imagens de TC de COVID-19, com o objetivo de fragmentar de forma automática as imagens em quatro elementos, sendo eles, pulmão esquerdo, direito, doença e plano de fundo usando o aprendizado profundo. Efetuaram a avaliação dos resultados utilizando o coeficiente de similaridade *Dice* no conjunto de testes, em que obteve 90,85% para o pulmão direito, 88,81% para o pulmão esquerdo, 74,28% para a doença e 99,37% para o plano de fundo.

Com o objetivo de melhorar a visualização dos resultados das pesquisas descritas nesta seção, a Tabela 1.1 apresenta as medidas de desempenho do índice de Jaccard e coeficiente Dice dos trabalhos relacionado a segmentação da região dos pulmões.

O estudo realizado por Costa *et al.* (2021) identificou nas segmentações dos pulmões em imagens de radiografias, que o modelo fragmentou uma parte da imagem no exterior das regiões pulmonares. Realizar a segmentação dos pulmões antes dos algoritmos de identificação

Tabela 1.1 – Medidas de desempenho das pesquisas do estado da arte.

Pesquisa	Índice de Jaccard	Coefficiente Dice
Costa et al. (2021)	93,34%	96,53%
Rahman et al. (2021)	94,30%	96,94%
Tahir et al. (2021)	96,11%	97,99%

da COVID-19, pode contribuir para a diminuição dos erros de detecção desta enfermidade. Dessa maneira, o comparativo pode auxiliar na escolha da CNN utilizada para segmentar as regiões dos pulmões.

A comparação contempla a análise das CNNs por classe para entender as características em individual, bem como treinadas sem e com equalização como pré-processamento. O objetivo da equalização é melhorias nos resultados em radiografias infectadas com patologias moderadas e imagens com alto ou baixo níveis de contrastes.

1.3 – Objetivos

1.3.1 – Objetivo Geral

Esta pesquisa tem como objetivo realizar segmentações com as redes neurais convolucionais UNet e MultiResUNet, analisando essas redes para extrair a região dos pulmões (área de interesse) de imagens de radiografia de tórax, tendo em vista os cenários em que os pulmões se encontram nos estados saudáveis, COVID-19 e não COVID (pneumonia viral e bacteriana), bem como utilizar medidas para verificação de seus desempenhos.

1.3.2 – Objetivos Específicos

- ▣ Realizar pesquisa bibliográfica sobre redes neurais convolucionais;
- ▣ Pesquisar base de imagens de radiografia do tórax para o treinamento das redes neurais convolucionais;
- ▣ Treinar as redes neurais convolucionais para identificar a região do pulmão na radiografia do tórax com e sem patologia;
- ▣ Analisar os resultados das redes neurais convolucionais com base nas métricas de desempenho;
- ▣ Avaliar necessidade de processamento para melhorar os resultados.

1.4 – Organização do Trabalho

Esta pesquisa está separada em seis capítulos. O Capítulo 2 conceitua sobre as imagens de radiografia e as enfermidades observadas neste trabalho, bem como os fundamentos acerca das redes neurais convolucionais. O Capítulo 3 aborda a metodologia empregada para o processo de treinamento das CNNs, assim como descreve a base de dados utilizada e a definição das métricas de avaliação. O Capítulo 4 apresenta os resultados por classes das segmentações efetuadas pelas redes treinadas, e também um comparativo entre elas. O Capítulo 5 são as conclusões dos resultados obtidos e recomendações de trabalhos futuros. E por fim, o Capítulo 6 menciona os artigos publicados relacionados ao tema de redes neurais convolucionais.

2.1 – Radiografia

A radiografia de tórax (*Chest X-ray - CXR*) é um instrumento simples, de menor custo e pode ser utilizado para diagnosticar infecções pulmonares. As radiografias podem ser compreendidas, por um radiologista especialista, como normal ou apresentando uma patologia, por exemplo, câncer de pulmão, tuberculose ou pneumonia (Khan *et al.*, 2021).

As radiografias são normalmente mais requisitadas do que as outras opções, como a ressonância magnética e tomografia computadorizada, por conta do seu custo baixo. Contudo, nos países desenvolvidos e em desenvolvimento existe uma carência de radiologistas (Khan *et al.*, 2021).

Uma das patologias identificadas na radiografia é a pneumonia, que pode ser provocada por patógenos, tal como bactérias, vírus e fungos. Ela é uma inflamação que é possível acometer qualquer indivíduo, sendo um risco para os bebês, cidadãos portadores de outras doenças, idosos, indivíduos com sistema imunológico prejudicado, pessoas que possuem doenças crônicas por exemplo a asma, pacientes em hospitais e indivíduos fumantes de cigarro (Chouhan *et al.*, 2020).

A pneumonia viral é mais moderada e os sinais acontecem gradativamente, contudo pode ter complicação no diagnóstico caso o paciente tenha também uma pneumonia bacteriana. No entanto, a pneumonia bacteriana é mais preocupante e seus sintomas podem apresentar gradualmente ou de repente, especialmente em crianças. Esta categoria de pneumonia prejudica a maior parte dos pulmões, bem como é possível chegar a atingir vários lobos, onde um indivíduo necessita ser hospitalizado caso muitos lobos sejam atingidos.

A outra pneumonia é a fúngica que pode acometer cidadãos com o sistema imunológico debilitado. Ela também tem a possibilidade de ser de alto risco e o paciente precisa de tempo para se recuperar (Chouhan *et al.*, 2020).

Em 31 de dezembro de 2019 manifestou-se um surto de origem desconhecida com ocorrências preocupantes de pneumonia, que difundiu-se depressa em vários países. Essa manifestação foi declarada como uma pandemia pela Organização Mundial da Saúde (OMS) em janeiro de 2020. Um vírus foi chamado de Síndrome Respiratória Aguda Grave Coronavírus 2 (SARS-CoV-2) quando foi descoberto e separado das células epiteliais do sistema de respiração de pessoas contaminadas. O surto foi nomeado como coronavírus (COVID-19) (Rousan *et al.*, 2020).

Os coronavírus são da família *coronaviridae* e sua particularidade morfológica, em um microscópio, revela peplômeros de picos virais emergindo do envelope viral parecendo com uma coroa. Eles encontram-se em meio aos humanos e mamíferos bastante disseminados. Geralmente os sintomas mais conhecidos do COVID-19 apresentam tosse, febre, dispneia, mialgia e fadiga, outros sinais não muito comuns são a dor de cabeça, escarro, hemoptise e sintomas gastrointestinais (Rousan *et al.*, 2020).

Os indivíduos acometidos pelo coronavírus mostraram descobertas peculiares nas imagens radiológicas de tórax, como consolidações com predomínio periférica e basal, e embaçamentos em vidro opaco multifocais e bilaterais, e outros menos comuns foram o bronquiectasias, espessamento septal, linfadenopatia, derrame pleural e cavitação (Rousan *et al.*, 2020).

2.2 – Inteligência Artificial

O cérebro humano consegue encarar informações probabilísticas ou inconsistentes em cenários divergentes, bem como ser flexível em adaptações de circunstâncias mal definidas. Essas características tem ocupado a atenção de vários pesquisadores que impulsionaram seus trabalhos na área de inteligência artificial (IA) (Chiarello *et al.*, 2019).

A inteligência artificial é a habilidade de adequação de uma máquina em situações novas, solucionar problemas, conseguir contestar perguntas, entre outras funções que exige um certo grau de inteligência naturalmente dos seres humanos (Chen *et al.*, 2020).

A inteligência do ser humano é uma união de várias habilidades (como raciocinar, resolver problemas, utilizar a linguagem, entre outros), de modo semelhante a IA é constituída de técnicas e métodos de diversas disciplinas da engenharia e ciência para conseguir assemelhá-las em máquinas. Interessante comentar que a inteligência artificial é comumente confundida com o aprendizado de máquina. A Figura 2.1 ilustra as habilidades da IA (Sessa *et al.*, 2020).

Figura 2.1 – Habilidades da Inteligência Artificial.



Fonte: (Sessa *et al.*, 2020) (com adaptações).

Normalmente para os trabalhos de ciência biomédica, o projeto experimental, estudo dos dados estatísticos e a ciência da computação continuamente são elementos integrados. Contudo, nos últimos anos o crescimento acelerado das técnicas para descobrir o conhecimento, tendo como base o aprendizado de máquina na IA, estabeleceu de modo claro essa tendência, assim para diferentes áreas médicas a colaboração desses métodos foram bastante detalhado (Sessa *et al.*, 2020).

2.2.1 – Aprendizado de Máquina

O aprendizado de máquina (*Machine Learning - ML*) é uma área multidisciplinar que utiliza de técnicas e métodos estatísticos, matemáticos e ciência da computação para absorver aprendizado a partir das experiências no que se refere a algumas atividades para conseguir mensurar o desempenho e aperfeiçoá-lo (reforço) (Sessa *et al.*, 2020).

Atualmente, os algoritmos de ML que possuem como base o aprendizado por reforço melhoram as capacidades de aprendizado da máquina, bem como acrescentam outros fatores

da inteligência como o raciocínio adequado, percepção dos fatos e resolver eficientemente os problemas (Sessa *et al.*, 2020).

O aprendizado de máquina é comumente definido como sistemas que têm a aptidão de, sem ser nitidamente programados, conseguir responder com decisões inteligentes. Os procedimentos de ML tem naturalmente os dados como base. Além do mais, os métodos de aprendizado de máquina possuem três categorizações em geral: supervisionadas, não supervisionadas e aprendizado por reforço (*Reinforcement Learning - RL*). A Figura 2.2 representa os tipos de categorias (Olowononi *et al.*, 2021).

Figura 2.2 – Categorias do aprendizado de máquina.



Fonte: (Olowononi *et al.*, 2021) (com adaptações).

No aprendizado supervisionado a coleção de treinamento inclui os exemplos de dados e as soluções esperadas. O intuito do algoritmo é mapear a entrada para a saída conforme uma função implementada. Depois do aprendizado, um modelo pode a partir de uma entrada determinar a saída (Olowononi *et al.*, 2021).

Em comparação com a técnica de aprendizado supervisionado, o aprendizado não supervisionado é obtido usando para o treinamento os dados não rotulados. O algoritmo tem como objetivo nos dados não rotulados compreender ou buscar percepções ocultas. Esta categoria efetua tarefas como dimensionalidade, clusterização, estimação de densidade e identificação de irregularidade (Olowononi *et al.*, 2021).

No aprendizado por reforço, o algoritmo que também é chamado de agente, por intermédio da sua comunicação com o ambiente consegue aprender a decidir, este procedimento é realizado por meio de tentativa e erro recebendo recompensas e punições de acordo com o desempenho. O algoritmo tem como finalidade potencializar a recompensa de qualquer forma.

O agente é o algoritmo em si e o ambiente retrata a circunstância ou objeto superficial no qual o agente está atuando (Olowononi *et al.*, 2021).

Uma propriedade exclusiva do RL que o diferencia das demais categorias de algoritmo de aprendizado é o equilíbrio entre exploração e aproveitamento, visto que o propósito do agente é elevar ao máximo a recompensa com a interação no ambiente examinando o conhecimento existente baseado nas interações antecedentes e nas recompensas adquiridas. Entretanto, para escolher as futuras melhores ações, o agente necessita investigar outras ações buscando potencializar as recompensas (Olowononi *et al.*, 2021).

O principal intuito do aprendizado supervisionado é encontrar um ótimo mapeamento das entradas para as saídas almejadas, assim é necessário um humano supervisionando para relacionar as amostras com o rótulo correspondente antes de efetuar o treinamento. Enquanto que o não supervisionado solicita somente as amostras de entrada sem precisar rotulá-las, e seu objetivo é examinar a forma dos dados distribuídos buscando adquirir importantes informações acerca da sua organização oculta. Os sistemas de aprendizado de máquina realizam atividades que podem ser brevemente explicadas como (Avci *et al.*, 2021):

- ▄ **Classificação** que busca definir o tipo a qual uma entrada pertença;
- ▄ **Regressão** que tem o intuito de formar o relacionamento dentre uma sequência de entrada com um número de saída. A divergência existente entre a regressão e a classificação é a configuração da saída;
- ▄ **Previsão** que é uma especial categoria de regressão em que o propósito é, a partir de uma sequência temporal determinada, antecipar futuros valores;
- ▄ **Clustering** que tem a finalidade de separar a coleção de dados de entrada em *clusters* de amostras similares. Em contrapartida com as atividades de classificação, regressão e previsão que utilizam de técnicas supervisionadas, a clusterização como mapa auto-organizado segue como método não supervisionado.

2.2.2 – Aprendizado Profundo

O aprendizado profundo (*Deep Learning - DL*), também chamado de aprendizado de representação, é uma subárea do ML incluso na área de IA. Os algoritmos de DL conseguem aprender a relacionar as características com as saídas almejadas, bem como efetuar o próprio procedimento para extrair recursos (Avci *et al.*, 2021).

Pesquisas recentes demonstraram que tais redes obtém uma melhor performance em atividades difíceis, como por exemplo detectar objetos, classificar imagens e classificar pulsações de eletrocardiograma (Avci *et al.*, 2021).

As técnicas de aprendizado profundo em relação aos algoritmos superficiais tradicionais divergem devido a variedade de camadas ocultas, abstrações de características de alto nível, generalizações melhores em novas amostras e apresentaram melhorias na performance dos sistemas que foram inseridas (Olowononi *et al.*, 2021).

Um tipo de aprendizado de características é o aprendizado profundo que, a partir de imagens de entrada, consegue extrair e aprender características. Diversos pesquisadores com intuito de extrair características importantes, criaram redes profundas de profundidades significativas. Importante salientar que uma rede de maior profundidade possui mais parâmetros de aprendizado, provocando uma menor rapidez no aprendizado, bem como um risco maior de sobreajuste (*overfitting*) (Kim & Lee, 2021).

Diversas técnicas de aprendizado profundo são aplicadas em imagens médicas para segmentar, classificar, detectar e registrar doenças. Isso é devido ao entusiasmo pelo enorme sucesso das abordagens de aprendizado profundo para resolver adversidades da visão computacional (Dutta, 2021).

Uma área significativa é a segmentação de imagens médicas para diagnosticar, monitorar e tratar doenças. Segmentar as imagens médicas manualmente por especialistas em modalidades variadas de imagens para o diagnóstico e tratamento de doenças ainda é considerado um padrão ouro, no entanto realizar a segmentação de forma manual é entediante, demorado e suscetível a falhas humanas. Contudo, na segmentação de imagens médicas tem algumas dificuldades, como a carência de informações fundamentais e a desproporção de classes (Dutta, 2021).

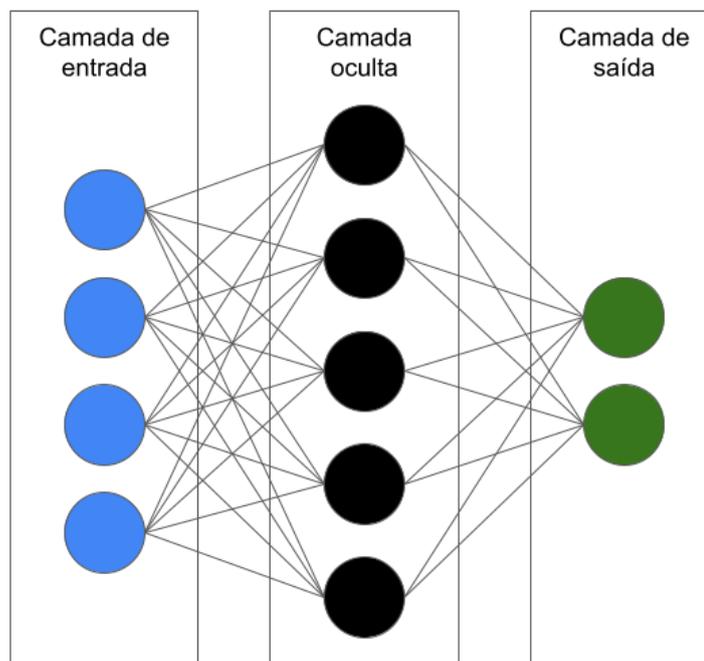
O problema da escassez de informações anotadas para efetuar o treinamento, pode ser contornado com o aumento e transformação de dados com o intuito de acrescentar as amostras rotuladas. Além do mais, as dificuldades da desproporção de classes podem ser solucionadas com técnicas fundamentadas em *patch* (Dutta, 2021).

2.2.3 – Redes Neurais Artificiais

As redes neurais artificiais (RNA) são métodos para processar dados que foi arquitetado baseado nos neurônios biológicos. Eles são instrumentos interessantes para antecipar, nos procedimentos químicos, a influência dos parâmetros funcional, por causa da sua aptidão de

diferenciar a similaridade das entradas e saídas. A RNA é constituída por camadas de entrada, oculta e saída, que tem que ser administrada de forma apropriada (Kakhki *et al.*, 2020). A Figura 2.3 ilustra a estrutura genérica de uma RNA.

Figura 2.3 – Estrutura genérica da rede neural artificial



Fonte: Elaborada pelo autor.

De modo geral, a estrutura da RNA consiste na camada de entrada, oculta e de saída. As entradas que estão normalizadas são interligadas com a camada oculta. A ligação de cada entrada com cada neurônio da camada oculta é ponderado, bem como possui uma polarização contínua. A camada oculta é interligada com a de saída, onde mais uma vez cada associação da camada oculta com a de saída possui um valor ponderado, uma função de transferência e um constante valor de polarização. Ao passo que ocorre uma normalização nas entradas, também acontece uma normalização na saída, sendo necessário a desnormalização para adquirir os valores pressupostos, os quais conseguem ser conferidos com os valores alvo. Assim, com o intuito de avaliação da precisão do modelo, são computados os erros dos valores presumidos com o alvo (Ferreira *et al.*, 2022).

As RNAs são sistemas computacionais que se adaptam e foram motivadas pelo desempenho do cérebro humano. Elas são principalmente consideradas interessantes para solucionar questões não lineares e encontrar leves propensões e relações entre variáveis (Gagliano *et al.*, 2021).

As redes neurais artificiais aparentam ser um instrumento interessante para verificação dos dados utilizando uma pequena quantidade de amostras devido a sua aprendizagem ter uma maneira adaptativa. Em outras palavras, retirar as informações importantes dos dados a disposição para alcançar um determinado objetivo e a partir do conhecimento aprendido, poder generalizar (Gagliano *et al.*, 2021).

2.3 – Redes Neurais Convolucionais

Atualmente, para efetuar as tarefas de classificação, segmentação e detecção de imagens, as redes neurais convolucionais (*Convolutional Neural Network - CNN*) tornou-se um procedimento de aprendizado de máquina de ponta. Apesar de ter sido incluído a cerca de duas décadas atrás, o aprendizado profundo vem se tornando mais conhecido por causa dos hardwares modernos, oferecendo maior poder computacional para treinar as CNN multicamadas (Dutta, 2021).

As CNNs comparadas com outros algoritmos que se baseiam no aprendizado de máquina, consideram as informações espaciais com o intuito de analisar os *pixels* vizinhos juntos, portanto unir este comportamento com a capacidade de generalizar das CNNs torna-a em diversas aplicações de visão computacional melhor que outras técnicas. A camada de convolução é o elemento fundamental das redes neurais convolucionais, assim são aplicados procedimentos de convolução nas entradas que posteriormente é passada adiante (Zhu *et al.*, 2019).

As camadas da CNN podem ser separadas em três conjuntos, sendo elas, as camadas convolucionais (*convolutional layers*), camadas de *pooling* e as camadas totalmente conectadas (*fully-connected layers*) (Hasan & Abdulazeez, 2020):

- ▄▄▄ As camadas convolucionais retira informações do mapa de características de entrada com um alto número de *kernels*, também chamados de filtros. Esta execução multiplica os pesos do filtro pelos valores da matriz da imagem correspondente, assim as características de baixo e alto nível são extraídos de acordo com que se aprofunda pela CNN;
- ▄▄▄ As camadas de *pooling* possuem vários filtros que adquire os mapas de características provenientes da camada de convolução, que posteriormente realiza a diminuição desses mapas conforme a função (*max*, *min* e *average*).

- ▣ O objetivo da camada totalmente conectada é unir as características extraídas da camada de *pooling* com os neurônios da camada totalmente conectada. Esta camada é projetada em conformidade com o que deseja executar, desse modo pode-se determinar a função de ativação como logística (*logistic*), *softmax* ou linear, para efetuar tarefas de classificação ou regressão.

As CNNs possuem uma grande aptidão para automatizar as segmentações em virtude de seu potencial de reconhecer recursos abstratos e de baixo nível. Contudo, dados acessíveis para o treinamento com rótulos que representam todos os fenótipos de doenças é um desafio existente para implantar as técnicas de aprendizado profundo em imagens médicas. Apesar dos rótulos inespecíficos não consigam ser úteis de modo direto para o treinamento de predição de rótulos específicos, a coleção de dados inespecífico pode incluir informações de fenótipos de doenças relevantes inexistentes na coleção de dados com rótulos específicos (Gerard *et al.*, 2021).

Desde o princípio das redes neurais, as pesquisas estão sendo focadas totalmente em projetos de otimização de arquitetura de redes. Atualmente, as redes de aprendizagem profunda avançada exigem um grande poder de processamento devido possuir centenas de camadas e milhões de parâmetros (Dutta, 2021).

2.3.1 – U-Net

A rede U-Net é uma rede neural profunda comumente utilizada para realizar segmentação de imagens médicas de modalidades diversificadas, como radiografia, imagem por ressonância magnética (*Magnetic Resonance Imaging - MRI*) e TC (Kim & Lee, 2021). A arquitetura U-Net é a rede mais conhecida e utilizada para segmentar imagens biomédicas, ela possui uma convolução simétrica nas unidades de codificação e decodificação, e em ambas as unidades as operações de convoluções tem como subsequente uma camada de ativação ReLU (Dutta, 2021).

A CNN U-Net apresentada por Ronneberger *et al.* (2015) é composta por uma arquitetura com dois caminhos simétricos: Codificador e Decodificador, que em algumas ocasiões também são conhecidas como *down-sampling* e *up-sampling*, respectivamente. O codificador é uma coleção de camadas de convolução e agrupamento máximo (*max-pooling*) com intuito de, nos mapas de características, realizar a amostragem, e o decodificador é um

conjunto de camadas de convolução transposta para reconstruir os mapas de características (Hasan & Abdulazeez, 2020).

A U-Net faz uso por completo de uma rede de camadas convolucionais com o intuito de efetuar a segmentação semântica. A rede é simétrica em sua estrutura contendo um codificador que retira as características espaciais da imagem, e um decodificador que compõe o mapa de segmentação baseado nas características que foram codificadas (Ibtehaz & Rahman, 2020).

O codificador possui uma estrutura comum de uma rede convolucional, possuindo dois procedimentos de convolução 3×3 em sequência, e um processo de *pooling* máximo (*max-pooling*) com 2×2 de tamanho de *pooling* e passo (*stride*) de 2. Esses procedimentos se repetem por quatro vezes, e posteriormente a cada *down-sampling* acontece uma duplicação na quantidade de filtros nas camadas convolucionais. E por fim, o encadeamento de dois processos de convolução 3×3 relaciona o codificador com o decodificador (Ibtehaz & Rahman, 2020).

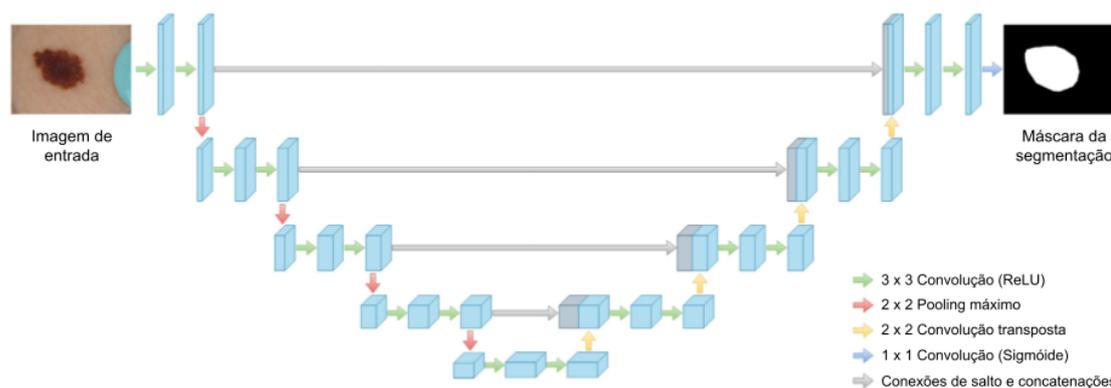
Em contrapartida, o decodificador primeiramente realiza o *up-samples* do mapa de características utilizando a convolução transposta 2×2 , e em sequência duas convoluções 3×3 são realizadas mais uma vez de forma encadeada. De modo semelhante ao codificador, esta série de *up-sampling* e dois processos de convolução se repetem por quatro vezes, efetuando a redução ao meio da quantidade dos filtros de cada etapa. E por último, é executado um procedimento de convolução 1×1 para a geração do mapa final de segmentação (Ibtehaz & Rahman, 2020).

Com exceção da camada convolucional final que utiliza a função de ativação *sigmoide*, as camadas convolucionais restantes desta estrutura faz uso da função de ativação ReLU (*Rectified Linear Unit*) (Ibtehaz & Rahman, 2020).

As conexões de salto (*Skip Connections*) possivelmente consista na inserção mais criativa da arquitetura da U-Net. A saída da camada convolucional, anteriormente ao procedimento de *pooling* no codificador, é enviado ao decodificador para os quatro níveis. Então, os mapas de características são unidos com a saída do procedimento de *up-sampling* e difundido para as camadas posteriores. As conexões de salto é importante para que as informações espaciais que sofreram perdas nos procedimentos de *pooling* sejam resgatadas. A Figura 2.4 apresenta a arquitetura da rede U-Net (Ibtehaz & Rahman, 2020).

A arquitetura básica da U-Net junta o percurso *down-sampling*, o codificador, com o objetivo de guardar as informações contextuais, seguidamente por um percurso simétrico de *up-sampling*, o decodificador, para conseguir localizar as características de forma precisa

Figura 2.4 – Arquitetura da U-Net.



Fonte: (Ibtehaz & Rahman, 2020) (com adaptações).

juntamente com as conexões de salto, com o intuito de combinar de modo direto os mapas de características da camada do codificador com as do decodificador (Dutta, 2021).

Em comparativo com outras redes, a U-Net possui algumas vantagens como disponibilizar informações de localização e contextual, possui um desempenho interessante com uma coleção de dados limitados, conserva o contexto inteiro das imagens de entrada se comparado com a segmentação fundamentado em *patch* e utiliza conexões de salto onde as características são removidas da camada de codificação de forma direta e associada a camada de decodificação (Dutta, 2021).

A CNN U-Net foi arquitetada inicialmente para segmentar imagens biomédicas. A arquitetura é constituída com intuito de guardar o contexto por um caminho de contração, bem como um caminho de expansão simétrico possibilitando um posicionamento preciso, desse modo o treinamento desta rede pode ser realizada por completo com poucas imagens (Zhu *et al.*, 2019).

Apesar das arquiteturas com várias camadas ou muito profundas consigam um desempenho superior, elas possuem uma dificuldade maior de treinamento devido ao gradiente que é o sinal utilizado para modificar os parâmetros da rede desvanecer entre as camadas. Caso ocorra nas camadas superficiais, os parâmetros não sofrem mudanças no decorrer do treinamento, logo o resultado da performance não será o ideal (Zhu *et al.*, 2019).

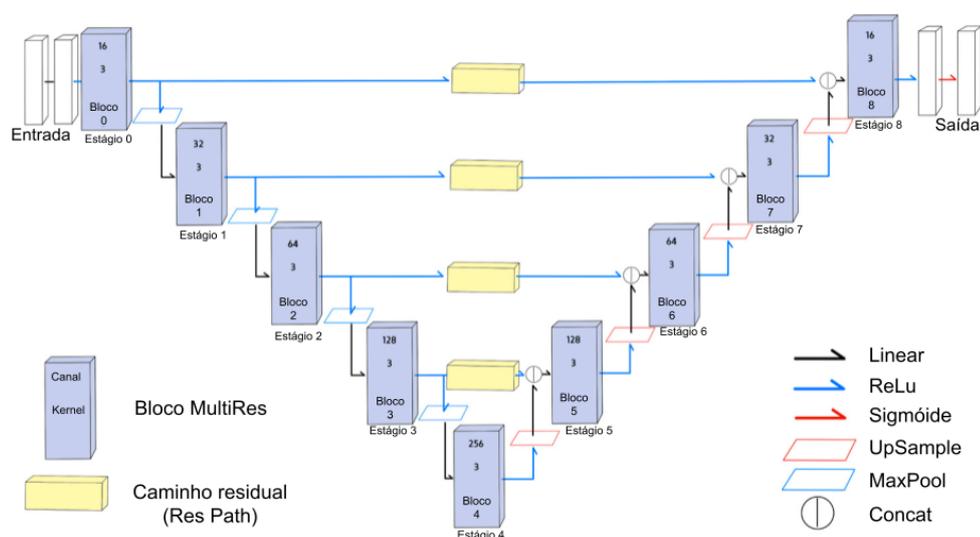
2.3.2 – MultiResUNet

A estrutura genérica da MultiResUNet é similar ao da U-Net, com exceção de poucas distinções nas características das convoluções em cada uma das camadas, bem como no caminho residual dos codificadores para os decodificadores. Foram substituídos cada camada

da U-Net pelos blocos *MultiRes* contendo 4 convoluções e as conexões de salto da U-Net pelos caminhos residuais. O incentivo na aceitação dessa rede segue o conceito de que uma estrutura ideal deve ter a capacidade de examinar imagens com diferentes escalas nos processos de segmentação de imagens médicas (Farheen *et al.*, 2021).

O bloco *MultiRes* substituiu cada estágio da U-Net, bem como o caminho residual foi inserido no lugar de cada conexão de salto. Essas características são ilustradas na Figura 2.5 (Lee & Jhang, 2021).

Figura 2.5 – Arquitetura da MultiResUNet.

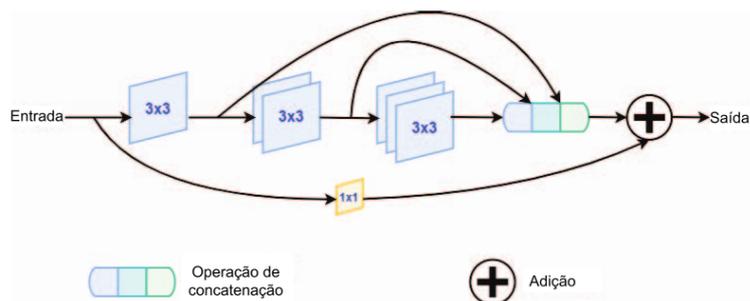


Fonte: (Lee & Jhang, 2021) (com adaptações).

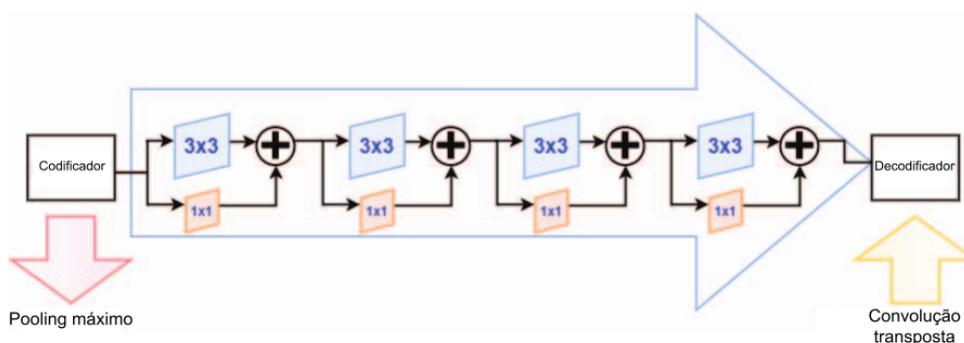
A MultiResUNet junta as saídas da camada convolucional que possui três sequências utilizando o formato da saída. Posteriormente, realiza o incremento de filtros nas três camadas consecutivas progressivamente, com o objetivo de prevenir que o quesito de memória das camadas precedentes disseminem de forma excessiva até as camadas mais profundas, este arranjo é nomeado de bloco *MultiRes* (Yang *et al.*, 2020). A Figura 2.6 demonstra a estrutura do bloco *MultiRes*.

A U-Net efetua a configuração de uma conexão de atalho no meio de amostras superiores e inferiores do nível equivalente. Contudo, entre a entrada e a saída existe uma lacuna semântica, assim a MultiResUNet insere o caminho residual para integrar algumas camadas inovadoras no decorrer das conexões de atalho, esta arquitetura é chamada de caminho residual (*Res Path*) (Yang *et al.*, 2020). A Figura 2.7 exhibe a estrutura do *Res Path*.

No modelo MultiResUNet, o bloco *MultiRes* substituiu a série de duas camadas convolucionais. Cada bloco *MultiRes* possui um parâmetro W com intuito de monitorar a

Figura 2.6 – Estrutura do bloco *MultiRes*.

Fonte: (Yang *et al.*, 2020) (com adaptações).

Figura 2.7 – Estrutura do *Res Path*.

Fonte: (Yang *et al.*, 2020) (com adaptações).

quantidade de filtros das camadas convolucionais do mesmo. Para a U-Net original e a MultiResUNet permanecer com uma ligação comparável dentre a quantidade de parâmetros, o valor do W foi calculado conforme a Equação 2.1 (Ibtehaz & Rahman, 2020).

$$W = \alpha \times U \quad (2.1)$$

O coeficiente escalar é denotado pelo α e o U é a quantidade de filtros da camada da U-Net. Isto possibilita uma forma interessante de inspecionar o número de parâmetros e preservá-los de um modo comparável aos da U-Net (Ibtehaz & Rahman, 2020).

As redes neurais convolucionais UNet e MultiResUNet serão aplicadas na segmentação das regiões pulmonares nas radiografias de tórax, e os procedimentos efetuados serão apresentados no capítulo seguinte.

3.1 – Base de Dados

Uma equipe de pesquisadores da Universidade do Qatar (*Qatar University - QU*) e da Universidade de Tampere (*Tampere University - TU*) criaram as coleções de dados COVID-QU e QaTa-Cov19. Gradativamente mais imagens de radiografia foram disponibilizadas, desse modo os autores ampliaram a coleção de imagens gerando o COVID-QU-Ex, que abrange mais de 33.000 imagens de radiografia de tórax em três distintas classes. A coleção de dados nomeada como COVID-QU-Ex, contém uma quantidade de imagens de radiografia de tórax de 11956 de COVID-19, 11263 não COVID (mas com alguma infecção) e 10701 normais (saudáveis) (Tahir *et al.*, 2021).

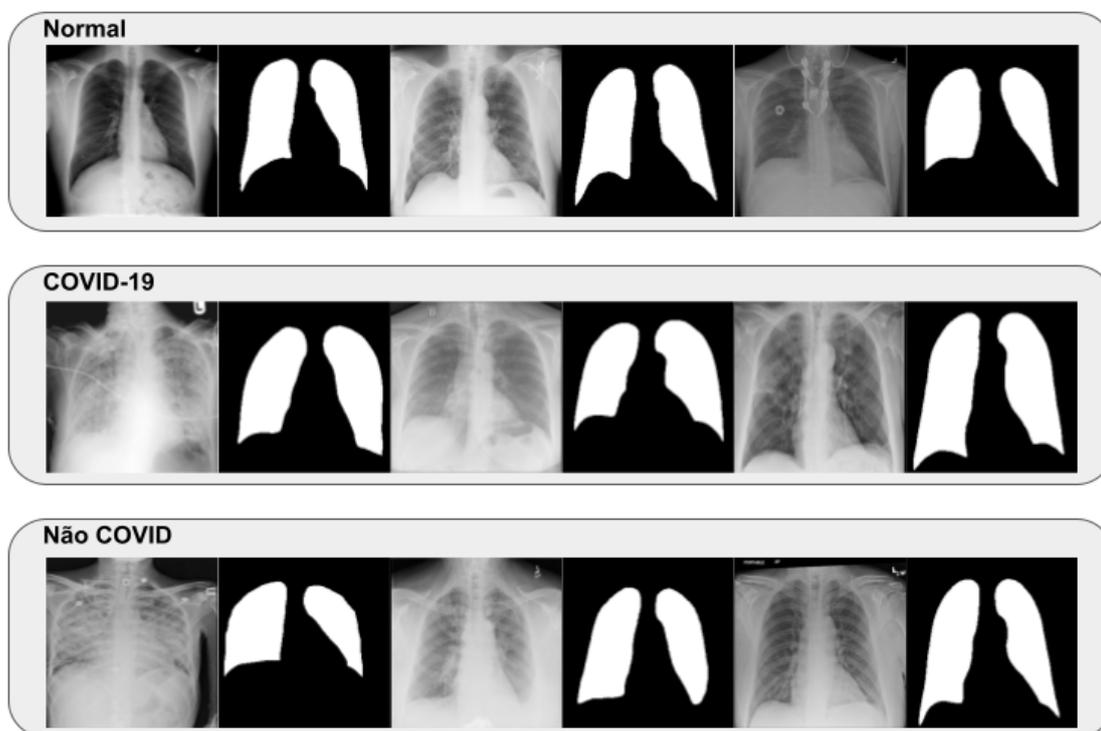
Os autores organizaram as máscaras de segmentação dos pulmões para toda a base de imagens, usando um refinado método cooperativo homem-máquina, o qual diminui consideravelmente para os humanos o trabalho de realizar as anotações nas imagens (Tahir *et al.*, 2021). A Figura 3.1 ilustra as radiografias dos pulmões e suas respectivas máscaras da base de imagens.

3.2 – Treinamento para Segmentação Pulmonar

A segmentação pulmonar consiste em remover apenas a localidade dos pulmões da imagem retirando informações externas a estes órgãos, como os ossos e órgãos que geralmente estão presentes em imagens médicas. Retirar esta região de interesse pode ser útil para treinamentos que busquem como entrada apenas as características dos pulmões.

O objetivo é realizar a segmentação dos pulmões das imagens de radiografia de tórax utilizando redes neurais convolucionais. Desse modo, a entrada é uma imagem de raio-x de tórax e a saída é uma máscara correspondendo a área do pulmão. A Figura 3.2 demonstra o

Figura 3.1 – Exemplos das radiografias e suas respectivas máscaras da base de imagem para os pulmões normal, acometido por COVID-19 e não COVID-19.



Fonte: COVID-QU-Ex (Tahir, 2022).

procedimento que será realizado para efetuar a segmentação do pulmão para todas as CNNs utilizadas.

Figura 3.2 – Metodologia para o treinamento das redes neurais convolucionais na segmentação pulmonar utilizando métricas para mensurar seu desempenho.



Fonte: Elaborada pelo autor.

Inicialmente é efetuado a etapa de entrada, onde as imagens de radiografia de tórax e suas respectivas máscaras são carregadas para o treinamento, validação e teste. Foram carregadas 1200 imagens para cada classe (saudável, COVID-19 e não COVID) totalizando 3.600 imagens. Não foi utilizada uma quantidade maior de imagens devido a quantidade de memória disponibilizada pelo Google Colab.

A divisão das imagens foi feita separando 80% do total das imagens para treinamento e 20% para testes, e do total de imagens separadas para treinamento foi retirado 10% para a validação durante o treinamento, como apresentado na Tabela 3.1.

Tabela 3.1 – Divisão das imagens para treinamento, validação e teste.

Imagens de treinamento	2.592
Imagens de validação	288
Imagens de teste	720
Total de imagens	3.600

Em seguida foram efetuados os pré-processamentos com a finalidade de redimensionar as imagens para 224×224 pixels e aplicar uma normalização (converter os valores dos pixels entre 0 e 1) para cada uma das imagens.

Posteriormente é executado os treinamentos da UNet e MultiResUNet, as quais recebem como entrada as radiografias e suas respectivas máscaras divididas para treinamento e validação, seguindo as configurações de acordo com a Tabela 3.2.

Tabela 3.2 – Configurações dos treinamentos.

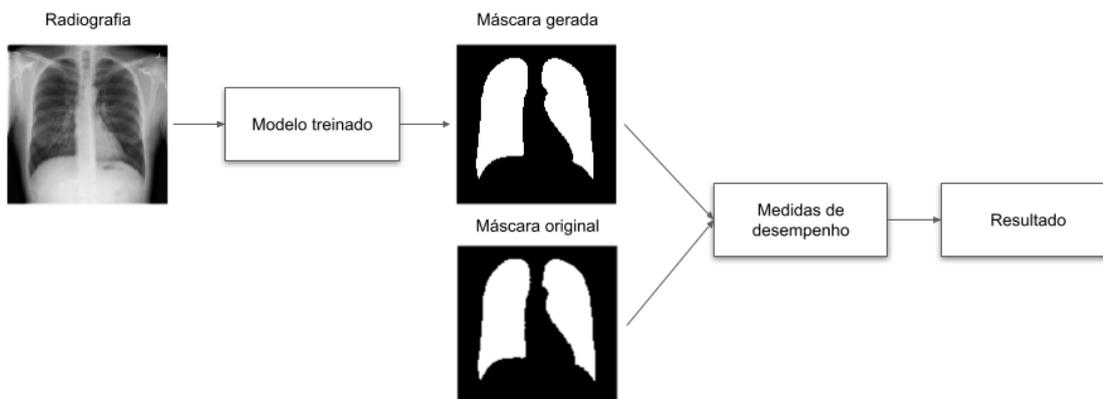
Configuração	Valor
Dimensões das imagens	224×224
Tamanho do lote	16
Épocas	50
Otimizador	Adam
Função de perda	Binary crossentropy

Como base é utilizado o script da UNet fornecido pelo Massucato (2018) e a MultiResUNet disponibilizado por Ibtehaz & Rahman (2020) com alguns ajustes em ambos. Eles são implementados na linguagem de programação *Python* e utiliza a biblioteca *Keras*.

Mais adiante é obtido os resultados usando o modelo gerado pelo treinamento nas imagens de teste. A Figura 3.3 demonstra o procedimento da geração da máscara e cálculo das métricas de desempenho considerando uma imagem em individual.

A radiografia após ser carregada, é submetida ao modelo para efetuar a previsão, no qual a saída é uma máscara correspondendo apenas a região do pulmão. Uma vez a máscara gerada, ela é enviada juntamente a máscara original para os cálculos das medidas de desempenho do Índice de Jaccard e o Coeficiente Dice (detalhadas na Seção 3.3), obtendo valores numéricos que representa a similaridade entre as duas imagens.

Este procedimento acontece para um total de 720 imagens para cada uma das classes da base de dados, com o intuito de examinar e comparar as medidas e as características por categoria, para identificar alguma particularidade da classe em individual que pode dificultar o treinamento, Tabela 3.3.

Figura 3.3 – Processo de previsão e cálculo das medidas de desempenho em uma imagem individual.

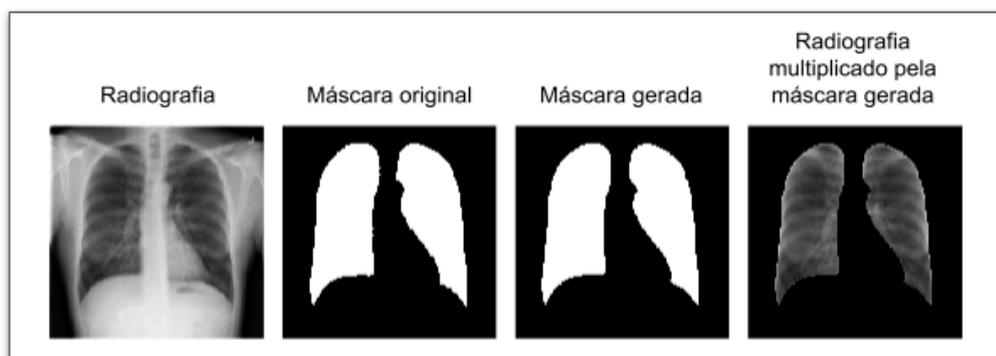
Fonte: Elaborada pelo autor.

Tabela 3.3 – Separação da quantidade de imagens para geração dos resultados de teste.

Imagens da classe normal	720
Imagens da classe COVID-19	720
Imagens da classe não COVID	720

E por fim, uma análise é realizada nos resultados gerados, organizando os valores das métricas de desempenho por classe para identificar a divergência entre os resultados obtidos, assim as características das imagens das categorias com medidas inferiores são examinadas em relação as demais, para verificar quais fatores podem estar dificultando a segmentação.

Com este objetivo, o entendimento das particularidades foi efetuado na comparação visual da máscara gerada com a máscara original, bem como a confirmação da segmentação da máscara gerada com a radiografia. A Figura 3.4 apresenta a estrutura de exibição para este comparativo.

Figura 3.4 – Exemplo da estrutura de exibição para análise visual da segmentação.

Fonte: Elaborada pelo autor.

A primeira imagem é a radiografia que é encaminhada à previsão, a segunda refere-se a máscara original que corresponde a região do pulmão do raio-x, a terceira consiste na máscara gerada pelo modelo treinado a partir da radiografia submetida, e por último a visão do raio-x apenas com a área do pulmão usando a máscara gerada para fragmentação.

Com esta forma de apresentação, é possível identificar, de modo geral, as falhas das máscaras geradas em relação as máscaras originais, o estado da radiografia (caso encontre-se ampliada, inclinada, com alterações no contraste, entre outras) e em uma outra perspectiva, examinar na eventualidade da segmentação ocorrer de maneira incompleta ou em outras regiões externa aos pulmões.

3.3 – Métricas de Avaliação

Na avaliação e comparativo do desempenho da segmentação das redes neurais convolucionais (UNet e MultiResUNet) treinadas, é utilizado as medidas de Índice de Jaccard e Coeficiente Dice que são métricas frequentemente aplicadas na literatura.

3.3.1 – Coeficiente de similaridade de dados

O coeficiente de similaridade de dados (*Dice Similarity Coefficient - DSC*) é normalmente utilizado, em imagens médicas, para analisar o nível de coincidência entre duas estruturas. Um DSC ($0 \leq DSC \leq 1$) elevado representa, entre as duas estruturas, um maior nível de sobreposição. O cálculo do DSC é realizado conforme a Equação 3.1 (Zhu *et al.*, 2019).

$$DSC = \frac{2(V_1 \cap V_2)}{V_1 + V_2} \quad (3.1)$$

O volume da estrutura de referência é denotado por V_1 e o volume da estrutura de comparação é definido pelo V_2 (Zhu *et al.*, 2019). O DSC computa a semelhança entre, para cada classe, os pixels previstos e reais (Hasan & Abdulazeez, 2020).

3.3.2 – Índice de Jaccard

O índice de *Jaccard* mede a proporção da classificação correta dos pixels considerando os dados reais totais e a previsão dos pixels para cada uma das classes (Hasan & Abdulazeez, 2020). Ele calcula a similaridade dividindo a quantidade de recursos da interseção com a

quantidade de recursos da união de duas coleções, este cálculo pode ser determinado pela Equação 3.2, em que a máscara original é demonstrado por GT e a predição é representado por PR (Maiello *et al.*, 2022).

$$Jaccard(GT, PR) = \frac{|GT \cap PR|}{|GT \cup PR|} \quad (3.2)$$

Resultados das Segmentações

Este capítulo tem como intuito apresentar os resultados das segmentações dos pulmões das radiografias de tórax, utilizando as redes neurais convolucionais MultiResUNet e UNet, bem como o tempo gasto para executar o treinamento dessas redes. Na avaliação é usado as medidas de desempenho (Índice de Jaccard e DSC), uma análise visual das identificações das máscaras (previsões) com as informações da base de imagens e um comparativo dos resultados obtidos nas imagens de testes.

4.1 – Segmentação com UNet

Esta seção tem o objetivo de apresentar os resultados da CNN UNet por meio das imagens de testes dos pulmões saudáveis, com COVID-19 e não COVID. O tempo de duração do treinamento para esta rede foi de aproximadamente 34 minutos até finalizar.

4.1.1 – Identificação das máscaras nas imagens saudáveis

A realização da previsão nas imagens divididas para teste com pulmões saudáveis, ocorreu com o número de 720 imagens, o qual executou em cerca de 12 segundos. A média dos resultados que o modelo treinado atingiu foi de um Índice de Jaccard de 96,05% e um DSC de 97,96%. Os valores obtidos são descritos na Tabela 4.1.

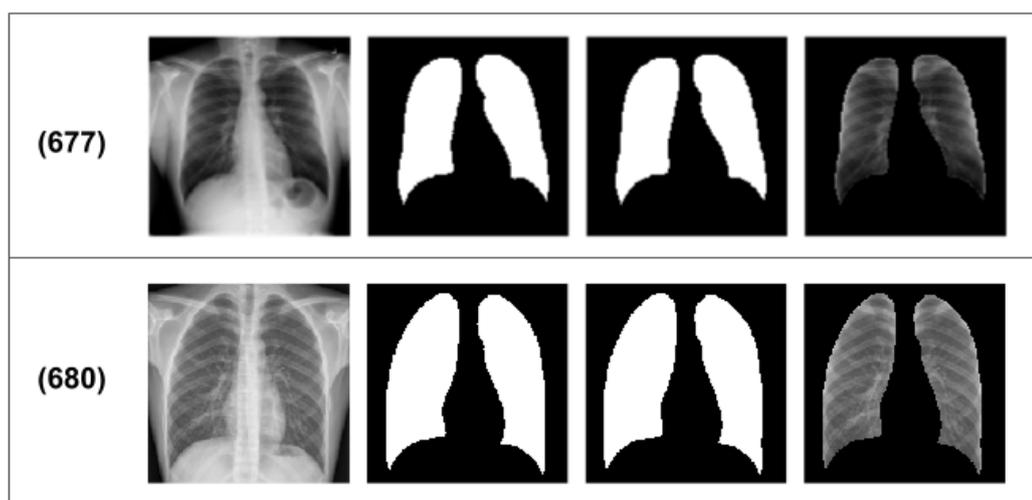
Tabela 4.1 – Média dos resultados das medidas de desempenho da UNet para imagens saudáveis.

Medidas	Resultados
Índice de Jaccard	96,05% ($\pm 2,49$)
DSC	97,96% ($\pm 1,35$)

A Figura 4.1 demonstra algumas radiografias que atingiram valores satisfatórios nas medidas de desempenho, em vista disso observa-se que as máscaras geradas estão similares as

máscaras originais. Os resultados para as radiografias foram a imagem (677), com Índice de Jaccard de 98,50% e o DSC de 99,24%, e a imagem (680), com Índice de Jaccard de 98,63% e o DSC de 99,31%.

Figura 4.1 – Imagens dos pulmões saudáveis de número (677) e (680) que obtiveram valores satisfatórios nas previsões da UNet.



Fonte: Elaborada pelo autor.

A Figura 4.2 ilustra determinadas imagens que resultaram em falhas de similaridades das máscaras geradas com as máscaras originais, nas quais a imagem (398), com Índice de Jaccard de 75,40% e o DSC de 85,98%, não detectou uma parte da região pulmonar esquerda, bem como identificou uma região externa de forma isolada no mesmo pulmão. Já na imagem (601), com Índice de Jaccard de 74,69% e o DSC de 85,51%, segmentou uma região maior do que a indicada no pulmão direito.

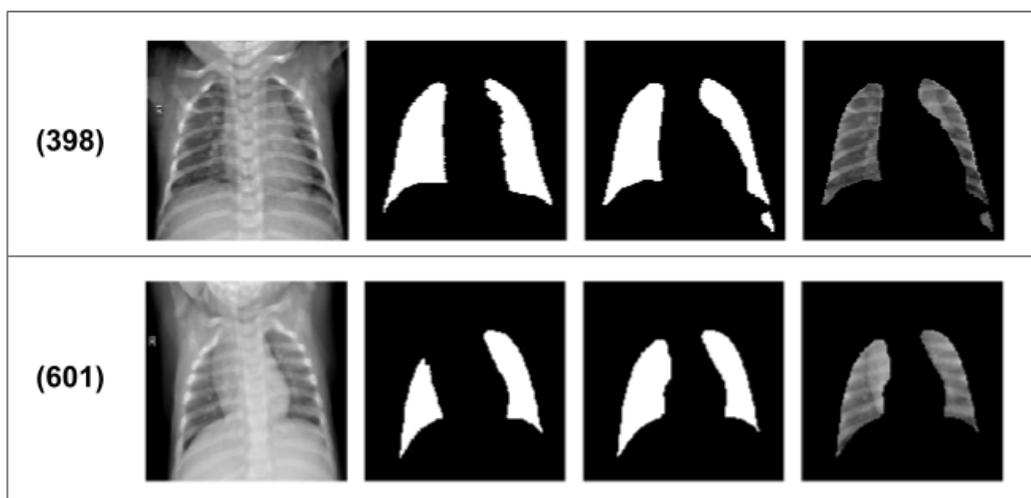
4.1.2 – Identificação das máscaras nas imagens com COVID-19

Na previsão com as 720 imagens de COVID-19 para testes, o modelo treinado efetuou a detecção em aproximadamente 11 segundos. Esta rede alcançou a média de Índice de Jaccard de 95,49% e um DSC de 97,65% nas medidas de desempenho. A Tabela 4.2 informa as médias atingidas.

Tabela 4.2 – Média dos valores das medidas de desempenho da UNet para imagens com COVID-19.

Medidas	Resultados
Índice de Jaccard	95,49% ($\pm 3,62$)
DSC	97,65% ($\pm 2,16$)

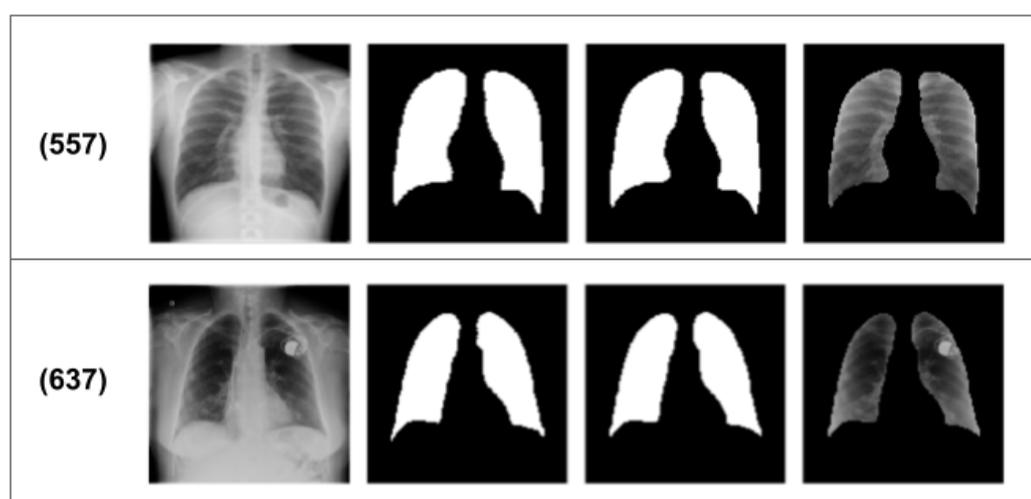
Figura 4.2 – Imagens dos pulmões saudáveis de número (398) e (601) que obtiveram falhas de similaridades nas previsões da UNet.



Fonte: Elaborada pelo autor.

A Figura 4.3 demonstra a imagem (557), com Índice de Jaccard de 98,45% e o DSC de 99,22%, e a imagem (637), com Índice de Jaccard de 98,23% e o DSC de 99,11%, que são exemplos de radiografias que alcançaram alguns dos melhores valores nas medidas de desempenho, por essa causa percebe-se a semelhança entre as máscaras geradas e as originais.

Figura 4.3 – Imagens dos pulmões com COVID-19 de número (557) e (637) que obtiveram valores satisfatórios nas previsões da UNet.

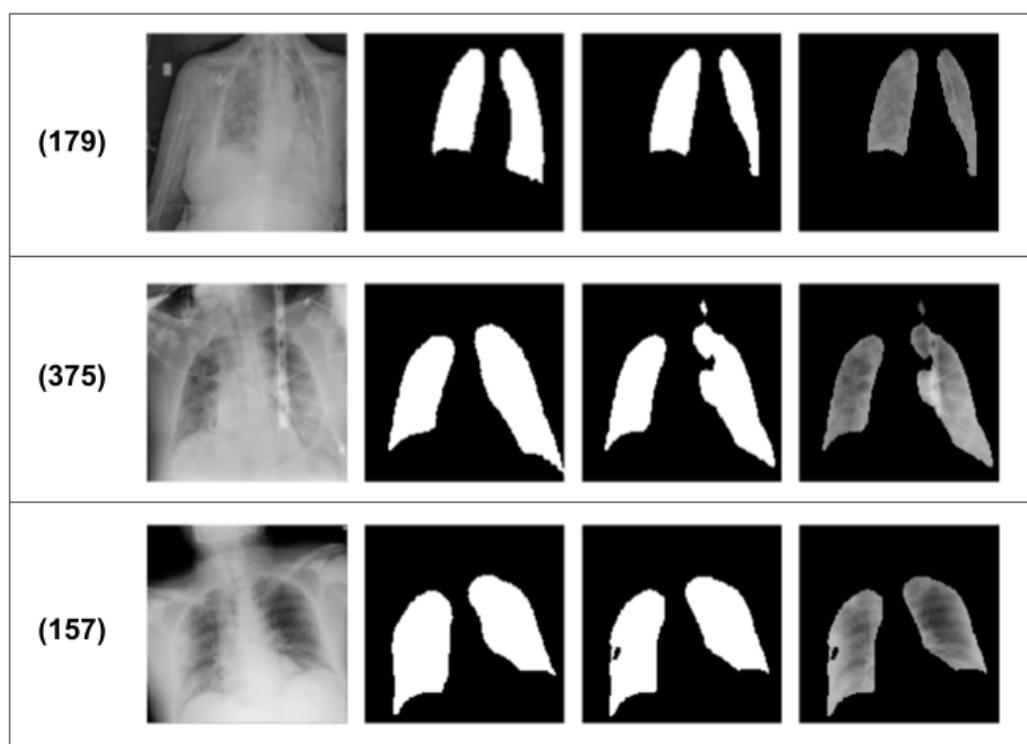


Fonte: Elaborada pelo autor.

A Figura 4.4 ilustra algumas imagens com falhas de similaridades entre as máscaras geradas e as originais. Na imagem (179), com Índice de Jaccard de 77,39% e o DSC de 87,26%, não foi possível segmentar localidades do pulmão esquerdo, na imagem (375), com Índice de Jaccard de 85,58% e o DSC de 92,23%, além de não conseguir detectar regiões do

pulmão esquerdo, também identificou como localidade pulmonar uma região externa ao mesmo pulmão, e na imagem (157), com Índice de Jaccard de 89,91% e o DSC de 94,68%, o modelo não segmentou uma parte interna do pulmão direito.

Figura 4.4 – Imagens dos pulmões com COVID-19 de número (179), (375) e (157) que obtiveram falhas de similaridades nas previsões da UNet.

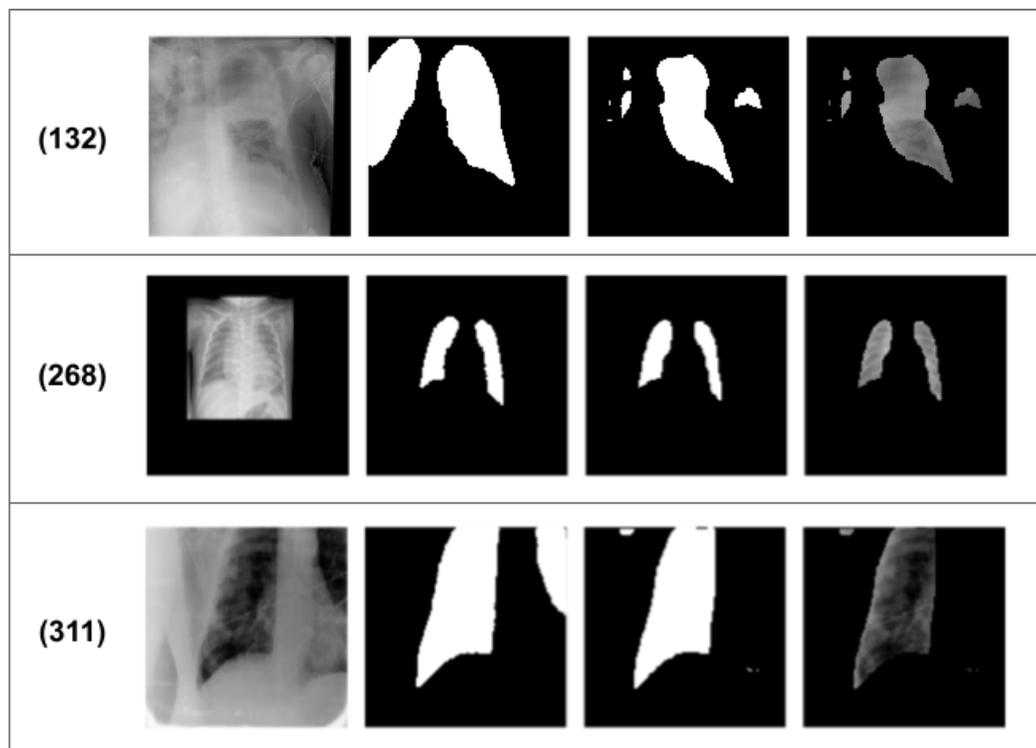


Fonte: Elaborada pelo autor.

A Figura 4.5 apresenta determinados exemplos de pulmões que estão em posições diferentes nas radiografias, os quais obtiveram valores inferiores nas métricas de desempenho. A imagem (132), com Índice de Jaccard de 46,83% e o DSC de 63,78%, está deslocada à esquerda ocultando parte do pulmão direito, a imagem (268), com Índice de Jaccard de 81,79% e o DSC de 89,98%, está reduzida em relação ao tamanho normal da imagem, e a imagem (311), com Índice de Jaccard de 76,69% e o DSC de 86,81%, está aparentemente com o tamanho ampliado, o que oculta a região pulmonar esquerda.

Na Figura 4.5, imagem (132), observa-se a detecção da região do pulmão direito, que no pulmão esquerdo a detecção obteve muitas falhas e que foi identificado área de pulmão em localidades sem conexão com quaisquer regiões pulmonares. Na imagem (268) nota-se que a detecção da área do pulmão foi um pouco menor. E na imagem (311) percebe-se que não foi identificado a região do pulmão direito, além disso foi identificado regiões de forma aleatória externo as regiões dos pulmões.

Figura 4.5 – Imagens dos pulmões com COVID-19 de número (132), (268) e (311) com posicionamentos diferentes que obtiveram falhas de similaridades nas previsões da UNet.



Fonte: Elaborada pelo autor.

4.1.3 – Identificação das máscaras nas imagens não COVID

A previsão do modelo treinado durou cerca de 11 segundos para um total de 720 imagens não COVID. A média das medidas de desempenho foram o Índice de Jaccard de 91,35% e um DSC de 95,39%. A Tabela 4.3 descreve a média dos resultados.

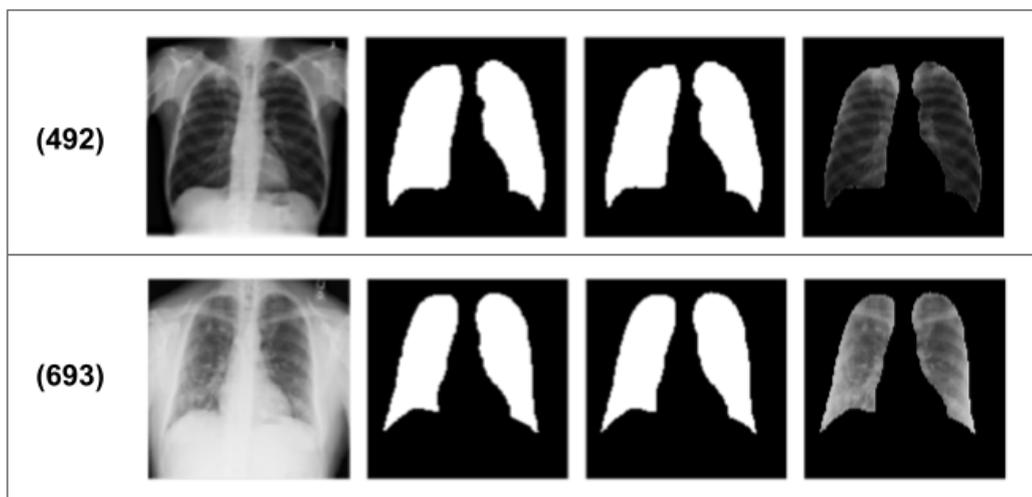
Tabela 4.3 – Média dos valores das medidas de desempenho da UNet para imagens não COVID.

Medidas	Resultados
Índice de Jaccard	91,35% ($\pm 5,43$)
DSC	95,39% ($\pm 3,17$)

A Figura 4.6 demonstra a imagem (492), com Índice de Jaccard de 98,23% e o DSC de 99,11%, e a imagem (693), com Índice de Jaccard de 98,45% e o DSC de 99,22%, tais quais são algumas das radiografias que atingiram resultados satisfatórios nas medidas de desempenho.

A Figura 4.7 apresenta algumas imagens com valores baixos nas métricas de desempenho que representam as principais falhas de similaridades encontradas. Na imagem (487), com Índice de Jaccard de 66,89% e o DSC de 80,16%, não detectou o topo do pulmão direito, na imagem (554), com Índice de Jaccard de 76,09% e o DSC de 86,42%,

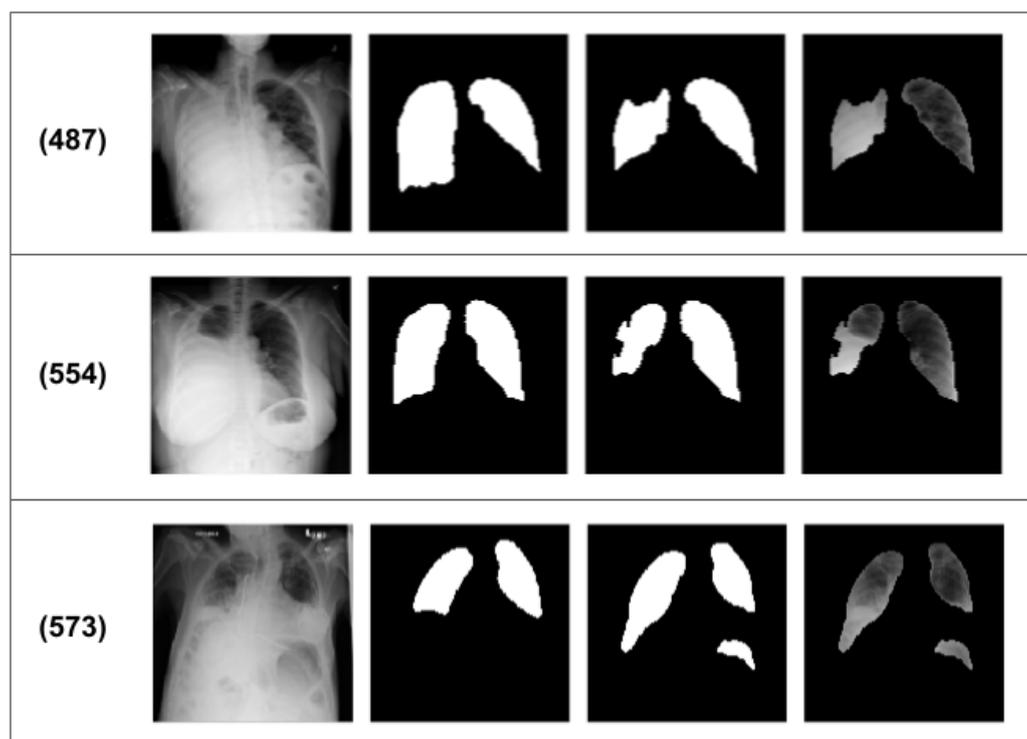
Figura 4.6 – Imagens dos pulmões não COVID de número (492) e (693) que obtiveram valores satisfatórios nas previsões da UNet.



Fonte: Elaborada pelo autor.

não segmentou partes da região pulmonar direita, na imagem (573), com Índice de Jaccard de 68,34% e o DSC de 81,19%, identificou erroneamente o pulmão direito e segmentou como pulmão uma localidade isolada de quaisquer regiões pulmonares.

Figura 4.7 – Imagens dos pulmões não COVID de número (487), (554) e (573) que obtiveram falhas de similaridades nas previsões da UNet.

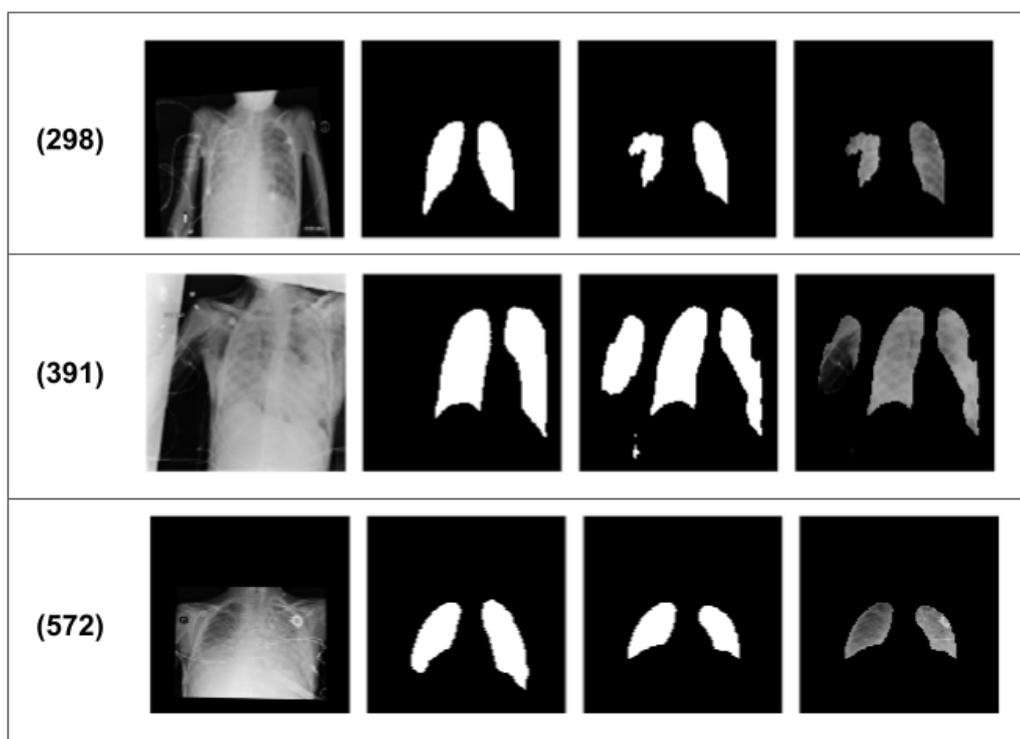


Fonte: Elaborada pelo autor.

A Figura 4.8 demonstra algumas radiografias com os pulmões de forma não centralizada. A imagem (298) está reduzida em tamanho e rotacionada a esquerda, a imagem (391) está rotacionada a direita e a imagem (572) a radiografia está com tamanho reduzido em relação as dimensões da imagem.

Observa-se que na imagem (298), com Índice de Jaccard de 56,84% e o DSC de 72,48%, segmentou com erros o pulmão direito, na imagem (391), com Índice de Jaccard de 63,82% e o DSC de 77,91%, gerou o pulmão esquerdo com falhas, além de identificar pulmões em localidades externas as regiões pulmonares, e na imagem (572), com Índice de Jaccard de 62,05% e o DSC de 76,58%, não segmentou os pulmões por completo.

Figura 4.8 – Imagens dos pulmões não COVID de número (298), (391) e (572) com posicionamentos diferentes que obtiveram falhas de similaridades nas previsões da UNet.



Fonte: Elaborada pelo autor.

4.1.4 – Comparativo entre os resultados das classes

No comparativo de duração das identificações das máscaras utilizando as imagens separadas para teste considerando as classes, a geração das máscaras alcançaram uma quantidade de tempo semelhante entre as categorias. A Tabela 4.4 informa o período de execução por classe.

Tabela 4.4 – Duração em segundos das segmentações da UNet nas imagens de teste por classe.

Imagens	Duração
Saudáveis	12s
Com COVID-19	11s
Não COVID	11s

A Tabela 4.5 descreve as médias das métricas de desempenho por classe com objetivo de simplificar a comparação. Percebe-se que os valores obtidos para saudáveis e com COVID-19 são próximos, entretanto os resultados do não COVID resultou em um menor valor em média em ambas as medidas de desempenho em relação as demais.

Tabela 4.5 – Comparativo das médias das medidas de desempenho das segmentações da UNet nas imagens de teste por classe.

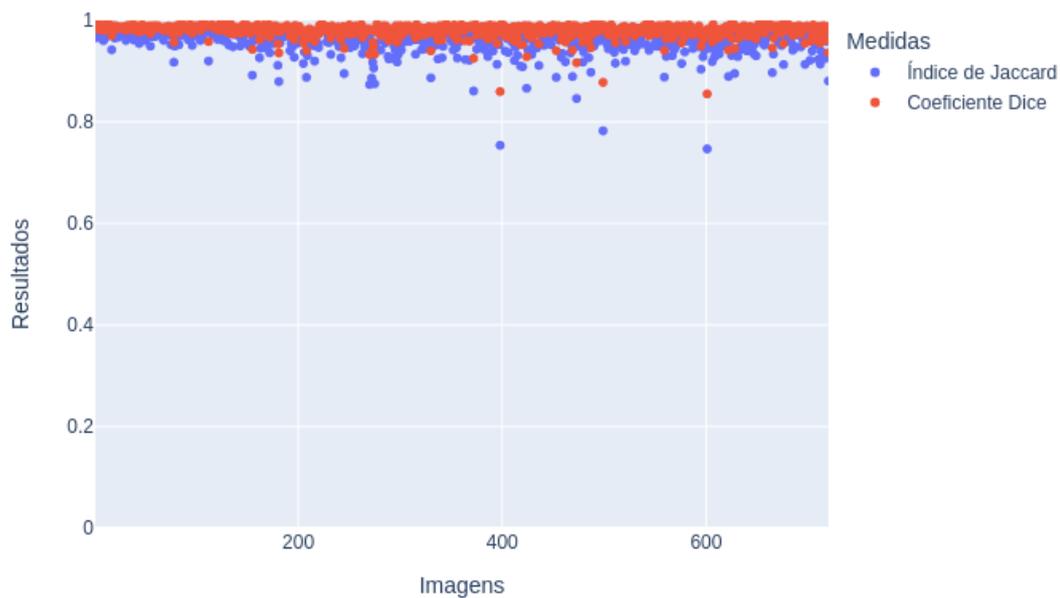
Imagens	Índice de Jaccard	DSC
Saudáveis	96,05% ($\pm 2,49$)	97,96% ($\pm 1,35$)
Com COVID-19	95,49% ($\pm 3,62$)	97,65% ($\pm 2,16$)
Não COVID	91,35% ($\pm 5,43$)	95,39% ($\pm 3,17$)

As Figuras 4.9, 4.10 e 4.11 ilustram os resultados de cada imagem das classes saudável, com COVID-19 e Não COVID respectivamente em gráficos. Nota-se que os resultados da classe não COVID oscila mais quando se comparado com a saudável e COVID-19, justificando a diferença considerável na média das medidas de desempenho da não COVID entre as demais categorias.

As três classes alcançaram medidas de desempenhos relevantes para várias das radiografias utilizadas nos testes, contudo em alguns casos foram obtidos valores baixos nas métricas. Desse modo a medida que esses resultados por radiografia diminuam, geravam falhas de similaridades nas regiões pulmonares. As Figuras 4.2, 4.4 e 4.7 ilustram alguns exemplos dessas detecções nas imagens dos pulmões saudáveis, com COVID-19 e não COVID, respectivamente.

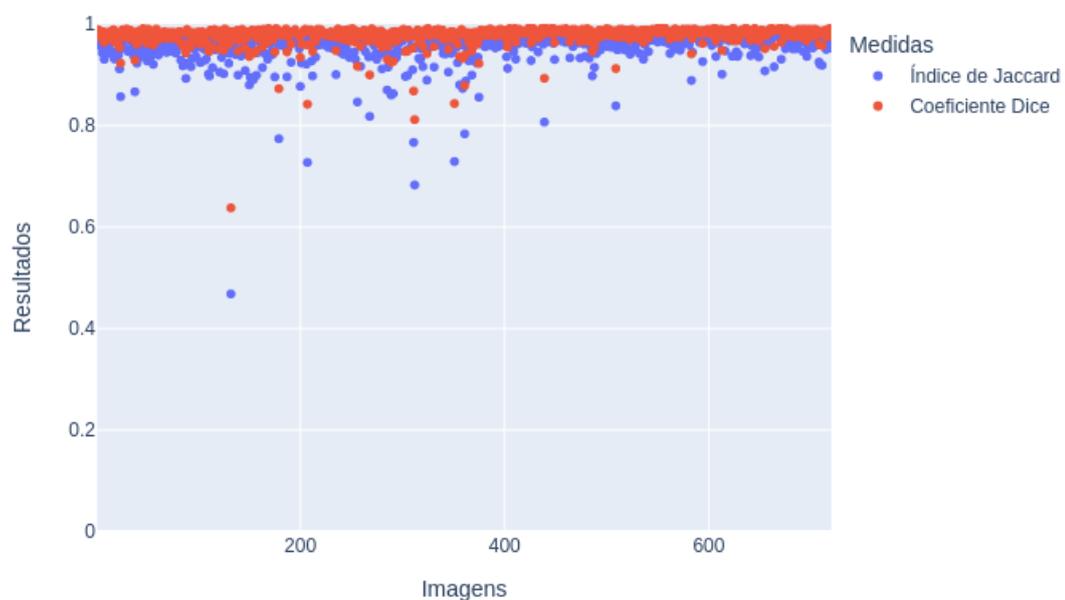
As imagens que tem o pulmão não centralizado nas radiografias, tamanho reduzido, compactadas, entre outros, são efeitos existentes para todas as classes aplicadas para os testes. As imagens das categorias testadas atingiram resultados expressivos em algumas dessas imagens, no entanto as radiografias das classes COVID-19 e não COVID, notou-se uma quantidade maior de erros de semelhança entre as máscaras geradas com as originais em contraste com as imagens saudáveis. As Figuras 4.5 e 4.8 demonstram determinados exemplos dessas identificações para as imagens com COVID-19 e não COVID, respectivamente.

Figura 4.9 – Gráfico da classe saudável com os resultados das medidas de desempenho de cada imagem de teste da UNet.



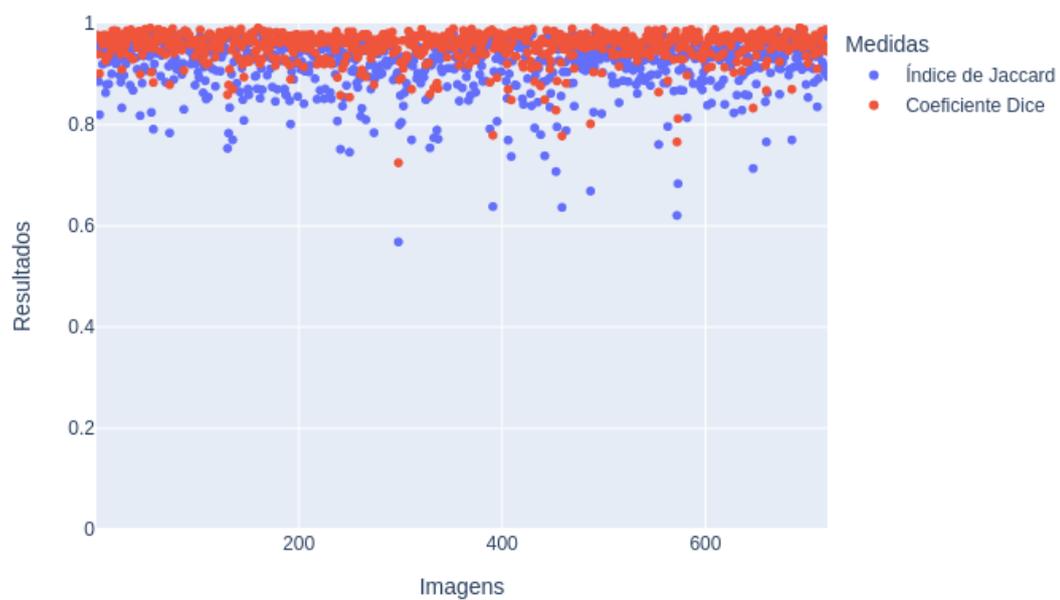
Fonte: Elaborada pelo autor.

Figura 4.10 – Gráfico da classe com COVID-19 com os resultados das medidas de desempenho de cada imagem de teste da UNet.



Fonte: Elaborada pelo autor.

Figura 4.11 – Gráfico da classe não COVID com os resultados das medidas de desempenho de cada imagem de teste da UNet.



Fonte: Elaborada pelo autor.

4.2 – Segmentação com MultiResUNet

Esta seção busca detalhar os resultados alcançados pela CNN MultiResUNet, dividindo as informações entre a identificação das máscaras das imagens saudáveis, com COVID-19 e não COVID. O treinamento da MultiResUNet durou cerca de 1 hora e 36 minutos até concluir.

4.2.1 – Identificação das máscaras nas imagens saudáveis

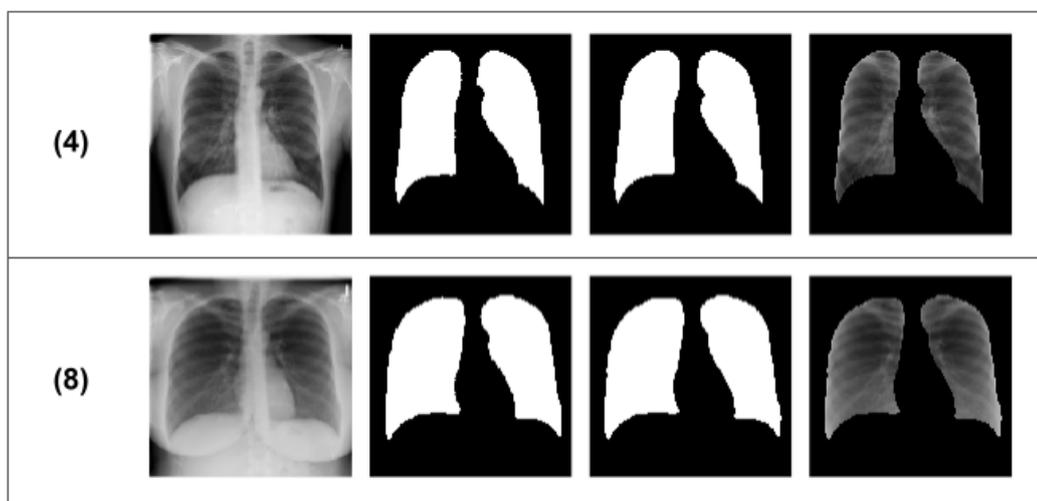
A previsão de 720 imagens do conjunto separado para realizar os testes com os pulmões saudáveis, terminou em aproximadamente 19 segundos. Nos resultados das identificações das máscaras, o modelo treinado alcançou em média um Índice de Jaccard de 95,71% e um DSC de 97,79%. As médias obtidas são ilustradas na Tabela 4.6.

Tabela 4.6 – Média dos resultados das medidas de desempenho da MultiResUNet para imagens saudáveis.

Medidas	Resultados
Índice de Jaccard	95,71% ($\pm 2,50$)
DSC	97,79% ($\pm 1,36$)

A Figura 4.12 demonstra determinadas segmentações que alcançaram algumas das melhores medidas de desempenho. Observa-se que as máscaras geradas da radiografia de número (4), com Índice de Jaccard de 98,29% e o DSC de 99,14%, e número (8), com Índice de Jaccard de 98,11% e o DSC de 99,04%, foram semelhantes as máscaras originais.

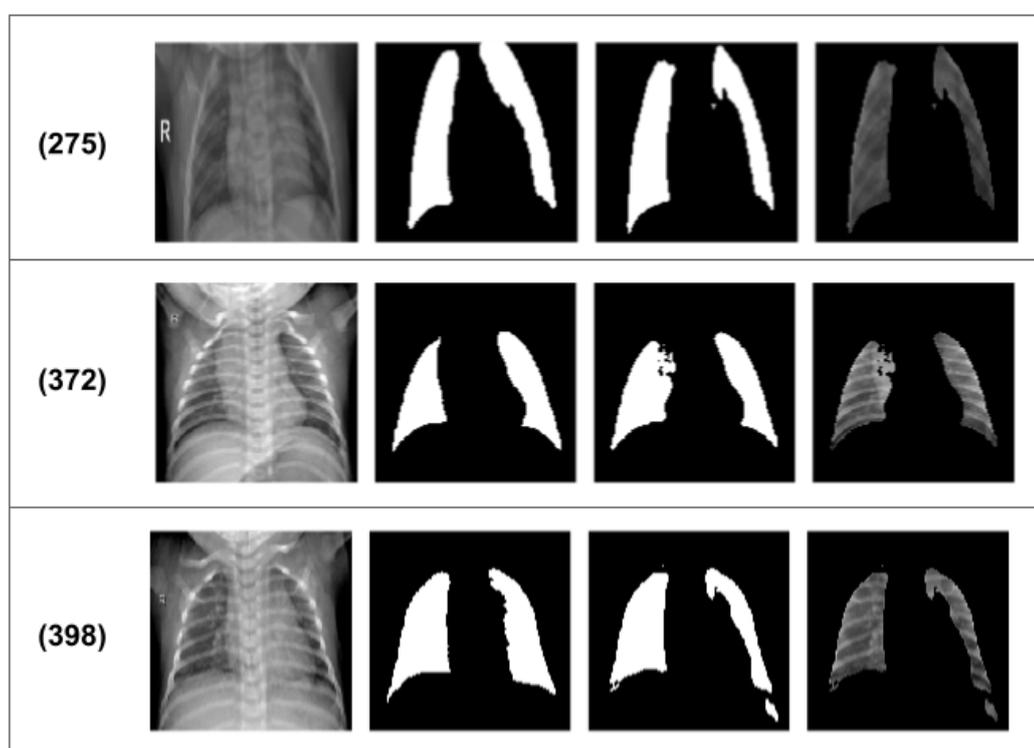
Figura 4.12 – Imagens dos pulmões saudáveis de número (4) e (8) que obtiveram valores satisfatórios nas previsões da MultiResUNet.



Fonte: Elaborada pelo autor.

A Figura 4.13 ilustra algumas imagens que obtiveram erros de similaridades nas segmentações. Percebe-se que na imagem (275), com Índice de Jaccard de 84,31% e o DSC de 91,49%, não identificou as regiões do topo de ambos os pulmões, na imagem (372), com Índice de Jaccard de 82,07% e DSC de 90,15%, segmentou a localidade do pulmão direito de forma errônea, e na imagem (398), com Índice de Jaccard de 75,07% e DSC de 85,76%, não detectou parte do pulmão esquerdo, bem como identificou uma região pulmonar de forma externa aos pulmões.

Figura 4.13 – Imagens dos pulmões saudáveis de número (275), (372) e (398) que obtiveram falhas de similaridades nas previsões da MultiResUNet.



Fonte: Elaborada pelo autor.

4.2.2 – Identificação das máscaras nas imagens com COVID-19

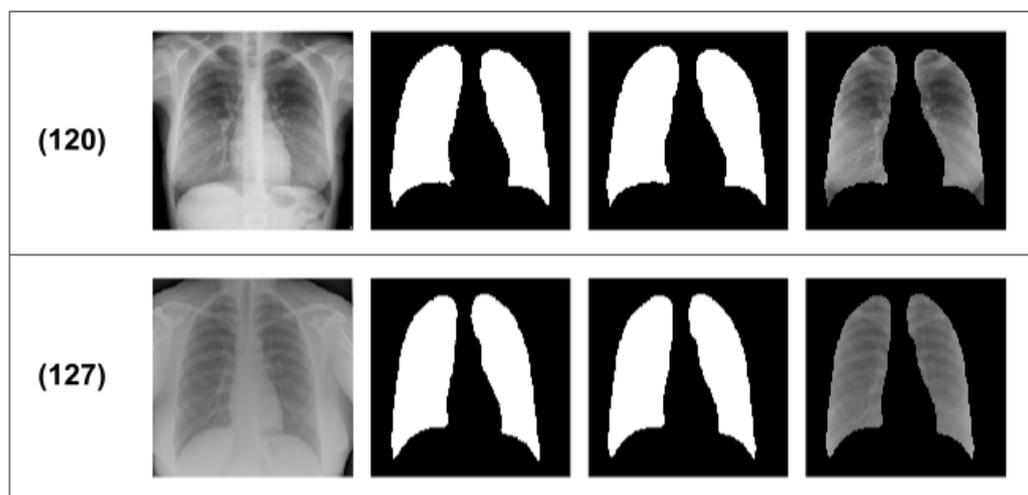
A previsão durou cerca de 19 segundos nas 720 imagens de testes com os pulmões acometidos por COVID-19. A CNN treinada obteve em suas identificações das máscaras uma média de Índice de Jaccard de 95,37% e um DSC de 97,59%. Os resultados alcançados são descritos na Tabela 4.7.

Na Figura 4.14 demonstra as previsões que atingiram valores interessantes nas métricas. Nota-se a correspondência das máscaras geradas com as originais, onde a imagem (120)

Tabela 4.7 – Média dos valores das medidas de desempenho da MultiResUNet para imagens com COVID-19.

Medidas	Resultados
Índice de Jaccard	95,37% ($\pm 3,69$)
DSC	97,59% ($\pm 2,20$)

calculou o Índice de Jaccard de 98,08% e o DSC de 99,03%, e a imagem **(127)** conseguiu um Índice de Jaccard de 98,21% e o DSC de 99,10%.

Figura 4.14 – Imagens dos pulmões com COVID-19 de número (120) e (127) que obtiveram valores satisfatórios nas previsões da MultiResUNet.

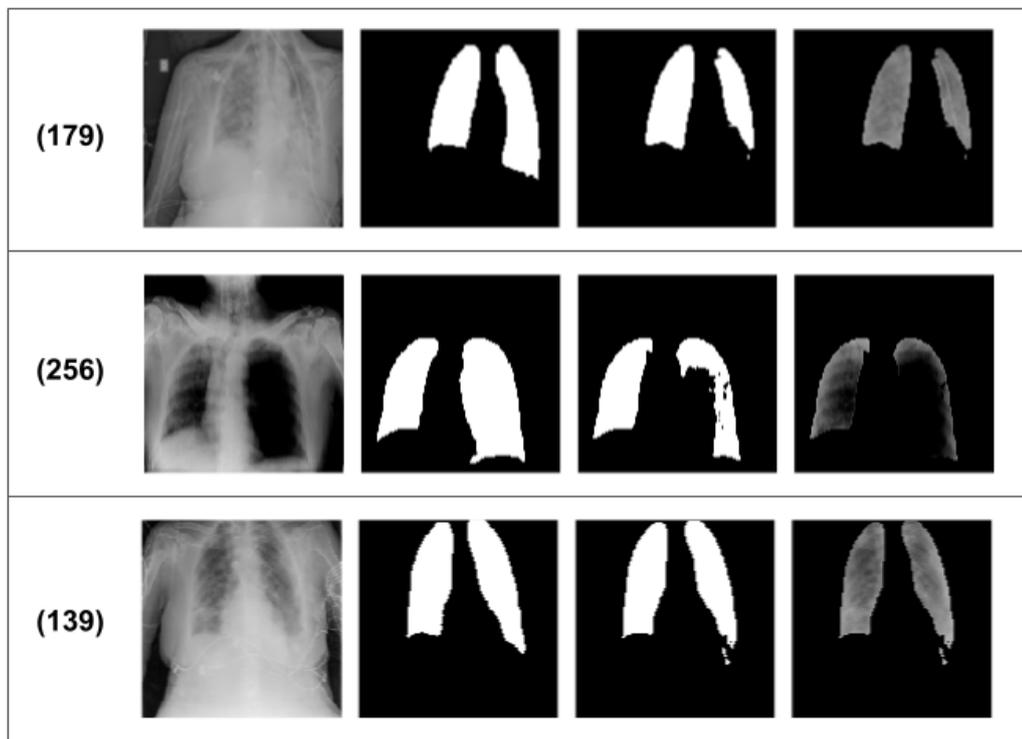
Fonte: Elaborada pelo autor.

A Figura 4.15 ilustra a imagem **(179)**, com Índice de Jaccard de 72,67% e o DSC de 84,17%, que segmentou o pulmão esquerdo com falhas, a imagem **(256)**, com Índice de Jaccard de 65,41% e o DSC de 79,09%, que identificou o pulmão esquerdo com erros, e a imagem **(139)**, com Índice de Jaccard de 88,92% e o DSC de 94,13%, que detectou uma região pulmonar sem conexão com o pulmão esquerdo.

A Figura 4.16 apresenta algumas imagens que obtiveram valores baixos nas métricas de desempenho, os quais são exemplos de alguns posicionamentos diferentes das radiografias. A imagem **(121)**, com Índice de Jaccard de 86,54% e o DSC de 92,78%, está rotacionada à esquerda, a imagem **(132)**, com Índice de Jaccard de 48,56% e o DSC de 65,38%, está deslocada à esquerda, e a imagem **(268)**, com Índice de Jaccard de 69,21% e o DSC de 81,81%, está reduzida em relação ao tamanho normal da imagem.

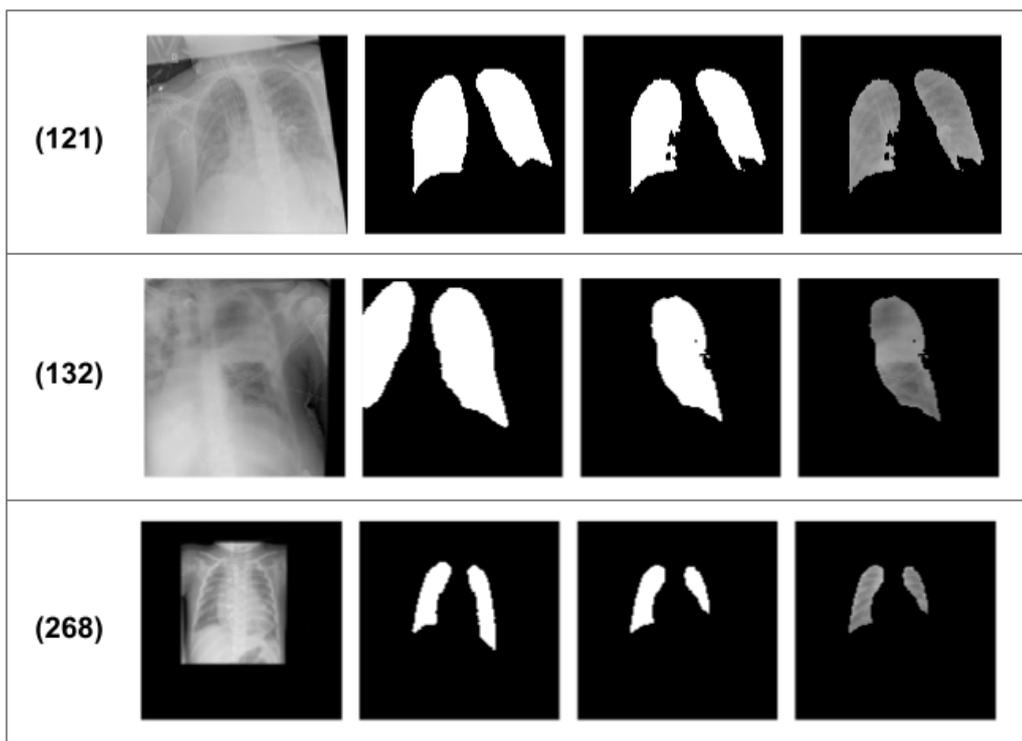
Importante notar que, na imagem **(132)** não segmentou o pulmão direito, o qual o deslocamento que ocultou parte da região pulmonar pode ter dificultado a identificação, bem como o pulmão esquerdo obteve algumas falhas em sua detecção. Na imagem **(121)** detectou

Figura 4.15 – Imagens dos pulmões com COVID-19 de número (179), (256) e (139) que obtiveram falhas de similaridades nas previsões da MultiResUNet.



Fonte: Elaborada pelo autor.

Figura 4.16 – Imagens dos pulmões com COVID-19 de número (121), (132) e (268) com posicionamentos diferentes que obtiveram falhas de similaridades nas previsões da MultiResUNet.



Fonte: Elaborada pelo autor.

as regiões pulmonares com obstruções, e na imagem (268) não segmentou o pulmão esquerdo por completo.

4.2.3 – Identificação das máscaras nas imagens não COVID

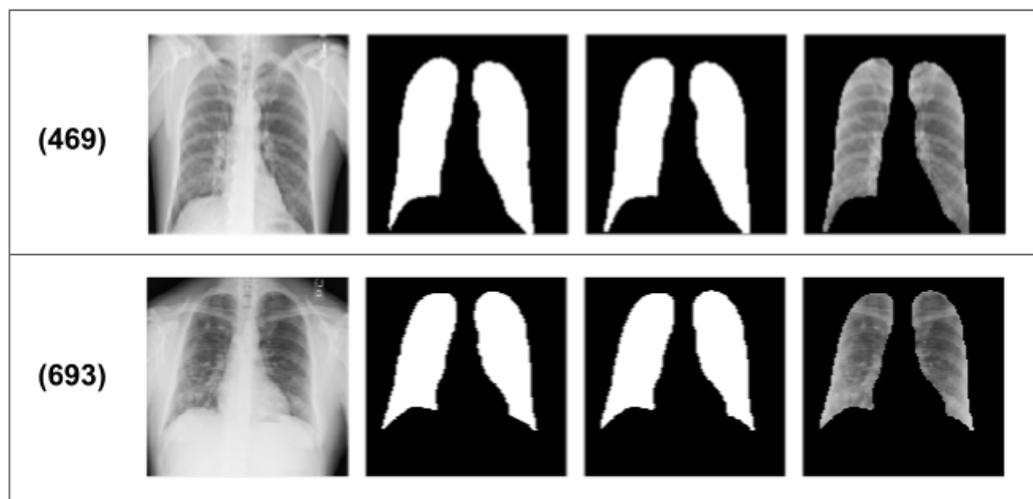
Nas 720 imagens não COVID, as previsões ocorreram em torno de 19 segundos. A média dos resultados foram o Índice de Jaccard de 91,39% e um DSC de 95,42% para o modelo treinado. A Tabela 4.8 detalha as informações das métricas de desempenho.

Tabela 4.8 – Média dos valores das medidas de desempenho da MultiResUNet para imagens não COVID.

Medidas	Resultados
Índice de Jaccard	91,39% ($\pm 4,90$)
DSC	95,42% ($\pm 2,85$)

A Figura 4.17 demonstra algumas das máscaras geradas em relação as originais, as quais alcançaram interessantes resultados e semelhança entre elas. A imagem (469) atingiu o Índice de Jaccard de 97,79% e o DSC de 98,88%, e a imagem (693) com o Índice de Jaccard de 98,20% e o DSC de 99,09%.

Figura 4.17 – Imagens dos pulmões não COVID de número (469) e (693) que obtiveram valores satisfatórios nas previsões da MultiResUNet.

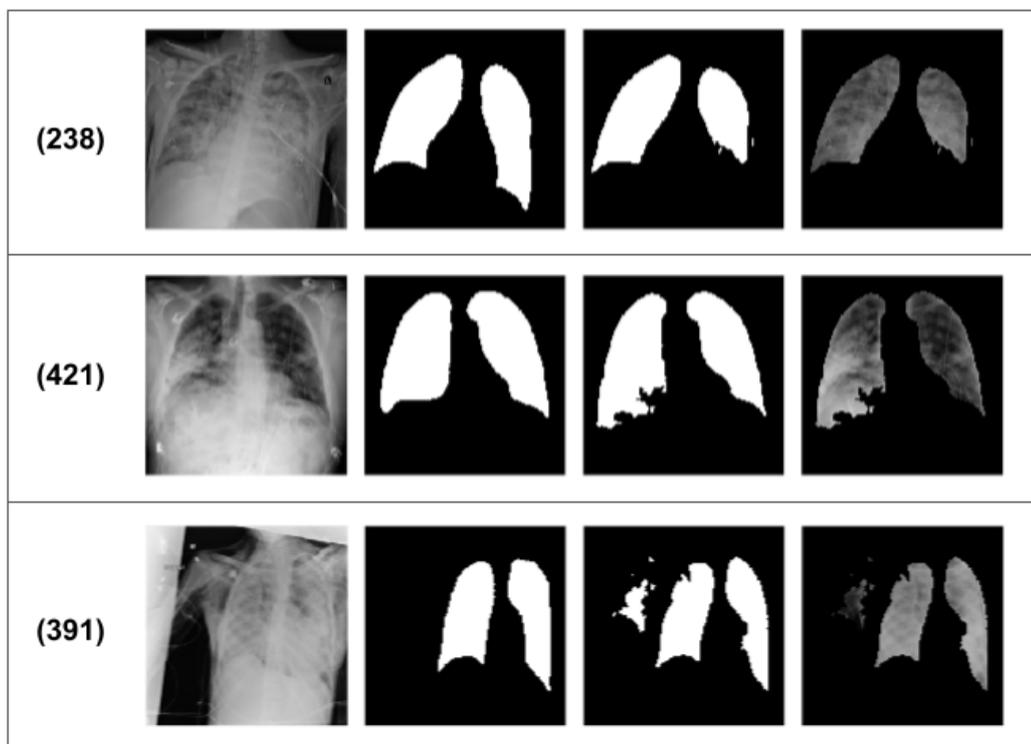


Fonte: Elaborada pelo autor.

A Figura 4.18 ilustra imagens que resultaram em valores baixos nas medidas de desempenho. Em vista disso, a segmentação aconteceu com falhas de similaridades em que não identificou o pulmão esquerdo completamente na imagem (238), com Índice de Jaccard de 80,69% e o DSC de 89,31%, detectou algumas localidades externa ao pulmão direito na imagem (421), com Índice de Jaccard de 81,16% e o DSC de 89,60%, e a imagem (391), com

Índice de Jaccard de 78,70% e o DSC de 88,08%, que segmentou parte do ombro direito como características que representam o pulmão.

Figura 4.18 – Imagens dos pulmões não COVID de número (238), (421) e (391) que obtiveram falhas de similaridades nas previsões da MultiResUNet.



Fonte: Elaborada pelo autor.

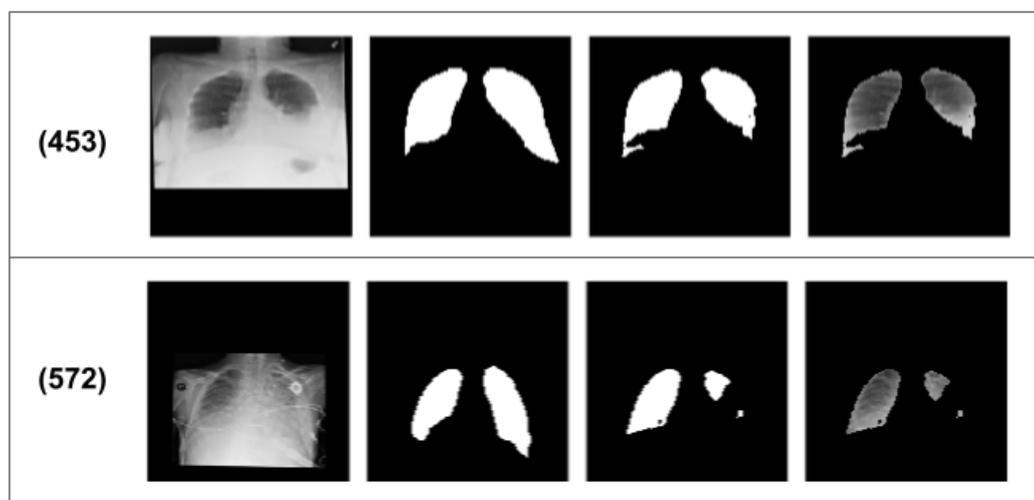
A Figura 4.19 apresenta imagens que está compactada (**453**), com Índice de Jaccard de 73,57% e o DSC de 84,77%, e reduzida (**572**), com Índice de Jaccard de 51,87% e o DSC de 68,30%, como exemplos de posições diferentes das radiografias entre as imagens utilizadas para testes, as quais atingiram valores inferiores em suas previsões.

Na imagem (**453**) identificou parte externa ao pulmão direito como região pulmonar e não segmentou localidades do pulmão esquerdo, e na imagem (**572**) segmentou com dificuldades a região pulmonar esquerda, além de possuir algumas falhas de similaridades no pulmão direito.

4.2.4 – Comparativo entre os resultados das classes

A Tabela 4.9 descreve um comparativo de tempo das identificações das máscaras entre as imagens de teste por classe, dessa forma nota-se que entre as categorias não obteve uma divergência significativa de duração das execuções.

Figura 4.19 – Imagens dos pulmões não COVID de número (453) e (572) com posicionamentos diferentes que obtiveram falhas de similaridades nas previsões da MultiResUNet.



Fonte: Elaborada pelo autor.

Tabela 4.9 – Duração em segundos das segmentações da MultiResUNet nas imagens de teste por classe.

Imagens	Duração
Saudáveis	19s
Com COVID-19	19s
Não COVID	19s

A Tabela 4.10 informa as médias das medidas de desempenho por classe. Observe-se que os resultados não conseguiram uma diferença considerável, no entanto a Não COVID adquiriu um valor inferior em relação as demais.

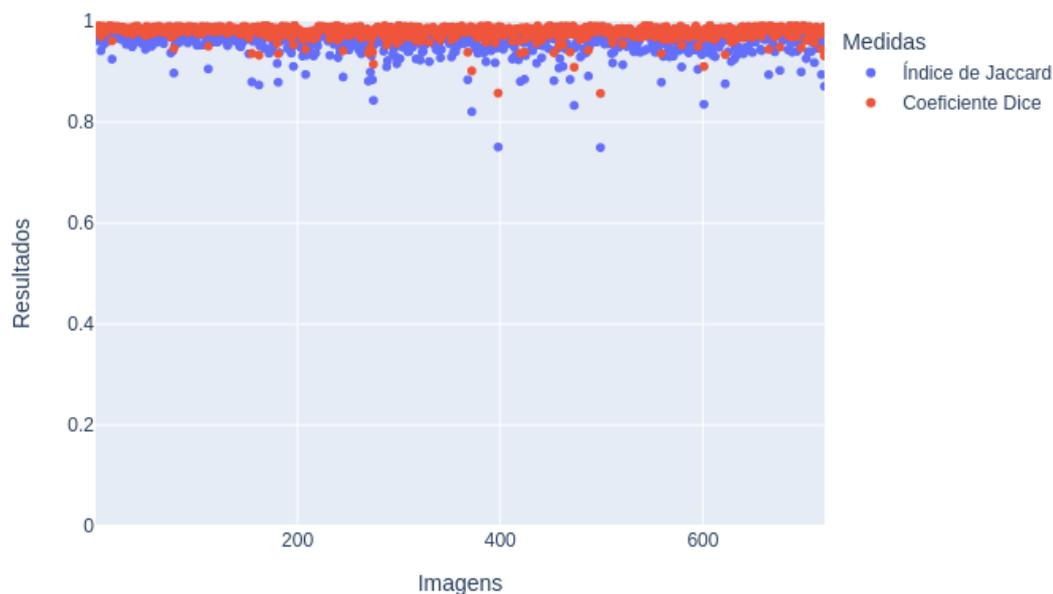
Tabela 4.10 – Comparativo das médias das medidas de desempenho das segmentações da MultiResUNet nas imagens de teste por classe.

Imagens	Índice de Jaccard	DSC
Saudáveis	95,71% ($\pm 2,50$)	97,79% ($\pm 1,36$)
Com COVID-19	95,37% ($\pm 3,69$)	97,59% ($\pm 2,20$)
Não COVID	91,39% ($\pm 4,90$)	95,42% ($\pm 2,85$)

As Figuras 4.20, 4.21 e 4.22 demonstram os valores das medidas de desempenho para cada imagem das categorias saudável, com COVID-19 e não COVID respectivamente em gráficos. Percebe-se nestas perspectivas, que a classe não COVID alterna com maior frequência em seus resultados quando comparado-as com as demais classes.

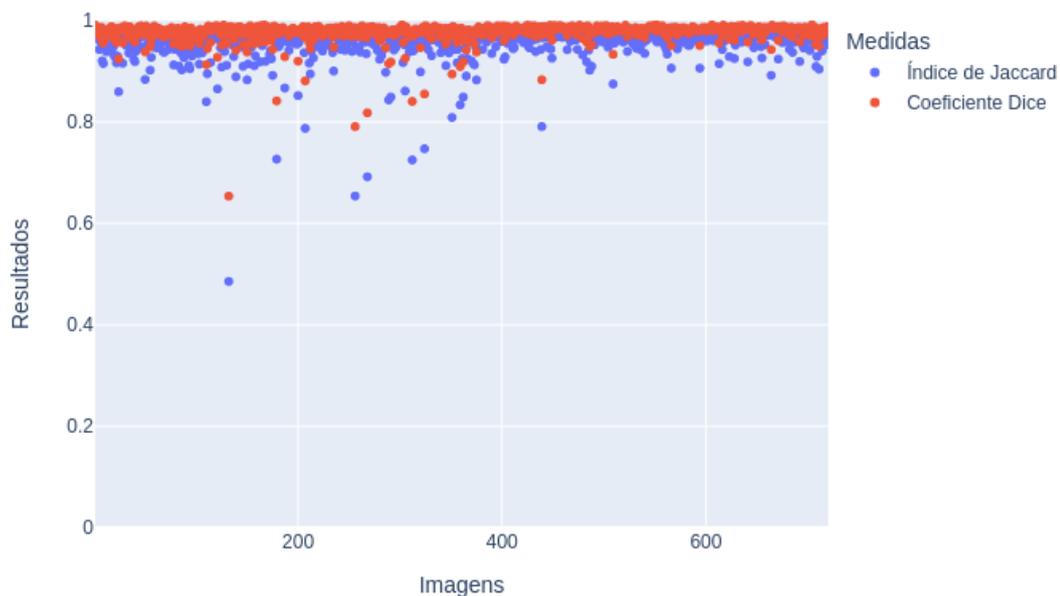
A medida que as métricas de desempenho resultavam em valores baixos na análise das similaridades das máscaras geradas com as originais, ocorriam segmentações de localidades que não eram regiões pulmonares ou não identificavam os locais dos pulmões corretamente, esses cenários são comuns para as três classes verificadas. As Figuras 4.13, 4.15 e 4.18, demonstram

Figura 4.20 – Gráfico da classe saudável com os resultados das medidas de desempenho de cada imagem de teste da MultiResUNet.



Fonte: Elaborada pelo autor.

Figura 4.21 – Gráfico da classe com COVID-19 com os resultados das medidas de desempenho de cada imagem de teste da MultiResUNet.

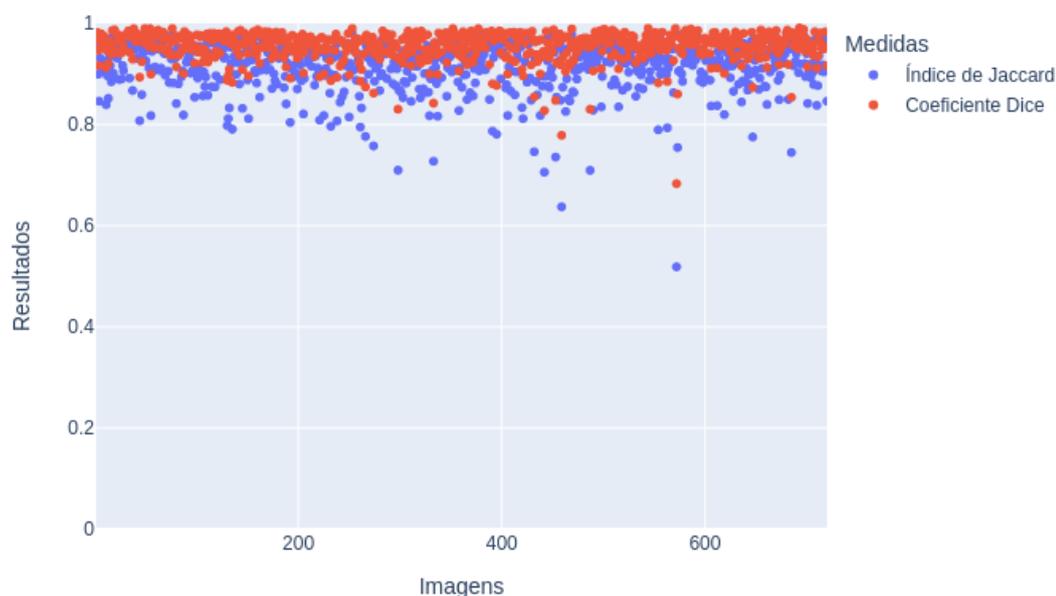


Fonte: Elaborada pelo autor.

alguns exemplos das segmentações com erros para as categorias dos pulmões saudáveis, com COVID-19 e não COVID, respectivamente.

As imagens carregadas por classes apresentaram algumas radiografias com posicionamentos diferentes, contendo rotações, deslocamentos, diminuições de tamanho, entre outros. Em todas as categorias atingiram medidas de desempenho relevantes para algumas

Figura 4.22 – Gráfico da classe não COVID com os resultados das medidas de desempenho de cada imagem de teste da MultiResUNet.



Fonte: Elaborada pelo autor.

dessas imagens, as quais exemplificam a flexibilidade da MultiResUNet em segmentações com posições diversificadas das radiografias. No entanto, nas imagens de COVID-19 e não COVID, percebe-se uma quantidade maior de falhas de similaridades nessas imagens quando comparado com as imagens saudáveis nos valores que ocorreram mais erros. As Figuras 4.16 e 4.19 exibem determinadas radiografias que as segmentações foram realizadas com falhas para as classes COVID-19 e não COVID, respectivamente.

4.3 – Comparativo entre as Redes Neurais Convolucionais

O processo de treinamento das CNNs foram cronometrados até a conclusão desta etapa. A Tabela 4.11 descreve esses períodos em tempo para cada modelo, e percebe-se que a UNet consumiu uma quantidade inferior em relação a MultiResUNet.

Tabela 4.11 – Duração dos treinamentos entre as redes neurais convolucionais.

CNN	Duração
UNet	34m
MultiResUNet	1h 36m

Nas previsões das 720 imagens de testes separadas por classe para as redes neurais, observa-se que a UNet manteve uma performance de tempo mais efetiva nas detecções quando comparada com a MultiResUNet. A Tabela 4.12 detalha o comparativo dessas informações.

Tabela 4.12 – Duração em segundos das previsões das redes neurais convolucionais nas imagens de testes por classe.

CNN	Classe	Duração
UNet	Saudáveis	12s
	Com COVID-19	11s
	Não COVID	11s
MultiResUNet	Saudáveis	19s
	Com COVID-19	
	Não COVID	

Como a MultiResUNet é um aprimoramento da UNet, algumas características foram implementadas com o intuito de melhorias da rede, dessa forma este pode ser um fator que contribui para a performance em tempo ser mais demorado.

Nos resultados das medidas de desempenho entre as classes por CNN, nota-se que a UNet obteve valores ligeiramente elevados que a MultiResUNet em todas as classes, com exceção da Não COVID. Contudo, a divergência das métricas obtidas dentre as categorias não foram significativas.

Tabela 4.13 – Média dos resultados das medidas de desempenho por rede neural convolucional.

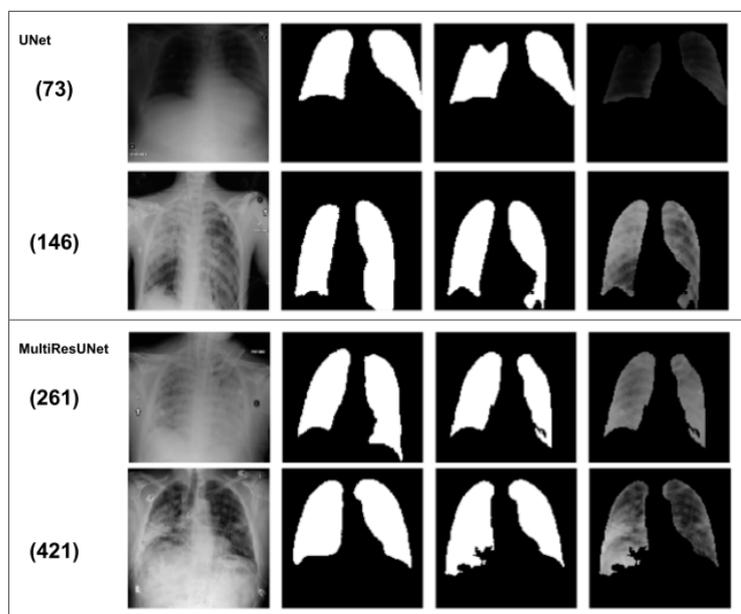
CNN	Classe	Índice de Jaccard	DSC
UNet	Saudáveis	96,05% ($\pm 2,49$)	97,96% ($\pm 1,35$)
	Com COVID-19	95,49% ($\pm 3,62$)	97,65% ($\pm 2,16$)
	Não COVID	91,35% ($\pm 5,43$)	95,39% ($\pm 3,17$)
MultiResUNet	Saudáveis	95,71% ($\pm 2,50$)	97,79% ($\pm 1,36$)
	Com COVID-19	95,37% ($\pm 3,69$)	97,59% ($\pm 2,20$)
	Não COVID	91,39% ($\pm 4,90$)	95,42% ($\pm 2,85$)

Observa-se que para UNet e a MultiResUNet, os valores das medidas do Não COVID foram consideravelmente inferiores em relação a saudável e COVID-19. Desse modo, as imagens do Não COVID foram analisadas detalhadamente para melhorar o entendimento dos resultados, uma vez que as imagens do COVID-19 também possuía características de patologias.

Na verificação da classe não COVID algumas radiografias com leves infecções da patologia dificultaram a identificação das regiões dos pulmões, assim como determinadas

oscilações no contraste das imagens. A Figura 4.23 demonstra alguns exemplos desses cenários que geraram falhas nas segmentações.

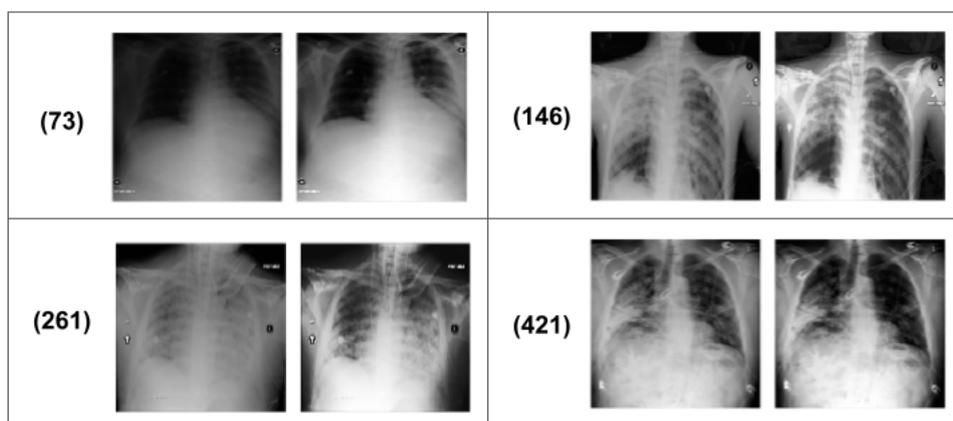
Figura 4.23 – Imagens dos pulmões não COVID de número (146), (261) e (421) com infecções nas regiões dos pulmões, bem como a imagem (73) com baixo contraste, que resultaram em baixas medidas de desempenho.



Fonte: Elaborada pelo autor.

A Figura 4.24 apresenta as imagens (146), (261) e (421) com infecções pulmonares e a imagem (73) com baixo contraste, e ao lado as mesmas aplicadas a equalização com o intuito de mitigar a infecção e aprimorar a visibilidade das radiografias com alto ou baixo contraste.

Figura 4.24 – Imagens dos pulmões não COVID de número (146), (261) e (421) com infecções nas regiões dos pulmões e suas equalizações, bem como a imagem (73) com baixo contraste e sua equalização.

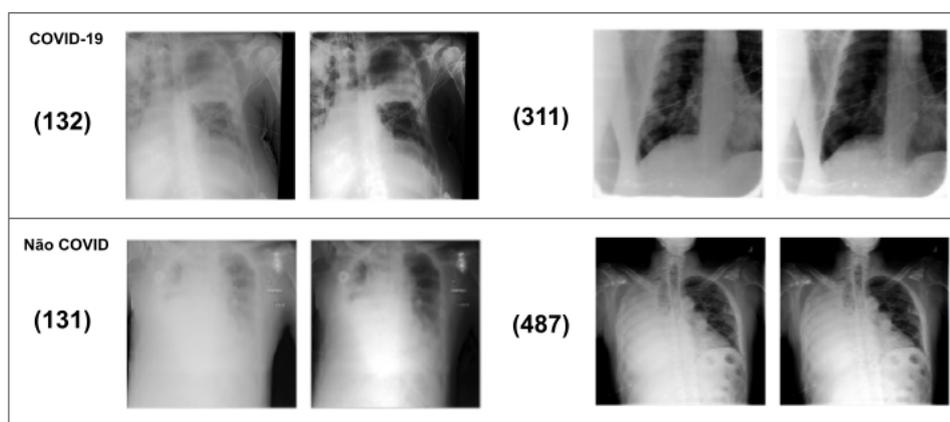


Fonte: Elaborada pelo autor.

A Figura 4.25 ilustra determinadas radiografias que as CNNs obtiveram dificuldades em efetivar as segmentações, devido as regiões pulmonares estarem consideravelmente danificadas.

Nesses casos, nota-se que as imagens do COVID-19 (132) e a (311) estão com regiões dos pulmões ocultados, os quais podem afetar nas segmentações dos modelos, uma vez que um dos pulmões não estão íntegros. Além disso, as imagens do não COVID (131) e a (487) apresentaram uma quantia elevada de infecções nas regiões pulmonares, tais quais não alcançaram melhorias ao ser aplicado a equalização.

Figura 4.25 – Imagens dos pulmões do COVID-19 de números (132) e (311) com parte dos pulmões ocultados e radiografias do não COVID de números (131) e (487) com alta infecção nas regiões dos pulmões.



Fonte: Elaborada pelo autor.

Dessa maneira, na análise para otimizar o desempenho do modelo, foi efetuado a equalização como pré-processamento em um novo treinamento para cada CNN, com o objetivo de diminuir as dificuldades em distinguir os pulmões para as radiografias com leves infecções e variações de contraste.

4.4 – Segmentações das Redes Neurais com Equalização

Esta seção tem o objetivo de descrever a análise realizada nas CNNs, as quais foram executadas com um passo adicional de equalização como pré-processamento antes da efetivação do treinamento. De modo similar ao estudo do treinamento sem a equalização, é examinado a duração do treinamento, o período das identificações das máscaras nas imagens de teste, os valores das medidas de desempenho e uma análise visual dos resultados.

Nas demais CNNs, percebe-se que o modelo UNet efetuou o treinamento em aproximadamente 35 minutos, tornando-se um valor significativo em relação a quantidade de tempo gasto pela MultiResUNet. A Tabela 4.14 descreve essas informações.

Tabela 4.14 – Duração dos treinamentos entre as redes neurais convolucionais treinadas com equalização.

CNN	Duração
UNet	35m
MultiResUNet	1h 38m

Na duração em tempo durante as previsões nas 720 imagens de testes, as redes não obtiveram uma diferença significativa entre as classes, no entanto entre os modelos, a UNet atingiu um resultado melhor quando se comparado com a MultiResUNet, conforme detalha a Tabela 4.15.

Tabela 4.15 – Duração em segundos das previsões das redes neurais convolucionais treinadas com equalização nas imagens de testes por classe.

CNN	Classe	Duração
UNet	Saudáveis	12s
	Com COVID-19	11s
	Não COVID	12s
MultiResUNet	Saudáveis	19s
	Com COVID-19	20s
	Não COVID	19s

Nas medidas de desempenho, conforme a Tabela 4.16, nota-se que a UNet e a MultiResUNet alcançaram resultados satisfatórios para as classes saudáveis e com COVID-19, bem como a diferença dos valores dessas categorias entre as redes não foram significativas. Contudo, o Não COVID para ambos os modelos obtiveram resultados inferiores em relação as outras classes, além de que a diferença da MultiResUNet para UNet para essa categoria, foi maior quando se comparado com a divergência das demais classes.

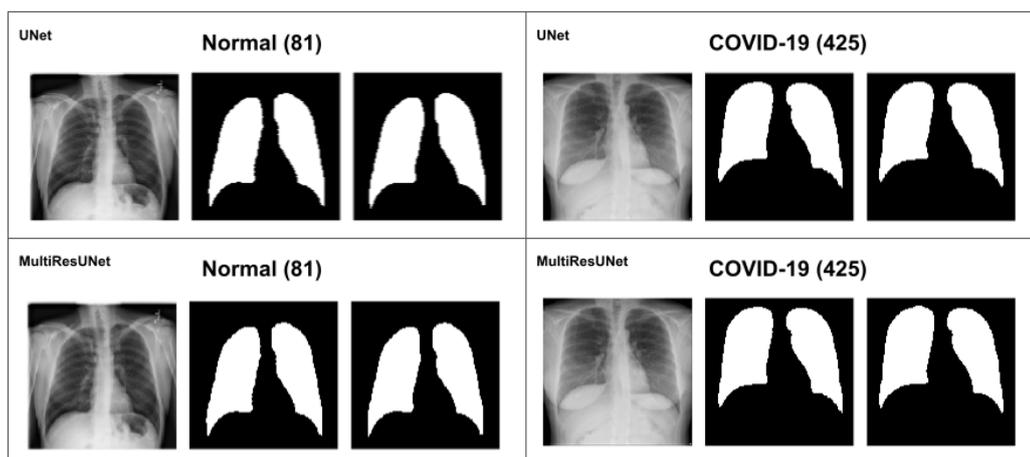
Tabela 4.16 – Média dos resultados das medidas de desempenho por rede neural convolucional treinadas com equalização.

CNN	Classe	Índice de Jaccard	DSC
UNet	Saudáveis	95,67% ($\pm 2,53$)	97,77% ($\pm 1,38$)
	Com COVID-19	94,37% ($\pm 4,33$)	97,04% ($\pm 2,61$)
	Não COVID	89,95% ($\pm 6,40$)	94,57% ($\pm 3,87$)
MultiResUNet	Saudáveis	95,59% ($\pm 2,61$)	97,72% ($\pm 1,43$)
	Com COVID-19	94,80% ($\pm 3,92$)	97,28% ($\pm 2,27$)
	Não COVID	91,14% ($\pm 5,12$)	95,28% ($\pm 3,03$)

4.4.1 – Análise das imagens saudáveis e COVID-19

A Figura 4.26 demonstra algumas radiografias que obtiveram medidas de desempenho satisfatórias para as classes saudável e COVID-19. Observa-se que para ambas as classes e categorias as máscaras geradas são similares às máscaras originais.

Figura 4.26 – Imagens dos pulmões saudáveis e COVID-19 de número (81) e (425) que obtiveram valores satisfatórios nas previsões por modelos treinado com equalização.



Fonte: Elaborada pelo autor.

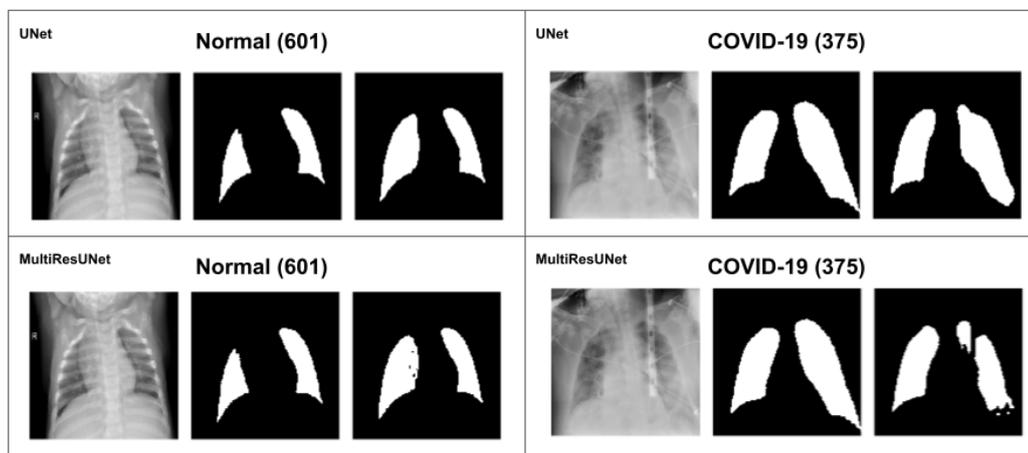
Nas imagens saudáveis, a imagem (81) na UNet atingiu o Índice de Jaccard de 98,34% e o DSC de 99,17% e a imagem (81) na MultiResUNet com Índice de Jaccard de 98,04% e o DSC de 99,01%. Nas radiografias da COVID-19, a imagem (425) na UNet alcançou um Índice de Jaccard de 98,26% e o DSC de 99,12% e a imagem (425) na MultiResUNet com Índice de Jaccard de 98,19% e o DSC de 99,09%.

A Figura 4.27 apresenta determinadas radiografias que geraram falhas nas segmentações. Percebe-se que para ambas as redes identificaram localidades que não eram pulmões no pulmão direito das imagens saudáveis, e nas imagens de COVID-19 para a região pulmonar esquerda as CNNs não segmentaram corretamente.

Nas imagens saudáveis, a imagem (601) na UNet obteve Índice de Jaccard de 73,43% e o DSC de 84,68%, e a imagem (601) na MultiResUNet com Índice de Jaccard de 72,52% e o DSC de 84,07%. Nas radiografias do COVID-19, a imagem (375) na UNet atingiu um Índice de Jaccard de 85,51% e o DSC de 92,19%, e a imagem (375) na MultiResUNet com Índice de Jaccard de 73,64% e o DSC de 84,82%.

A Figura 4.28 ilustra uma das imagens com posição diferente, a qual está deslocada para a esquerda, o que oculta a região do pulmão direito. Nota-se que a omissão deste pulmão

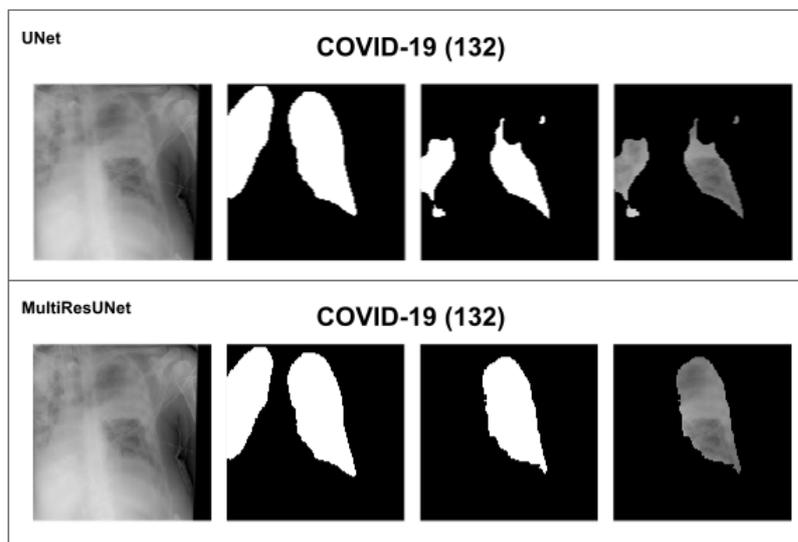
Figura 4.27 – Imagens dos pulmões saudáveis e COVID-19 de números (601) e (375) que obtiveram falhas nas previsões por modelos treinado com equalização.



Fonte: Elaborada pelo autor.

dificulta as segmentações das redes. Contudo, a MultiResUNet pra esse caso em específico identificou o pulmão esquerdo, enquanto que a UNet gerou com falhas.

Figura 4.28 – Imagens dos pulmões de COVID-19 de número (132) com posicionamento diferente que obtiveram falhas nas previsões por modelos treinado com equalização.



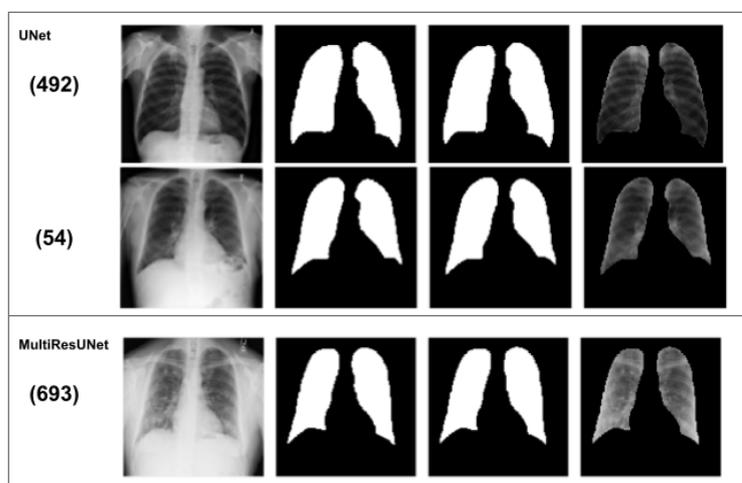
Fonte: Elaborada pelo autor.

Na categoria COVID-19, a imagem (132) na UNet alcançou um Índice de Jaccard de 41,09% e o DSC de 58,25%, e a imagem (132) na MultiResUNet resultou um Índice de Jaccard de 52,78% e o DSC de 69,09%.

4.4.2 – Análise das imagens não COVID

A Figura 4.29 demonstra exemplos de radiografias para cada CNN que atingiram valores satisfatórios nas medidas de desempenho, nota-se que as máscaras geradas são semelhantes as máscaras originais. A imagem (492) da UNet alcançou o Índice de Jaccard de 98,45% e o DSC de 99,22%, a imagem (54) da UNet resultou o Índice de Jaccard de 98,26% e o DSC de 99,12%, e a imagem (693) na MultiResUNet com o Índice de Jaccard de 98,40% e o DSC de 99,20%.

Figura 4.29 – Imagens dos pulmões não COVID de número (492), (54) e (693) que obtiveram valores satisfatórios nas previsões por modelos treinados com equalização.

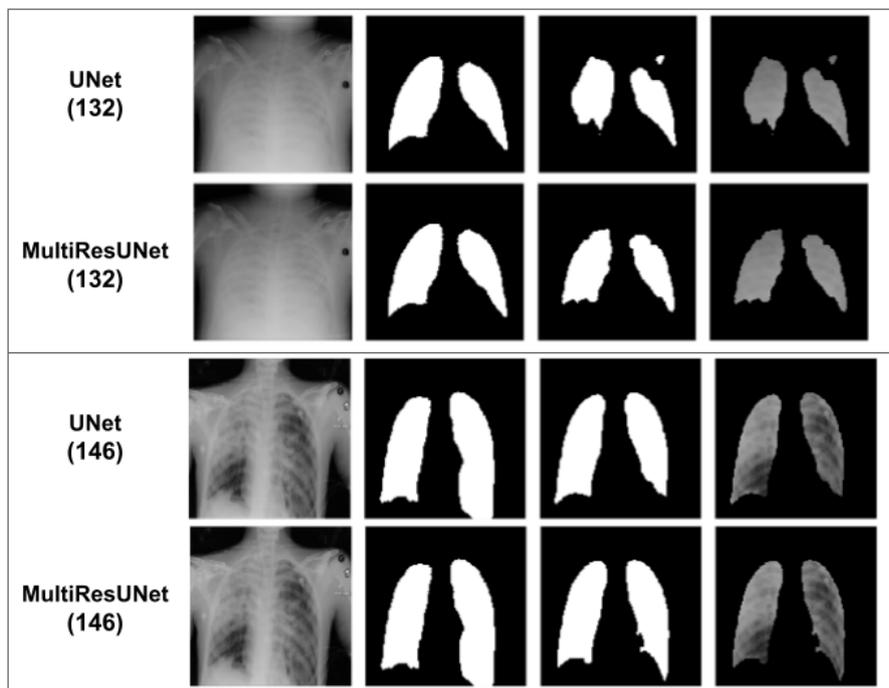


Fonte: Elaborada pelo autor.

A Figura 4.30 apresenta determinadas radiografias que falharam nas segmentações para cada modelo. A imagem (132) da UNet, com Índice de Jaccard de 68,57% e o DSC de 81,36%, e a imagem (132) da MultiResUNet, com Índice de Jaccard de 79,26% e o DSC de 88,43%, não segmentou os pulmões completamente, além de que a imagem (132) da UNet identificou como pulmão, localidade externa aos mesmos. A imagem (146) da UNet, com Índice de Jaccard de 78,67% e o DSC de 88,06%, e a imagem (146) da MultiResUNet, com Índice de Jaccard de 81,15% e o DSC de 89,59%, detectou erroneamente a região pulmonar esquerda.

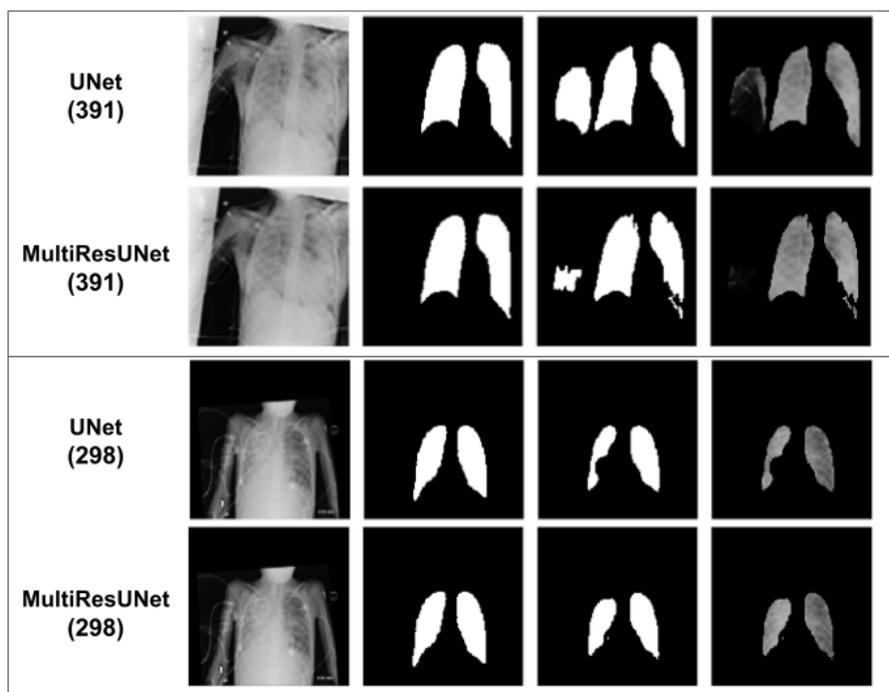
A Figura 4.31 ilustra algumas radiografias com posições diferentes, em que as segmentações de cada CNN resultaram em valores baixos nas medidas. A imagem (391) da UNet, com Índice de Jaccard de 61,83% e o DSC de 76,41%, e a imagem (391) da MultiResUNet, com Índice de Jaccard de 80,29% e o DSC de 89,07%, além de detectar as regiões dos pulmões com falhas, também identificaram regiões pulmonares isolados dos mesmos.

Figura 4.30 – Imagens dos pulmões não COVID de número (132) e (146) que obtiveram falhas nas previsões por modelos treinado com equalização.



Fonte: Elaborada pelo autor.

Figura 4.31 – Imagens dos pulmões não COVID de número (391) e (298) com posicionamentos diferentes que obtiveram falhas nas previsões por modelos treinado com equalização.



Fonte: Elaborada pelo autor.

Observa-se na Figura 4.31, a imagem (298) da UNet, com Índice de Jaccard de 70,07% e o DSC de 82,40%, e a imagem (298) da MultiResUNet, com Índice de Jaccard de 76,41% e o DSC de 86,62%, não segmentaram as regiões pulmonares por completo.

4.5 – Comparativo dos Modelos Treinados com Equalização

Esta seção tem o objetivo de detalhar o comparativo entre o treinamento com pré-processamento de equalização das imagens com o treinamento sem a efetivação deste procedimento. Desse modo, a análise ocorre no desempenho de tempo da duração do treinamento do modelo e da previsão nas imagens de testes, estudos sobre os resultados das medidas de desempenho e examinação visual das segmentações.

A Tabela 4.17 informa o período até a finalização dos treinamentos dos modelos para ambos os cenários. Observa-se que a diferença da duração dos treinamentos não foram significativas, entretanto a UNet e a MultiResUNet do treinamento sem equalização, executaram em um tempo reduzido que os mesmos treinado com o pré-processamento da equalização.

Tabela 4.17 – Duração dos treinamentos entre as redes neurais convolucionais para os cenários com e sem equalização.

Treinamento sem equalização		Treinamento com equalização	
CNN	Duração	CNN	Duração
UNet	34m	UNet	35m
MultiResUNet	1h 36m	MultiResUNet	1h 38m

A Tabela 4.18 descreve as previsões nas imagens de testes para os cenários dos treinamentos sem e com equalização. Nota-se que a divergência entre os modelos pelos os cenários dos treinamentos não foram expressivos.

A Tabela 4.19 apresenta os valores das medidas de desempenho para os treinamentos sem pré-processamento da equalização e com a efetivação da equalização. Percebe-se que para as classes Saudáveis e COVID-19 obtiveram valores satisfatórios, e a diferença entre os resultados dos modelos não foram significativos, todavia esperava-se que os resultados para estas categorias ao menos permanecessem elevados.

O pré-processamento da equalização anteriormente ao treinamento, tem o intuito de otimizar os resultados das métricas principalmente para a classe Não COVID, entretanto para a UNet e a MultiResUNet não resultou em melhorias nas segmentações. Além disso, percebe-se que para a CNN UNet foi obtido uma diferença maior para esta categoria quando comparado a MultiResUNet.

As Figuras 4.32, 4.33 e 4.34 demonstram alguns exemplos da segmentações, comparando-as pelos cenários do treinamento sem e com equalização. A Figura 4.32 apresenta radiografias com medidas de desempenho satisfatórias, a Figura 4.33 ilustra imagens com

Tabela 4.18 – Duração em segundos das previsões entre as redes neurais convolucionais nas imagens de testes por classe para os cenários com e sem equalização.

Treinamento sem equalização		
CNN	Classe	Duração
UNet	Saudáveis	12s
	Com COVID-19	11s
	Não COVID	11s
MultiResUNet	Saudáveis	19s
	Com COVID-19	
	Não COVID	
Treinamento com equalização		
CNN	Classe	Duração
UNet	Saudáveis	12s
	Com COVID-19	11s
	Não COVID	12s
MultiResUNet	Saudáveis	19s
	Com COVID-19	20s
	Não COVID	19s

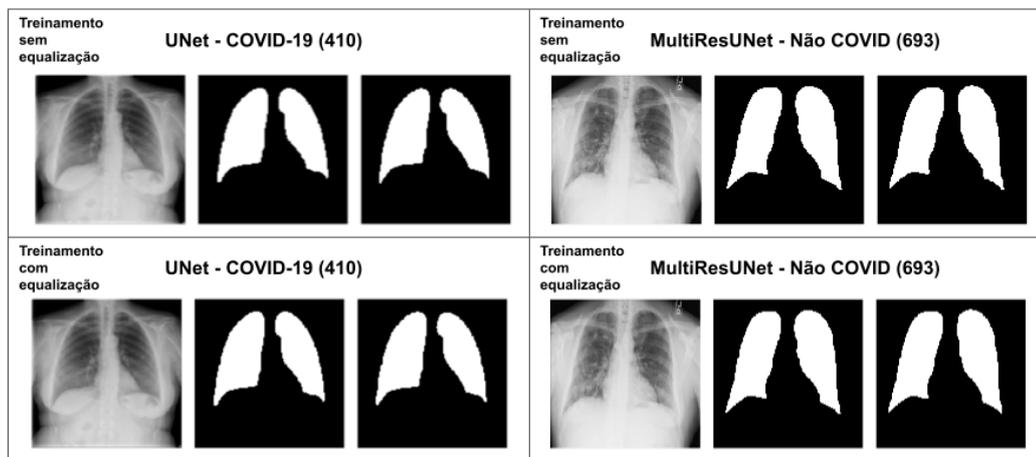
Tabela 4.19 – Média dos resultados das medidas de desempenho por redes neurais convolucionais nas imagens de testes por classe para os cenários com e sem equalização.

Treinamento sem equalização			
CNN	Classe	Índice de Jaccard	DSC
UNet	Saudáveis	96,05% ($\pm 2,49$)	97,96% ($\pm 1,35$)
	Com COVID-19	95,49% ($\pm 3,62$)	97,65% ($\pm 2,16$)
	Não COVID	91,35% ($\pm 5,43$)	95,39% ($\pm 3,17$)
MultiResUNet	Saudáveis	95,71% ($\pm 2,50$)	97,79% ($\pm 1,36$)
	Com COVID-19	95,37% ($\pm 3,69$)	97,59% ($\pm 2,20$)
	Não COVID	91,39% ($\pm 4,90$)	95,42% ($\pm 2,85$)
Treinamento com equalização			
CNN	Classe	Índice de Jaccard	DSC
UNet	Saudáveis	95,67% ($\pm 2,53$)	97,77% ($\pm 1,38$)
	Com COVID-19	94,37% ($\pm 4,33$)	97,04% ($\pm 2,61$)
	Não COVID	89,95% ($\pm 6,40$)	94,57% ($\pm 3,87$)
MultiResUNet	Saudáveis	95,59% ($\pm 2,61$)	97,72% ($\pm 1,43$)
	Com COVID-19	94,80% ($\pm 3,92$)	97,28% ($\pm 2,27$)
	Não COVID	91,14% ($\pm 5,12$)	95,28% ($\pm 3,03$)

falhas nas segmentações e a 4.34 demonstra radiografias com posições diferentes com erros nas detecções.

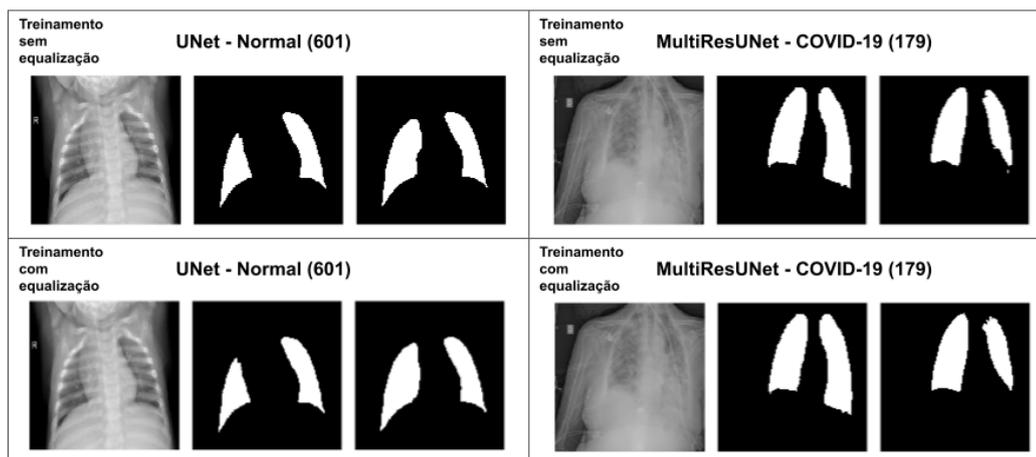
As Figuras 4.33 e 4.34 ilustram determinadas radiografias com falhas nas segmentações, com intuito de exemplificar a ocorrência dos erros nas identificações dos pulmões para ambos os cenários dos treinamentos com pré-processamento da equalização e sem o procedimento.

Figura 4.32 – Comparativo dos resultados satisfatórios dos treinamentos sem e com equalização das redes neurais UNet e MultiResUNet das classes COVID-19 e Não COVID.



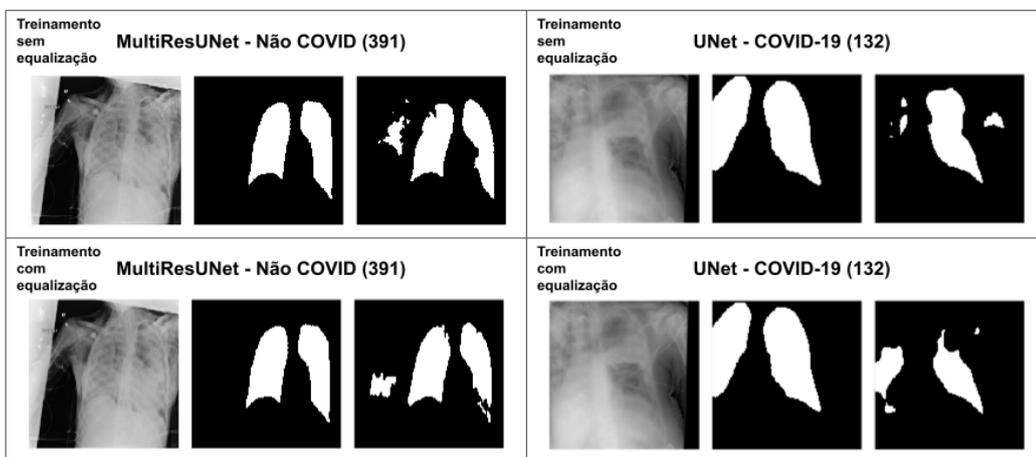
Fonte: Elaborada pelo autor.

Figura 4.33 – Comparativo dos resultados com falhas dos treinamentos sem e com equalização das redes neurais UNet e MultiResUNet das classes Normal e COVID-19.



Fonte: Elaborada pelo autor.

Figura 4.34 – Comparativo dos resultados com falhas e diferentes posições dos treinamentos sem e com equalização das redes neurais UNet e MultiResUNet das classes Não COVID e COVID-19.



Fonte: Elaborada pelo autor.

Esta pesquisa tem o intuito de realizar um comparativo da performance entre as redes neurais convolucionais UNet e MultiResUNet, na segmentação das regiões pulmonares em radiografias de tórax saudáveis, com COVID-19 e não COVID, considerando o período para efetivação do treinamento dos modelos, duração para as previsões nas imagens de testes e as medidas de desempenho, para os cenários de treinamento com e sem pré-processamento.

No período de execução dos treinamentos e das identificações das máscaras nas imagens de testes, a UNet obteve uma performance melhor ao comparada com a MultiResUNet, tanto para os cenários sem e com equalização. Em relação ao desempenho de cada CNN entre as categorias e cenários com pré-processamento ambas as redes obtiveram resultados similares.

Na análise efetuada para as classes utilizadas, as redes neurais convolucionais atingiram resultados satisfatórios nas medidas de desempenho de Índice de Jaccard e Coeficiente Dice, entretanto a categoria não COVID apresentou mais dificuldades nos resultados das segmentações.

A efetivação de novos treinamentos para cada rede aplicando uma equalização como pré-processamento tinha o objetivo de aprimorar as métricas obtidas da classe não COVID, uma vez que as infecções moderadas da patologia e a oscilação do contraste dificultavam a visibilidade dos pulmões. Contudo, a efetivação da equalização não resultaram em diferenças relevantes, com exceção do valor inferior de 89,95% da UNet na medida de desempenho do Índice de Jaccard.

Percebeu-se que a UNet apresentou mais eficiência no contexto de segmentação dos pulmões em radiografias de tórax, visto que seus resultados também foram expressivos. Em relação ao tempo de processamento os treinamentos e detecções das máscaras ocorreram em um tempo inferior ao da MultiResUNet.

A média dos resultados apresentados por classes da UNet com 94,29% pro Índice de Jaccard e 97,00% pro DSC e a MultiResUNet com 94,15% pro Índice de Jaccard e 96,93%

pro DSC sem equalização obteve medidas de desempenho semelhantes em relação as CNNs utilizadas nas pesquisas de Costa *et al.* (2021) e Rahman *et al.* (2021).

Como trabalhos futuros poderão ser acrescentados outras redes neurais convolucionais para agregar conhecimento ao comparativo das redes, encontrar radiografias e suas respectivas máscaras dos pulmões com outros tipos de infecções para aumentar a variedade das características de patologias nas regiões pulmonares, continuar as análises nos resultados para identificar pré-processamentos que otimizem a performance dos modelos e utilizar as imagens separadas de forma aleatória com todas as classes durante o treinamento para testes em comparativo com as divididas por categorias.

Artigos Publicados

1. FARIAS, R. S.; OLIVEIRA, K. R. S.; REGIS, C. D. M.; COSTA, C. M.; SEIXAS, J. M. Redes Neurais Convolucionais para Classificação da COVID-19 em Imagens de Raio-x de Tórax. In: Congresso Brasileiro de Inteligência Computacional, 2021, Joinville, SC. Anais do 15. Congresso Brasileiro de Inteligência Computacional, 2021. p. 1.
2. COSTA, C. M.; SEIXAS, J. M.; GUTFILEN, B.; SOUZA, S. A. L.; OLIVEIRA, S. M.; REGIS, C. D. M.; FARIAS, R. S.; OLIVEIRA, K. R. S. Apoio para Triagem da Infecção por COVID-19 Através de Aprendizagem Profunda Sobre Imagens Segmentadas de Raio-X do Tórax. In: Congresso Brasileiro de Inteligência Computacional, 2021, Joinville, SC. Anais do 15. Congresso Brasileiro de Inteligência Computacional. p. 1.

Referências Bibliográficas

- Avci, Onur, Abdeljaber, Osama, Kiranyaz, Serkan, Hussein, Mohammed, Gabbouj, Moncef, & Inman, Daniel J. 2021. A review of vibration-based damage detection in civil structures: From traditional methods to Machine Learning and Deep Learning applications. *Mechanical systems and signal processing*, **147**, 107077.
- Chen, Lijia, Chen, Pingping, & Lin, Zhijian. 2020. Artificial intelligence in education: A review. *Ieee Access*, **8**, 75264–75278.
- Chiarello, Flávio, Steiner, Maria Teresinha Arns, Oliveira, Edilson Batista de, Arce, Júlio Eduardo, & Ferreira, Júlio César. 2019. ARTIFICIAL NEURAL NETWORKS APPLIED IN FOREST BIOMETRICS AND MODELING: STATE OF THE ART (JANUARY/2007 TO JULY/2018).
- Chouhan, Vikash, Singh, Sanjay Kumar, Khamparia, Aditya, Gupta, Deepak, Tiwari, Prayag, Moreira, Catarina, Damaševičius, Robertas, & De Albuquerque, Victor Hugo C. 2020. A novel transfer learning based approach for pneumonia detection in chest X-ray images. *Applied Sciences*, **10**(2), 559.
- Costa, Cecília, Seixas, José, Gutflen, Bianca, Souza, Sérgio, Medeiros, Susie, Regis, Carlos, Farias, Ricardo, & Oliveira., Kaique. 2021. Apoio para Triagem da Infecção por COVID-19 Através de Aprendizagem Profunda Sobre Imagens Segmentadas de Raio-X do Tórax. *Pages 1–7 of: Anais do 15 Congresso Brasileiro de Inteligência Computacional*. Joinville, SC: SBIC.
- Degerli, Aysen, Ahishali, Mete, Yamac, Mehmet, Kiranyaz, Serkan, Chowdhury, Muhammad EH, Hameed, Khalid, Hamid, Tahir, Mazhar, Rashid, & Gabbouj, Moncef. 2021. COVID-19 infection map generation and detection from chest X-ray images. *Health information science and systems*, **9**(1), 1–16.

- Dutta, Kaushik. 2021. Densely Connected Recurrent Residual (Dense R2UNet) Convolutional Neural Network for Segmentation of Lung CT Images. *arXiv preprint arXiv:2102.00663*.
- Farheen, Farhanaz, Shamil, Md, Ibte haz, Nabil, Rahman, M Sohel, *et al.* 2021. Segmentation of Lung Tumor from CT Images using Deep Supervision. *arXiv preprint arXiv:2111.09262*.
- Ferreira, Felipe Piana Vendramell, Shamass, Rabee, Limbachiya, Vireen, Tsavdaridis, Konstantinos Daniel, & Martins, Carlos Humberto. 2022. Lateral-torsional buckling resistance prediction model for steel cellular beams generated by Artificial Neural Networks (ANN). *Thin-Walled Structures*, **170**, 108592.
- Gagliano, Antonella, Puligheddu, Monica, Ronzano, Nadia, Congiu, Patrizia, Tanca, Marcello Giuseppe, Cursio, Ida, Carucci, Sara, Sotgiu, Stefano, Grossi, Enzo, & Zuddas, Alessandro. 2021. Artificial neural networks analysis of polysomnographic and clinical features in Pediatric Acute-Onset Neuropsychiatric Syndrome (PANS): from sleep alteration to “Brain Fog”. *Nature and Science of Sleep*, **13**, 1209.
- Gerard, Sarah E, Herrmann, Jacob, Xin, Yi, Martin, Kevin T, Rezoagli, Emanuele, Ippolito, Davide, Bellani, Giacomo, Cereda, Maurizio, Guo, Junfeng, Hoffman, Eric A, *et al.* 2021. CT image segmentation for inflamed and fibrotic lungs using a multi-resolution convolutional neural network. *Scientific reports*, **11**(1), 1–12.
- Hasan, Dathar Abas, & Abdulazeez, Adnan Mohsin. 2020. A modified convolutional neural networks model for medical image segmentation. *learning*, **20**, 22.
- Ibte haz, Nabil, & Rahman, M. Sohel. 2020. MultiResUNet : Rethinking the U-Net architecture for multimodal biomedical image segmentation. *Neural networks*, **121**, 74–87.
- Jacobi, Adam, Chung, Michael, Bernheim, Adam, & Eber, Corey. 2020. Portable chest X-ray in coronavirus disease-19 (COVID-19): A pictorial review. *Clinical imaging*, **64**, 35–42.
- Kakhki, Roya Mohammadzadeh, Mohammadpoor, Mojtaba, Faridi, Reza, & Bahadori, Mehdi. 2020. The development of an artificial neural network–genetic algorithm model (ANN-GA) for the adsorption and photocatalysis of methylene blue on a novel sulfur–nitrogen co-doped Fe₂O₃ nanostructure surface. *RSC Advances*, **10**(10), 5951–5960.
- Khan, Wasif, Zaki, Nazar, & Ali, Luqman. 2021. Intelligent pneumonia identification from chest x-rays: A systematic literature review. *IEEE Access*.

- Kim, Minki, & Lee, Byoung-Dai. 2021. Automatic lung segmentation on chest X-rays using self-attention deep neural network. *Sensors*, **21**(2), 369.
- Kundu, Rohit, Das, Ritacheta, Geem, Zong Woo, Han, Gi-Tae, & Sarkar, Ram. 2021. Pneumonia detection in chest X-ray images using an ensemble of deep learning models. *PloS one*, **16**(9), e0256630.
- Lee, Gwanghee, & Jhang, Kyoungson. 2021. Neural Network Analysis for Microplastic Segmentation. *Sensors*, **21**(21), 7030.
- Maiello, Lorenzo, Ball, Lorenzo, Micali, Marco, Iannuzzi, Francesca, Scherf, Nico, Hoffmann, Ralf-Thorsten, Gama de Abreu, Marcelo, Pelosi, Paolo, & Huhle, Robert. 2022. Automatic lung segmentation and quantification of aeration in computed tomography of the chest using 3D transfer learning. *Frontiers in physiology*, 2508.
- Massucato. 2018. *Deep Learning - Unet Model*. <https://github.com/massucattoj/unet-model>. Acessado em 04/06/2021.
- Olowononi, Felix O, Rawat, Danda B, & Liu, Chunmei. 2021. Resilient Machine Learning for Networked Cyber Physical Systems: A Survey for Machine Learning Security to Securing Machine Learning for CPS. *IEEE Communications surveys and tutorials*, **23**(1), 524–552.
- OMS. 2022. *Painel da OMS sobre o coronavírus (COVID-19)*. <https://covid19.who.int/>. Acessado em 07/05/2022.
- Rahimzadeh, Mohammad, & Attar, Abolfazl. 2020. A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2. *Informatics in medicine unlocked*, **19**, 100360.
- Rahman, Tawsifur, Khandakar, Amith, Qiblawey, Yazan, Tahir, Anas, Kiranyaz, Serkan, Kashem, Saad Bin Abul, Islam, Mohammad Tariqul, Al Maadeed, Somaya, Zughaier, Susu M, Khan, Muhammad Salman, *et al.* 2021. Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in biology and medicine*, **132**, 104319.
- Rajah, Jayant, & Lee, Joanna. 2021. CSF rhinorrhoea post COVID-19 swab: A case report and review of literature. *Journal of Clinical Neuroscience*, **86**, 6–9.

- Ronneberger, Olaf, Fischer, Philipp, & Brox, Thomas. 2015. U-net: Convolutional networks for biomedical image segmentation. *Pages 234–241 of: International Conference on Medical image computing and computer-assisted intervention*. Springer.
- Rousan, Liqa A, Elobeid, Eyhab, Karrar, Musaab, & Khader, Yousef. 2020. Chest x-ray findings and temporal lung changes in patients with COVID-19 pneumonia. *BMC Pulmonary Medicine*, **20**(1), 1–9.
- Sessa, Maurizio, Khan, Abdul Rauf, Liang, David, Andersen, Morten, & Kulahci, Murat. 2020. Artificial Intelligence in Pharmacoepidemiology: A Systematic Review. Part 1—Overview of Knowledge Discovery Techniques in Artificial Intelligence. *Frontiers in pharmacology*, **11**, 1028–1028.
- Tahir, Anas M. 2022. *COVID-QU-Ex*. <https://www.kaggle.com/datasets/anasmohammedtahir/covidqu>. Acessado em 01/03/2022.
- Tahir, Anas M, Chowdhury, Muhammad EH, Khandakar, Amith, Rahman, Tawsifur, Qiblawey, Yazan, Khurshid, Uzair, Kiranyaz, Serkan, Ibtehaz, Nabil, Rahman, M Sohel, Al-Maadeed, Somaya, *et al.* 2021. COVID-19 infection localization and severity grading from chest X-ray images. *Computers in biology and medicine*, **139**, 105002.
- Yan, Qingsen, Wang, Bo, Gong, Dong, Luo, Chuan, Zhao, Wei, Shen, Jianhu, Shi, Qinfeng, Jin, Shuo, Zhang, Liang, & You, Zheng. 2020. COVID-19 chest CT image segmentation—a deep convolutional neural network solution. *arXiv preprint arXiv:2004.10987*.
- Yang, Qi, Li, Yunke, Zhang, Mengyi, Wang, Tian, Yan, Fei, & Xie, Chao. 2020. Automatic Segmentation of COVID-19 CT Images using improved MultiResUNet. *Pages 1614–1618 of: 2020 Chinese Automation Congress (CAC)*. IEEE.
- Zhu, Jinhan, Zhang, Jun, Qiu, Bo, Liu, Yimei, Liu, Xiaowei, & Chen, Lixin. 2019. Comparison of the automatic segmentation of multiple organs at risk in CT images of lung cancer between deep convolutional neural network-based and atlas-based techniques. *Acta Oncologica*, **58**(2), 257–264.
-