MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE CIÊNCIAS DA SAÚDE DE PORTO ALEGRE
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM TECNOLOGIAS DA INFORMAÇÃO E GESTÃO EM SAÚDE

Nouara Cândida Xavier

CovNet-UFCSPA: Uma Arquitetura Baseada em Rede Neural Convolucional para Auxílio ao Diagnóstico de Pneumonia Induzida pela COVID-19

Porto Alegre
2022

Nouara Cândida Xavier

CovNet-UFCSPA: Uma Arquitetura Baseada em Rede Neural Convolucional para Auxílio ao Diagnóstico de Pneumonia Induzida pela COVID-19

Dissertação no Programa de Mestrado Acadêmico em Tecnologias da Informação e Gestão em Saúde da Universidade Federal de Ciências da Saúde de Porto Alegre.

Orientador: Prof. Dra. Carla Diniz Lopes Becker

Co-Orientador: Prof. Dra. Thatiane Alves Pianoschi Alva

Porto Alegre

2022

Catalogação na Publicação

Xavier, Nouara
CovNet-UFCSPA: Uma Arquitetura Baseada em Rede Neural Convolucional para Auxílio ao Diagnóstico de Pneumonia Induzida pela COVID-19 / Nouara Xavier. -- 2022.
145 f. : 30 cm.

Dissertação (mestrado) -- Universidade Federal de Ciências da Saúde de Porto Alegre, Programa de Pós-Graduação em Tecnologias da Informação e Gestão em Saúde, 2022.

Orientador(a): Carla Becker ; coorientador(a): Thatiane Alva.

1. CNN. 2. COVID-19. I. Título.

Sistema de Geração de Ficha Catalográfica da UFCSPA com os dados fornecidos pelo(a) autor(a).

Nouara Cândida Xavier

CovNet-UFCSPA: Uma Arquitetura Baseada em Rede Neural Convolucional para Auxílio ao Diagnóstico de Pneumonia Induzida pela COVID-19

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Tecnologias da Informação e Gestão em Saúde da Universidade Federal de Ciências da Saúde de Porto Alegre como requisito parcial para a obtenção do título de Mestre em Tecnologia da Informação e Gestão em Saúde.

Orientador: Prof. Dra. Carla Diniz Lopes Becker

Co-orientador: Prof. Dra. Thatiane Alves Pianoschi Alva

Aprovada em: _____ de _____ de _____.

BANCA EXAMINADORA:

_____

Prof. Dr.
Universidade

_____

Prof. Dr.
Universidade

_____

Prof. Dr.
Universidade

Esta dissertação é dedicada a todo e qualquer ser humano que se considera mulher e que luta a árdua batalha da busca pela diversidade, equidade e respeito.

AGRADECIMENTOS

Agradeço primeiramente a Deus por até aqui ter me sustentado. Agradeço à minha orientadora Carla Becker e à co-orientadora Thatiane Alva por todo empenho, paciência e conhecimento cedidos. Ao professor Mirko Sánchez pela parceria com seu projeto no HCPA. Aos meus professores do PPGTIG que sempre me orientaram. Aos meus pais por todo suporte dado. Ao meus irmão Igor Xavier pelo ombro cedido nas horas difíceis. Agradeço aos meus amigos Adriano Martins, Carolina Ehlert, Laramila Sinimbu, Raíssa Mattos e Paulo Ricardo que me apoiaram nesta jornada. Ao meu colega e líder de trabalho Reinaldo Neto, que flexibilizou minha jornada para realização deste projeto.

Agradecimentos especiais são direcionados ao Hospital da Clínica de Porto Alegre da Universidade Federal do Rio Grande do Sul pela parceria cedida e ao Laboratório Nacional de Computação Científica pela alocação no supercomputador Santos Dumont.

RESUMO

A identificação rápida da COVID-19 em pacientes proporciona uma triagem adequada, podendo assim evitar o agravamento dos sintomas ocasionados pela doença. Esta pesquisa propõe a arquitetura CovNet-UFCSPA, composta por técnicas de pré-processamento de dados e CNN. Um total de 24 235 imagens foram utilizadas para treinamento, validação e teste do modelo. Técnicas de recorte, ECG e CLAHE foram utilizadas no pré-processamento das imagens. A arquitetura apresentou um *recall* DE 99% ao ser utilizada para classificar raios-x de paciente brasileiros do HCPA. A aplicação de CLAHE e retirada da região de interesse do raio-x trouxe uma melhoria na taxa de FN diminuindo de 187 para 9 os resultados de classificação do modelo. A arquitetura disponibilizou para os profissionais de saúde uma métrica de *score* e o mapa de calor das imagens testadas. Para análise de desempenho a arquitetura foi comparada com uma Resnet50 V2 e um Inception V3, os resultados demonstraram que a arquitetura CovNet-UFCSPA obteve as melhores taxas de FN e VP e o melhor *recall*.

Palavras-chaves: CNN; aprendizado de máquina profundo; pneumonia; COVID-19.

ABSTRACT

The rapid identification of COVID-19 in patients provides adequate screening, thus preventing the worsening of symptoms caused by the disease. This research proposes the CovNet-UFCSPA architecture, composed of data pre-processing and CNN techniques. A total of 24 235 images were used for training, validating, and testing the model. Cropping, ECG, and CLAHE techniques were used in the pre-processing of the images. The architecture presented a *recall* DE 99% when used to classify x-rays of Brazilian HCPA patients. The application of CLAHE and removal of the region of interest from the x-ray brought an improvement in the FN rate, decreasing the classification results of the model from 187 to 9. The architecture provided healthcare professionals with a *score* metric and a heat map of the tested images. For performance analysis, the architecture was compared with a Resnet50 V2 and an Inception V3, the results showed that the CovNet-UFCSPA architecture obtained the best FN and VP rates and the best *recall*

Keywords: CNN; machine learning; pneumonia; COVID-19.

LISTA DE FIGURAS

Figura 2.1 – Radiografia de tórax normal em PA e axial apontando as principais estruturas anatómicas identificáveis. AE – Átrio Esquerdo, VE – Ventrículo Esquerdo, AD – Átrio direito, LS – lobo superior, LM – lobo médio, LI – lobo inferior. 34
Figura 2.2 – Bronquiolite obliterante com pneumonia em organização. Corte axial na TC de alta resolução onde evidencia áreas de consolidação bilaterais com típica distribuição Peribrônquica. 35
Figura 2.3 – Pneumonia bacteriana no pulmão esquerdo, na forma de consolidação do espaço aéreo (seta). Com contornos mal definidos, algodonosos, e na distribuição segmentar. 35
Figura 2.4 – TC de secção fina transversal do toráx com padrão de vidro fosco em paciente com COVID-19. . . . 36
Figura 2.5 – Raio-X com opacidades em vidro fosco (seta preta) em paciente com COVID-19. 36
Figura 2.6 – Cenário básico de aprendizado com reforço. . . . 41
Figura 2.7 – Rede neurais simples x rede neurais profundas. . 42
Figura 2.8 – Representação de uma imagem em RGB. 44
Figura 2.9 – Representação de uma CNN com camada totalmente conectada. 46

Figura 4.1 – Exemplos csv gerado pelo script. 49
Figura 4.2 – Pré-processamento nas imagens HCPA 51
Figura 4.3 – Arquitetura CovNet-UFCSPA. 52
Figura 4.4 – Rede Pré-treinada. 53
Figura 4.5 – Matriz de confusão. 55
Figura 4.6 – Curva ROC do Ensaio I - tamanho do lote 1500. 56

Figura 5.1 – Composição dos dados do ensaio I. 59
Figura 5.2 – Desenho do Ensaio I. 61
Figura 5.3 – Composição dos dados do ensaio II e III. 63
Figura 5.4 – Desenho do ensaio II. 64
Figura 5.5 – Dados da etapa de teste. 65

Figura 5.6 – Desenho do ensaio III. 68
Figura 5.7 – Composição dos dados do ensaio IV. 69
Figura 5.8 – Desenho do ensaio IV. 70
Figura 5.9 – Histograma de raio-X com COVID-19 71

Figura 6.1 – Resultados do ensaio I 75
Figura 6.2 – Curva de acurácia segmentado por batch do ensaio I 76
Figura 6.3 – Curva de erro segmentado por batch do ensaio I . 77
Figura 6.4 – Curvas de acurácia e erro utilizando CovNet-UFCSPA com imagens de pacientes com COVID-19 do HCPA 79
Figura 6.5 – Mapa de calor - Caso I 83
Figura 6.6 – Mapa de calor - Caso II 84
Figura 6.7 – Mapa de calor - Caso III 85

LISTA DE TABELAS

Tabela 2.1 – Dados com padrões radiológicos de pacientes com pneumonia induzida pela COVID-19 37

Tabela 5.1 – Informações do Ensaio: Efeitos do Tamanho do Lote 61
Tabela 5.2 – Conjunto de dados 65
Tabela 5.3 – Informações do Ensaio: Arquitetura de CovNet-UFCSPA auxiliando no diagnóstico da COVID-19 de pacientes do HCPA 66
Tabela 5.4 – Informações do Ensaio: Arquitetura de CovNet-UFCSPA auxiliando no diagnóstico da COVID-19 de pacientes do HCPA 67
Tabela 5.5 – Informações do Ensaio: Identificação de casos com e sem COVID-19 72

Tabela 6.1 – Tabela de resultados Ensaio I Arquitetura CovNet-UFCSPA 78
Tabela 6.2 – Tabela de resultados Ensaio I Arquitetura CovNet-UFCSPA 80
Tabela 6.3 – Conjunto de dados 82
Tabela 6.4 – Tabela de resultados Ensaio III 87
Tabela 6.5 – Tabela de resultados Ensaio IV 89

LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizado de Máquina
AMP	Aprendizado de Máquina Profundo
CAD	Computer Aided Design
CLAHE	Contrast Limited Adaptive Histogram Equalization
CNN	Convolutional Neural Network
COVID-19	COrona Virus Disease
CPU	Central Processing Unit
DNA	Ácido Desoxirribonucleico
ECG	Equalização Global de Contraste
FN	Falso Negativo
FP	Falso Positivo
GPU	Graphics Processing Units
HCPA	Hospital de Clínicas de Porto Alegre
IA	Inteligência Artificial
IgC	Imunoglobulina C
IgM	Imunoglobulina M
OMS	Organização Mundial de Saúde
PA	Poster Anterior
PAC	Pneumonia Adquirida na Comunidade
PCR	Polimerase Chain Reaction
PPGTIG	Programa de Pós Graduação em Tecnologias da Informação e Gestão em Saúde

PV	Pneumonia Viral
RGB	Red, Green, Blue
ROC	Receiver Operator Characteristic Curve
RT-PCR	Reverse Transcription Polymerase Chain Reaction
SUS	Sistema Único de Saúde
TC	Tomografia Computadorizada
TPV	Trombose Venosa Profunda
UFCSPA	Universidade Federal de Ciências da Saúde de Porto Alegre
UFRG	Universidade Federal do Rio Grande do Sul
VF	Verdadeiro Negativo
VP	Verdadeiro Positivo

SUMÁRIO

1 INTRODUÇÃO 24
1.0.1 Justificativa 25
1.0.2 Objetivos 27
1.0.2.1 Objetivo Geral 27
1.0.2.2 Objetivos Específicos 27
1.0.3 Contribuições Esperadas 27
1.0.4 Estrutura do Documento 28

2 REFERENCIAL TEÓRICO 29
2.1 PNEUMONIA 29
2.1.1 Pneumonia Viral 30
2.1.1.1 Pneumonia Induzida pela COVID-19 31
2.1.2 Diagnóstico 31
2.2 PADRÃO RADIOLÓGICO DA PNEUMONIA . . 32
2.2.1 Padrões Radiológicos da Pneumonia Induzida pela COVID-19 34
2.3 APRENDIZADO DE MÁQUINA 39
2.3.1 Aprendizado de máquina 39
2.3.2 Rede Neurais 41
2.4 APRENDIZADO DE MÁQUINA PROFUNDO . 42
2.4.1 Sistemas de Aprendizagem Distribuída 43
2.4.2 Rede Neurais Convolucionais 43
2.4.2.1 Camada convolucional 45
2.4.2.2 Camada *pooling* 45
2.4.2.3 Camada totalmente conectada 45

3 TRABALHOS RELACIONADOS 47

4 MATERIAIS 48
4.1 AQUISIÇÃO DOS DADOS 48
4.2 PRÉ-PROCESSAMENTO DOS DADOS 48
4.2.1 Separação das imagens 49
4.2.2 Recorte 49
4.2.3 Redimensionamento 49

4.2.4 Equalização de contraste global 50
4.2.5 CLAHE 50
4.3 ARQUITETURAS 52
4.3.1 CovNet-UFCSPA 52
4.3.2 Redes pré-treinadas 52
4.4 SANTOS DUMONT 53
4.4.1 Múltiplas GPUs 54
4.5 ANÁLISE DE DESEMPENHO DA ARQUITETURA 54
4.6 MAPA DE CALOR 57

5 MÉTODOS 58
5.1 ENSAIOS 58
5.2 MÉTODOS DO ENSAIO I 58
5.2.1 Divisão dos dados 58
5.2.2 Procedimentos 59
5.3 MÉTODOS DO ENSAIO II 62
5.3.1 Divisão dos dados 62
5.3.2 Procedimentos 63
5.4 MÉTODOS DO ENSAIO III 66
5.4.1 Procedimentos 67
5.5 MÉTODOS DO ENSAIO IV: IDENTIFICAÇÃO DE CASOS COM E SEM COVID-19 68
5.5.1 Procedimentos 68

6 RESULTADOS E DISCUSSÃO 73
6.1 ENSAIO I: EFEITOS DO TAMANHO DO LOTE 73
6.1.1 Resultados 73
6.2 ENSAIO II: ARQUITETURA COVNET-UFCSPA AUXILIANDO NO DIAGNÓSTICO DA COVID-19 DOS PACIENTES DO HCPA 78
6.2.1 Resultados 78
6.2.1.1 Mapa de Calor 80
6.3 ENSAIO III: ANÁLISE COMPARATIVA DE REDES PRÉ-TREINADAS COM A ARQUITETURA COVNET-UFCSPA 86
6.3.1 Resultados 86

6.4 MÉTODOS DO ENSAIO IV: IDENTIFICAÇÃO DE CASOS COM E SEM COVID-19 87

7 CONCLUSÃO 90

Referências 95

APÊNDICE A – REVISÃO INTEGRATIVA 105

APÊNDICE B – PRE-PROCESSING.PY . 122

APÊNDICE C – SANTOS_DUMONT.PY 131

APÊNDICE D – HEATMAP.PY 133

ANEXO A – ANEXO A 137

ANEXO B – ANEXO B 143

1 INTRODUÇÃO

Nos últimos anos a Organização Mundial de Saúde (OMS) vem se destacando em medidas preventivas para amortizar os efeitos das epidemias em todo mundo, a exemplo: o controle da influenza. Segundo declaração do diretor-geral da OMS Tedros Adhanom Ghebreyesus, em março de 2019, um ano antes da pandemia da COVID-19, existia um risco potencialmente contínuo de que um novo vírus da influenza, com transmissão de animais para humanos poderia ocasionar uma pandemia, e que a necessidade de vigilância e preparação era de extrema importância (BASTOS, 2019). Pandemias, são conhecidas como epidemias com proporção mundial, causando grande número de doentes e vítimas, refletindo diretamente na economia global (AKIN; GÖZEL, 2020). Após a declaração do diretor-geral da OMS, no dia 11 de março de 2020 a OMS declarou a pandemia de COVID-19, doença causada pelo coronavírus (Sars-Cov-2) (WHO..., 2020). Mais de 6.207.615 mortes foram contabilizadas em decorrência do vírus (WHO..., 2020).

O diagnóstico precoce da COVID-19 vem se mostrando extremamente eficiente na diminuição de risco de morte de um paciente, além de diminuir o risco de um progresso da doença para um estágio crítico (GONG et al., 2020). Em locais afastados dos grandes centros, geralmente, a capacidade dos testes é limitada, devido à carência de suprimentos (JACOBI et al., 2020), desta forma alternativas de detecção da doença devem ser buscadas. Buscando combater e amenizar os efeitos da pandemia estratégias para a identificação do SARS-CoV-2 foram protocoladas, variando entre a aplicação de testes sorológicos, a realização de testes por reação em cadeia da polimerase por transcrição reversa (RT-PCR), vigilância de casos e a análise da tomografia computadorizada (TC) (UDUGAMA et al., 2020).

Algoritmos de aprendizado de máquina profundo (AMP) podem auxiliar no diagnóstico de certas patologias, como tuberculose

e câncer de pulmão, utilizando raio-X do tórax em um nível comparável a radiologistas (CHASSAGNON et al., 2020). A utilização de AMP em conjunto com técnicas de pré-processamento de imagem se mostrou altamente precisa na detecção de pneumonia (NAHID et al., 2020). Com isso, diversos trabalhos buscando otimizar, acelerar e auxiliar a triagem de pacientes com COVID-19 estão sendo desenvolvidos utilizando AMP, a exemplo (RAJARAMAN; ANTANI, 2020) que pelo uso de AMP identifica pacientes com pneumonia induzida pela COVID-19 utilizando raio-X do tórax fracamente rotulados, técnicas semelhantes também foram utilizadas nos trabalhos de (OZTURK et al., 2020), e (MITTAL et al., 2020).

A principal questão desta pesquisa é: 'O quanto o uso de AMP pode otimizar o processo de triagem de um paciente com COVID-19?'

Este projeto propõe uma arquitetura baseada em rede neural convolucional, que a partir de raios-x do toráx seja possível identificar a COVID-19, otimizando o tempo de atendimento de pacientes com suspeita de pneumonia causada por COVID-19 e auxiliando no processo triagem de pacientes com suspeita de COVID-19, para que, recebam tratamento adequado rapidamente.

1.0.1 Justificativa

A combinação do RT-PCR com a TC é descrita como a principal ferramenta para o diagnóstico preciso da COVID-19. Todavia, a RT-PCR é custosa e complexa para ser realizada em larga escala, demandando equipes treinadas e equipamentos especializados (CASTRO-DE-ARAUJO et al., 2020), restringindo a sua disponibilidade. Em locais afastados dos grandes centros, geralmente, a capacidade dos testes é limitada, devido à carência de suprimentos, e onde não há disponibilidade de aparelhos e estrutura para a realização de exames de TC (PEREIRA, 2020), o raio-X de tórax acaba sendo o único método de investigação para a COVID-19. As imagens radiográficas por raio-X pode permitir a triagem rápida de pacientes com suspeita de COVID-19, e podem ser realizadas paralelamente a testes virais , cujo resultado pode ser demorado. O seu

uso ajuda a aliviar o volume de pacientes, especialmente nas áreas mais afetadas.

A radiologia é naturalmente uma das áreas da medicina com mais contato com as imagens médicas, sendo que a Detecção Auxiliada por Computador (CAD) já é decisiva para o reconhecimento de nódulos pulmonares, embolia pulmonar, fibrose pulmonar e pneumonia, onde ao serem aplicadas com técnicas de inteligência artifical (IA) criam soluções que apoiam o diagnóstico (ARDAKANI et al., 2021).

Algoritmos de AMP possuem a capacidade de classificação que apoiam o diagnóstico de certas patologias, como tuberculose e câncer de pulmão, em alguns casos essas aplicações possuem um nível de acurácia comparável a radiologistas (CHASSAGNON et al., 2020). A utilização de AMP associadas a técnicas de pré-processamento de imagem mostra-se ser altamente eficiente na detecção de pneumonia ao analisar métricas como acurácia, precisão e *recall* é possível identificar melhores classificações (NAHID et al., 2020).

Uma revisão integrativa foi realizada no início desta pesquisa, buscando trabalhos no período de 2015 a 2021 com o foco em AMP aplicada para COVID-19, esta revisão integrativa teve o objetivo de identificar as características da doença e buscar dados *open-source* para serem aplicados nesta dissertação. Esta revisão permitiu identificar que muitos trabalhos encontrados não eram *open source*, assim não disponibilizando os dados nem o algoritmo. No Apêndice A é apresentada a revisão integrativa realizada.

Com isto, este projeto visa criar uma arquitetura denominada CovNet-UFCSPA, utilizando dados de imagens clínicas (raio-X), com o objetivo de identificar possíveis pacientes com COVID-19. Além disso, esta arquitetura testará seu desempenho com o apoio do Hospital da Clínica de Porto Alegre da Universidade Federal do Rio Grande do Sul (HCPA - UFRGS), onde imagens de 1538 pacientes diagnosticados com e sem COVID-19 serão aplicadas na CovNet-UFCSPA.

1.0.2 Objetivos

1.0.2.1 Objetivo Geral

O objetivo geral é automatizar os mecanismos de identificação de COVID-19, por meio de uma arquitetura de *software*, alimentada por algoritmos de AMP e com entradas de dados de raio-X. Esta arquitetura busca identificar se o paciente desenvolveu uma pneumonia induzida pela COVID-19.

1.0.2.2 Objetivos Específicos

1. Criação de um banco de dados de raio-X e TC do tórax de pacientes com COVID-19.
2. Aplicação de técnicas de pré-processamento para analise do seu efeito no desempenho da arquitetura.
3. Análise semântica das imagens médicas, por meio de mapa de calor, buscando o rastreamento de pontos das imagens que o algoritmo utilizou para classificar a imagem como pneumonia induzida pela COVID-19.
4. Aplicação da arquitetura em um ambiente real: utilizando dados do HCPA - UFRGS.
5. Disponibilizar a arquitetura para a comunidade.

1.0.3 Contribuições Esperadas

Baseada na questão de pesquisa, este projeto busca construir uma arquitetura *open source* que deve atuar com objetivo de classificar pacientes com COVID-19. Espera-se que este algoritmo obtenha bons resultados de classificação. Para isto, as medidas para análise de desempenho serão quantitativas, tais como acurácia, precisão e outras variáveis que serão discutidas na metodologia. Caso as métricas estipuladas possuam um bom desempenho será possível comprovar a importância da criação de ferramentas tecnológicas que auxiliem os profissionais de saúde.

Além disso, espera-se que arquitetura seja disponibilizada de maneira *open source*. A utilização dos dados do HCPA - UFRGS contribuirá para o processo de teste da arquitetura proposta. Um análise de comportamento da arquitetura diante de dados de pacientes brasileiros e do Sistema único de Saúde (SUS), visto que conforme a tabela apresentada no Capítulo 4, sendo os dados utilizados para treinamento de pacientes de outras nacionalidades.

1.0.4 Estrutura do Documento

No Capítulo 2 é apresentado os conceitos relevantes para criação da arquitetura proposta nesta pesquisa. O Capítulo 3 encontra-se uma revisão da literatura com os principais resultados encontrados que possuem relação com está dissertação. O Capítulo 4 é apresentada os materiais que será utilizada para construção e validação da arquitetura. O Capítulo 5 apresenta os métodos utilizado. No Capítulo 6 estão descritos os resultados alcançados por esta pesquisa. O Capítulo 7 é apresentada a conclusão deste trabalho.

2 REFERENCIAL TEÓRICO

2.1 PNEUMONIA

A pneumonia é classificada como uma doença respiratória aguda, causada comumente por vírus ou bactérias, podendo acometer pacientes de forma leve ou fatal, segundo o Ministério da Saúde sua definição consiste em:

> Pneumonia é uma infecção que se instala nos pulmões, órgãos duplos localizados um de cada lado da caixa torácica. Pode acometer a região dos alvéolos pulmonares onde desembocam as ramificações terminais dos brônquios e, às vezes, os interstícios (espaço entre um alvéolo e outro). Basicamente, pneumonias são provocadas pela penetração de um agente infeccioso ou irritante (bactérias, vírus, fungos e por reações alérgicas) no espaço alveolar, onde ocorre a troca gasosa. (SAÚDE DO MINISTÉRIO DA SAÚDE, 2011).

Está doença ocasiona danos a vida e a sociedade, estima-se que:

a) 15 % de todas as mortes de crianças menores de 5 anos são ocorrência da pneumonia (ORGANIZATION, 2021);

b) A cada 39 segundos morre uma criança vítima de pneumonia (NAÇÕES UNIDAS - NEWS, 2021)

c) É a maior causa de morte mundial por doença infecciosa de adultos e crianças, ceifando a vida de 2,5 milhões de pessoas, incluindo 672.000 crianças, em 2019 (SAÚDE DO MINISTÉRIO DA SAÚDE, 2021);

d) A COVID-19 pode adicionar 1,9 milhão ao número de mortos este ano, no mundo, provocando um aumento das mortes por pneumonia por "todas as causas"em mais de 75% e nenhuma outra infecção causa tantas mortes(SAÚDE DO MINISTÉRIO DA SAÚDE, 2021);

e) Estima-se que as interrupções do atendimento nos serviços de saúde, por conta da pandemia, possam causar até 2,3 milhões mortes infantis no mundo, resultando em um adicional de 35% (SAÚDE DO MINISTÉRIO DA SAÚDE, 2021).

Os agentes causadores da pneumonia são diferentes podendo ser: bactérias, vírus ou fungos, isto faz com que a evolução clínica da doença seja associada à virulência dos agentes etiológicos e/ou ao estado de imunidade do hospedeiro. O tratamento varia com antibióticos que buscam combater patógenos bacterianos e drogas antivirais que atuam contra os patógenos virais (LEE et al., 2010).

2.1.1 Pneumonia Viral

Existem uma grande diversidade de vírus que afetam o trato respiratório que podem acometer o trato respiratório baixo, causando bronquiolite, bronquite e pneumonia. A pneumonia viral (PV) é uma das complicações causadas por esses vírus, esta doença é definida pelo ocorrimento de anormalidade nas trocas gasosas a nível alveolar que acompanha uma inflamação do parênquima pulmonar, tais anormalidade são detectadas por exames de imagens como TC e raio-X (FIGUEIREDO, 2009). O impacto nos pacientes varia: pacientes imunocomprometidos possuem o sistema de defesa contra infecções comprometido, sendo assim ineficientes no combate de vírus, já pacientes imunocompetentes são capazes de reagir e combater adequadamente patógenos como os causadores da pneumonia viral (KOO et al., 2018).

Diversos são os patógenos causadores, o estudo Koo et al. (2018) indica alguns como: Adenoviridae, Herpesviridade, Parvoviridae, Paramyxoviridae, neumoviridae, Bunyaviridae, Orthomyxoviridae, Coronaviridade, Picornaviridae e Antiviral Treatment. Para o diagnóstico das infecções respiratórias os métodos de detecção mais utilizados são: sorológicos e por detecção do ácido desoxirribonucleico (DNA, do inglês *deoxyribonucleic acid*)(FIGUEIREDO, 2009).

2.1.1.1 Pneumonia Induzida pela COVID-19

O progresso da COVID-19 para o estágio crítico deve ser observado e possivelmente impedido, observa-se que o agravamento do estado clínico do paciente ocasiona o desenvolvimento de pneumonia, sendo esta do tipo viral com agente etiológico SARS-CoV-2 (GONG et al., 2020). O diagnóstico da COVID-19 também é realizado principalmente por métodos de detecção do DNA, o teste de reação em cadeia da polimerase por transcrição reversa (RT-PCR, do inglês *Reverse Transcription Polymerase Chain Reaction*), análise de sintomatologia e exames de imagem do tórax, sendo raio-X e TC os mais comuns (UDUGAMA et al., 2020).

A necessidade de mapear os sintomas e suas consequências é constante para melhor compreensão da doença, autores como (STRUYF et al., 2020) apresentaram após uma revisão de 16 estudos com um total de 7.706 participantes, que os principais sintomas são febre, mialgia ou artralgia, fadiga sendo menos comum tosse, dor de garganta, febre, mialgia ou artralgia, fadiga e cefaleia. Os autores concluem que sinais ou sintomas não trazem precisão o suficiente para excluir ou descartar a doença. Esses sintomas também são apresentados em (ZHAO et al., 2020) onde febre e tosse são predominantes nos pacientes. Um mapeamento detalhado dos sintomas, exames médicos e padrões radiológicos da doença foi realizado ns revisão integrativa, presente no Apêndice A

2.1.2 Diagnóstico

O diagnóstico da pneumonia possui alguns desafios devido à dificuldade de detecção dos agentes etiológicos das infecções do trato respiratório (MCCRACKEN JR, 2000). Os principais métodos de diagnóstico de pneumonia são sorológicos ou por detecção de DNA, a seguir encontra-se suas definições:

Definição 2.1.1 (Métodos Sorológicos)**.** Os materiais coletados são processados para o isolamento viral em cultura de células e utilizados na detecção de anticorpos IgM (imunoglobulina M) e/ou IgC (imunoglobulina C) que sugerem infecções recentes do vírus causadores de pneumonia (FIGUEIREDO, 2009). No entanto sua praticida-

de é bastante reduzida devido a necessidade de duas amostras para demonstrar soro conversão dificultando o seu uso de maneira mais ampla, porém a técnica de ELISA para identificação de IgM anti M é muito utilizada e pode dispensar a realização de uma segunda coleta (RODRIGUES; SILVA FILHO; BUSH, 2002).

Definição 2.1.2 (Métodos de Detecção do DNA)**.** Este método é dividido em: métodos de hibridização com sondas e métodos de amplificação do DNA, cuja técnica mais utilizada é a reação em cadeia da polimerase (PCR, do inglês *Polimerase Chain Reaction*), sendo a RT-PCR a mais utilizadas na última década por possuir uma capacidade de detecção 2-3 vezes maior do que os métodos de cultura viral (MOHAN et al., 2010).

2.2 PADRÃO RADIOLÓGICO DA PNEUMONIA

O diagnóstico radiológico, baseado em imagem, leva em consideração aspectos como: densidade, tamanho, número, homogeneidade, nitidez, definição de margens, localização, presença ou não de calcificações ou de escavações. Doenças alveolares apresentam características de consolidações pulmonares, que são criadas pela substituição do ar dos alvéolos por líquido, células ou a combinação destes dois, neste trabalho as principais característica mapeadas é da pneumonia, que é uma doença alveolar aguda (ESCUISSATO, 2018).

Para a identificação de pneumonia os principais exames de imagens utilizados são radiografia e tomografia do tórax, os quais apresentam os seguintes planos: sagital, coronal ou frontal e transversal ou axial. A Figura 2.1 apresenta um raio-X com projeções axial e coronal em poster anterior (PA) onde o tórax é dividido em um compartimento mediano (mediastino) e dois laterais: pleuras e pulmões. O pulmão direito possui cissura oblíqua e horizontal que divide em lobos superior, médio e inferior, já o pulmão esquerdo há apenas a cissura oblíqua que compõe os lobos superior e inferior (BRENTANO et al., 2014). Estas imagens buscam mostrar para os profissionais de saúde o estado dos pulmões para que um possível diagnóstico de pneumonia seja dado. Todavia, a literatura observa

que existem padrões radiológicos para esta doença que variam de acordo com o agente etiológicos. Porém muitas vezes estes padrões se sobrepõem, em função disto uma classificação comum é a separação por mecanismo de origem, podendo ser: pneumonia adquirida na comunidade (PAC), pneumonia nosocomial e pneumonia aspirativa. Essas pneumonias apresentam padrões como: consolidação do espaço aéreo conforme as Figura 2.2 e Figura 2.3, vidro fosco presentes nas Figura 2.4 e Figura 2.5, padrão nodular (composto por nódulos, reação granulomatosa e bronquiolite) e padrão reticular(com opacidades lineares intralobulares) (SHARMA; MAYCHER; ESCHUN, 2007).

Figura 2.1 – Radiografia de tórax normal em PA e axial apontando as principais estruturas anatómicas identificáveis. AE – Átrio Esquerdo, VE – Ventrículo Esquerdo, AD – Átrio direito, LS – lobo superior, LM – lobo médio, LI – lobo inferior.

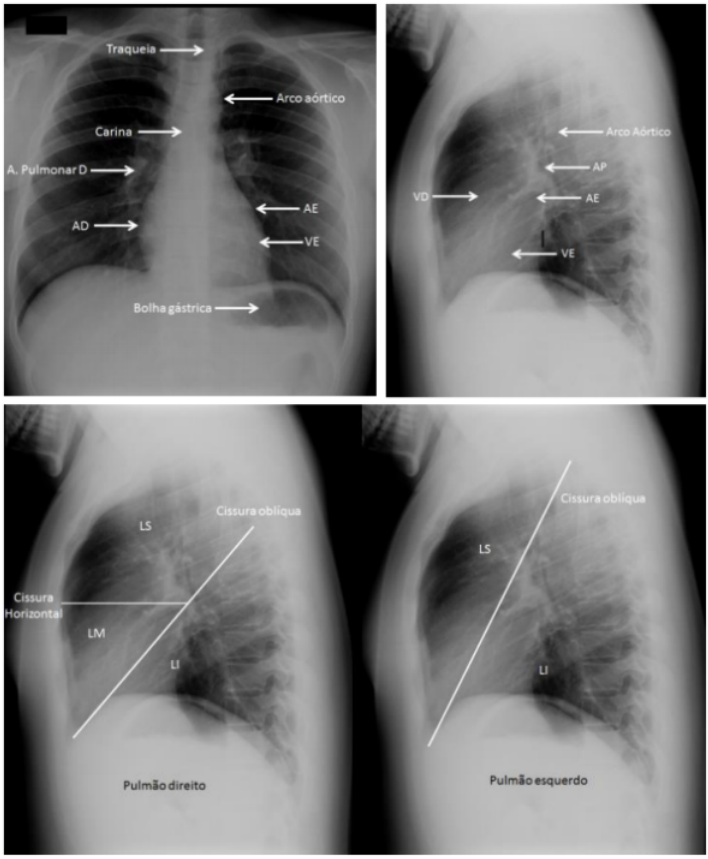

Fonte: (BRENTANO et al., 2014)

2.2.1 Padrões Radiológicos da Pneumonia Induzida pela COVID-19

A pneumonia induzida pela COVID-19 possui alguns padrões particulares identificados em exames de raio-X e TC do tórax, as características demográficas de tomografias de pacientes com esta

pneumonia varia de acordo com estágio da doença e gravidade clínica sob o indivíduo. Os autores (SHI et al., 2020) apresentaram um estudo com 81 pacientes chineses acometidos pela doença, onde foram encontrados padrões de anormalidade, nos exames radiológicos, de 79% bilateral, 54% periférico e 81% apresentaram anomalias mal definidas, além disso 79% dos pacientes apresentaram opacidade de vidro fosco. A Figura 2.4 representa um TC de uma paciente com COVID-19 com padrão de vidro fosco. A Figura 2.5 apresenta um raio-X de paciente diagnósticado com COVID-19, onde a seta preta indica o padrão de vidro fosco.

Figura 2.2 – Bronquiolite obliterante com pneumonia em organização. Corte axial na TC de alta resolução onde evidencia áreas de consolidação bilaterais com típica distribuição Peribrônquica.

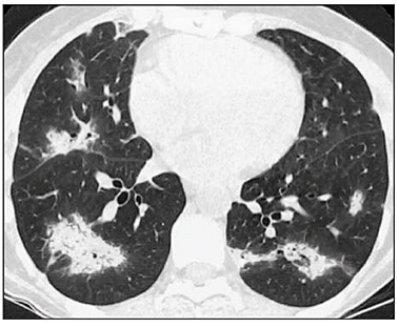

Fonte: (SILVA; MÜLLER, 2005)

Figura 2.3 – Pneumonia bacteriana no pulmão esquerdo, na forma de consolidação do espaço aéreo (seta). Com contornos mal definidos, algodonosos, e na distribuição segmentar.

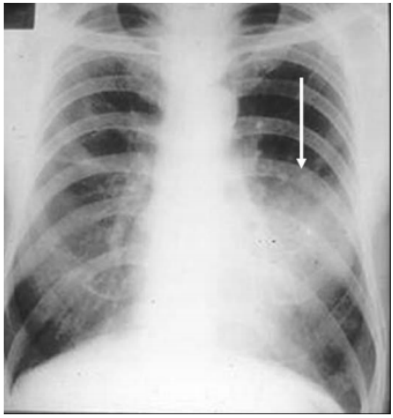

Fonte: (MEIRELLES, 2021)

Figura 2.4 – TC de secção fina transversal do toráx com padrão de vidro fosco em paciente com COVID-19.

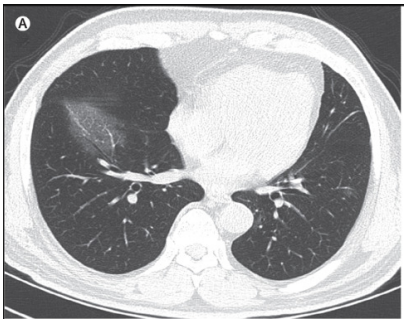

Fonte: (SHI et al., 2020)

Figura 2.5 – Raio-X com opacidades em vidro fosco (seta preta) em paciente com COVID-19.

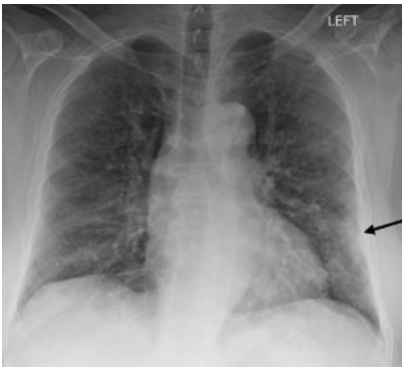

Fonte: (JACOBI et al., 2020)

Na Tabela 2.1 são apresentados alguns trabalhos onde é realizado o mapeamento de padrões radiológicos da doença. Os principais padrões são: periféricos, opacidades bilaterais de vidro fosco, consolidações.

Tabela 2.1 – Dados com padrões radiológicos de pacientes com pneumonia induzida pela COVID-19

Informações	**Autores**										
	Han (1)	Song (2)	Wu (3)	Li Y.(4)	Zhao (5)	Bai (6)	Bernheim (7)	Ai (8)	Shi (9)	Li K. (10)	Guan(11)
Informações Gerais											
Dado *open source* (S/N)	N	N	N	N	N	N	N	N	N	N	N
Possui Sintomas (S/N)	S	S	S	S	S	S	S	N	S	S	S
Possui Exames clínicos (S/N)	S	N	S	N	N	N	N	N	S	S	S
Inf. sobre comorbidade (S/N)	N	S	S	N	N	S	N	N	S	S	S
Dados Demográficos											
Número de pacientes	108	51	80	51	101	219	121	1014	81	83	1099
Idade média	45	49	44	58	44	45	45	51	50	46	47
Pacientes masc	38	25	42	28	56	119	61	467	42	44	637
Países do pacientes	China	China	China	China	China	China	China/Alemanha/Holanda	China	China	China	China
Distribuição das Lesões											
Sem lesão (%)	0	0	-	4	8	-	22	12	0	-	14
Bilateral/Unilateral (%)	-	86/14	-	-	82/10	75/19	60/18	-	79/21	95/5	52/34
Periférico/Central (%)	90/2	86/10	53/NA	96/NA	87/1	80/1	52/0	-	54/NA	-	-
Multifocal/Difuso (%)	-	-	NA/9	-	55/32	61/27	-	-	NA/44	-	-
Envolvimento de 1 lóbulo/ 5 lóbulo (%)	35/NA	8/39	-	NA/75	-	-	15/27	-	-	-	-
Lóbulo superior (dir/med)(%)	-	-	-	-	-	-	44/48	-	19/20	65/86	-
Lobo médio (%)	-	-	-	-	-	-	41	-	10	74	-
Lobos inferiores (dir/esq) (%)	-	-	84/79	-	-	-	65/63	-	27/24	94/96	-
Aparência das Lesões na TC											
GGO (%)	60	77	91	35	86	91	34	46	65	98	56
Consolidação (%)	6	55	63	6	44	69	2	50	17	64	-
GGO e consolidação (%)	41	59	-	55	64	-	41	-	-	-	-
Reticulação (%)	-	22	59	-	49	35	7	1	35	-	-
Sinais na TC	-	-	-	-	-	-	-	-	-		
Padrão de pavimentação louco (%)	40	-	29	71	-	5	5	-	10	36	-
Sinal de teia de aranha (%)	-	-	25	-	-	-	-	-	-	25	-
Broncograma aéreo (%)	48	80	-	69	-	14	-	-	47	-	-
Bronquiectasia (%)	-	-	-	-	53	-	1	-	11	-	-
Espessamento da parede brônquica (%)			11		29	9	12			23	-
Linha subpleural (%)	-	-	20	-	28	-	-	-	21	-	
Aumento vascular (%)	80	-	-	82	71	59	-	-	-	-	-
Sinal de halo (%)	64	-	-	18	-	26	-	-	-	-	-
Sinal de halo invertido (%)	-	-	-	4	-	5	2	-	-	-	-
Nódulos (%)	-	-	-	22	23	32	0	3	6	7	
Achados extrapulmonares											
Derrame pleural (%)	0	8	6	2	14	4	1	-	5	8	-
Espessamento pleural (%)	0	-	-	-		15	-	-	32	-	-
Linfadenopatia (%)	0	6	4	0	1	3	0	-	6	8	-
Derrame pericárdico (%)	-	6	5	-	-	-	-	-	-	5	-

Fonte: Adapatada de (GÜNEYLI et al., 2020)

Legenda Tabela 2.1, : Referências - (1) (GUO; WANG; WANG, 2019); (2) (SONG et al., 2020); (3) (SONG et al., 2020); (4) (LI; XIA, 2020); (5) (ZHAO et al., 2020); (6) (BAI et al., 2020); (7) (BERNHEIM et al., 2020); (8) (AI et al., 2020); (9) (SHI et al., 2020); (10)(DAS et al., 2015); (11)(GUAN et al., 2020).

Abreviaturas - S - sim; N - não; GGO - vidro fosco (do inglês *ground glass opacities*); NA - não aplicável

2.3 APRENDIZADO DE MÁQUINA

2.3.1 Aprendizado de máquina

O aprendizado de máquina (AM) é uma subárea da inteligência artificial que por meio de programação de computadores otimiza o desempenho de um critério, através da criação de um modelo onde seu aprendizado utiliza um conjunto de dados e/ou experiência anterior. Podendo ser este modelo preditivo (previsão de futuro) e/ou descritivo (para obter conhecimento dos dados) (ALPAYDIN, 2020, p. 3). As áreas de atuação do AM são diversas e divididas com objetivo de atender problemas diferentes, alguns exemplos são: aprendizado por associação, classificação, regressão e aprendizado não supervisionado (ALPAYDIN, 2020, p.5-14). Associação e classificação são aplicações com AM, os quais serão utilizados nesta pesquisa.

O aprendizado por associação busca o relacionamento recorrente de um conjunto de dados, aplicando nestes dados regras de associação, por exemplo: um paciente que sofre de diabetes provavelmente também sofrerá de hipertensão. (ALTAF; SHAHBAZ; GUERGACHI, 2017). O uso desta área também é uma realidade em aplicações onde o conjunto de dados são imagens médicas, em (RIBEIRO et al., 2009) os autores aplicaram AM e regras de associação em imagens médicas para sugerir uma segunda opinião a radiologistas ou até mesmo um diagnóstico preliminar em imagens médicas.

Aplicações de classificação de dados utilizando AM são compreendidas em 7 conceitos principais, são eles: 1) Classificação: é a definição das classes que o conjunto de dados serão submetidos para classificação, podendo ser uma ou mais; 2) Discriminante: por meio de um função separa os exemplos de diferentes classes; 3) Predição: onde baseado em experiência anterior um nova instância de dados podem ser previstas corretamente; 4) Reconhecimento de padrão: obtido por meio das extrações e seleções das características mais discriminativas do conjunto de dados; 5) Extração do conhecimento: onde a partir de dados aprende-se um regra; 6) Compreensão: é quan-

do realizado o ajuste de uma determinada regra a uma instância de dados; 7) Detecção de exceção: o objetivo é identificar quais dados não se aplicam a regra aprendida (ALPAYDIN, 2020). Os autores (KHAN; SOHAIL; KHAN, 2020), aplicaram técnicas de classificação utilizando redes neurais convolucionais para distinção de raio-X de pacientes com pneumonia da COVID-19.

O AM possui três principais tipos de aprendizados, são eles: supervisionados, não supervisionados e por reforço (ALTAF; SHAHBAZ; GUERGACHI, 2017). O aprendizado supervisionado é utilizado para descrever tarefas de previsão, cujo objetivo é prever ou classificar uma ou mais classes de interesse (JIANG; GRADUS; ROSELLINI, 2020). Para isto, um conjunto de variáveis de entrada são utilizados para previsão de uma variável de resposta quantitativa ou qualitativa, modelos supervisionados possuem tarefas que utilizam somente dados que são rotulados. Métodos de aplicação deste tipo de aprendizado são encontrados em máquinas de vetores de suporte (SVMs do inglês *Support Vector Machines*), redes neurais, regressão logística, árvore de decisão, naive bayes e floresta aleatória (CARUANA; NICULESCU-MIZIL, 2006). Trabalhos com ação de classificações como as descritas nesta seção utilizam o método de aprendizado por supervisão. Já quando não há rotulação dos dados (os resultados são desconhecidos), ou seja, não há um supervisor existindo e tendo assim somente dados de entradas, o aprendizado é classificado como não supervisionado. Os autores (MACKEY et al., 2020), utilizando um modelo de AM não supervisionado, desenvolveram um estudo que por meio de dados do *twitter* detectaram e caracterizaram conversas geradas pelos usuários buscando associações com os sintomas da COVID-19.

Por fim o aprendizado por reforço o qual é aplicado em situações que necessitam extrair qual a melhor ação a ser tomada diante de uma circunstância. A Figura 2.6 representa um cenário básico e típico onde para o aprendizado de reforço é utilizado um controlador que recebe o estado do sistema controlado e uma recompensa é associada a última transição de estado, com isso calcula-se uma ação, que é enviada de volta para o sistema, em resposta o sistema faz uma transição para um novo estado e o ciclo é repetido (SZEPESVÁRI,

2010, p.9).

Figura 2.6 – Cenário básico de aprendizado com reforço.

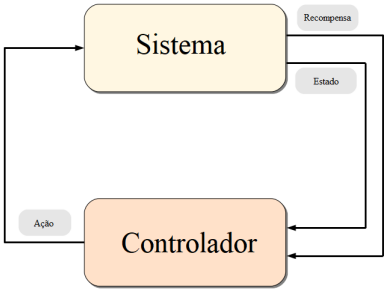

Fonte: Adaptado de (SZEPESVÁRI, 2010, p.9)

2.3.2 Rede Neurais

Uma rede neural é definida como sendo um processador maciçamente paralelamente distribuído, constituído de unidades de processamento simples, com propensão natural para armazenar conhecimento e torná-lo disponível para uso, este processo são semelhantes ao cérebro por dois motivos: o conhecimento é adquirido pela rede através do processo de aprendizagem, e o processo de armazenamento do conhecimento é feito por conexões entre os neurônios (HAYKIN, 2007, p. 27). Todo procedimento para o processo de aprendizagem é denominado de algoritmo de aprendizagem, cuja a função é modificar os pesos sinápticos da rede de forma ordenada em busca de um objetivo (HAYKIN, 2007, p. 28), (GALLANT; GALLANT, 1993, p.6).

Uma rede é composta por camada de entrada onde ocorre o recebimento de dados, uma ou mais camadas ocultas e uma camada de saída. As redes neurais profundas também são conhecidas por perceptrons de múltiplas camadas, este tipo de arquitetura é aplicada em algoritmos de retropropagação de erro (*error back propagation*), esses algoritmos possuem dois passos: propagação e retropropagação (ALBUQUERQUE et al., 2008). No processo de propagação os

pesos sinápticos da redes são fixos, já no processo de retropropagação os pesos são todos ajustados de acordo com uma regra de correção (HAYKIN, 2007, p. 184). Um perceptron de múltiplas camadas é composto por uma função de ativação não linear, muitas vezes sigmóides, camadas de neurônios ocultos e possuem uma alta conectividade da rede (ALBUQUERQUE et al., 2008). A Figura 2.7 representa a diferença de uma estrutura de uma rede neural simples e profunda, onde as camadas são totalmente conectadas, ou seja, um neurônio em qualquer camada da rede está conectado a todos os neurônios da camada anterior.

Figura 2.7 – Rede neurais simples x rede neurais profundas.

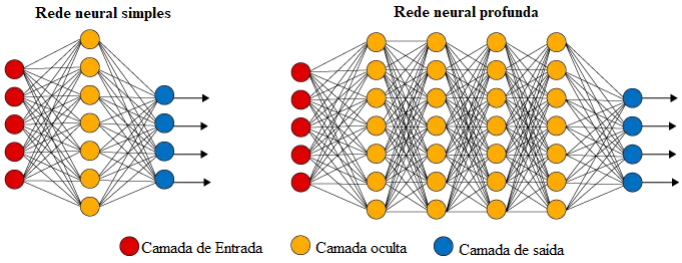

Fonte: Adaptado de (ACADEMY, 2018)

2.4 APRENDIZADO DE MÁQUINA PROFUNDO

O AMP é uma sub-área do AM, que permite aprender com a experiência e compreender o mundo em termos de uma hierarquia de conceitos, o qual o aprendizado de conceitos complicados são construidos a partir de outros mais simples, essas hierarquias são composta por muitas camadas de profundidade (GOODFELLOW et al., 2016).

Arquiteturas profundas necessitam de grande poder computacional devido as suas sucessivas camadas e operações matemáticas, normalmente algoritmos utilizando este aprendizado possuem um tempo de treinamento longo, o seu uso foi viabilizado devido aumento poder de processamento dos *hardwares* (JANGAMREDDY,

2019). Para o treinamento estratégias utilizando *Graphics Processing Unit* (GPU) são populares, denominando-se em sistemas de aprendizagem distribuída.

2.4.1 Sistemas de Aprendizagem Distribuída

Esses sistemas são muito utilizados em aplicações de AMP, uma vez que GPUs são mais eficientes no tratamento da multiplicação matriz-matriz em comparação com multiplicações vetor-matriz. Isto ocorre por que diferentemente da CPUs que possuem poucos núcleos, onde cada núcleo é capaz de atender em média apenas 100s de threads por instante, já as GPUs em seu núcleo podem executar em média 1000s simultaneamente (JANGAMREDDY, 2019).

Umas das rotinas em AMP é a divisão do conjunto de dados em minilotes, o objetivo disto é acelerar o processo de treinamento, pois os dados da camada de entrada são geralmente agrupados nos chamados minilotes, que tem como objetivo evitar o uso excessivo de memória (HAENSCH; GOKMEN; PURI, 2018). Está técnica de divisão de dados será discutida na metodologia, Capítulo 4.

2.4.2 Rede Neurais Convolucionais

Redes Neurais Convolucionais (CNN do inglês *Convolutional Neural Network*) é um dos algoritmos mais estabelecidos entre os vários modelos do AMP, seu uso em aplicações médicas alcançou um desempenho equiparado a especialistas, na radiologia sua aplicação já é consolidada sendo aplicada em diversos estudos como: detecção de lesões, classificação, segmentação e reconstrução de imagens (YAMASHITA et al., 2018). Sua aplicabilidade é uma realidade na identificação de padrão em exames de imagens, sendo capaz de identificar padrões como os apresentados na Tabela 2.1. A utilização deste algoritmo não se limita somente a imagens, diversas pesquisas demonstram sucesso na classificação de relatório em texto, tendo precisão equivalente ou até mesmo superior, quando comparado a modelos tradicionais, como o de processamento natural da linguagem (CHEN et al., 2018), (LAI et al., 2015).

O modo de operação das CNNs é um destaque, por não ser

necessário a preocupação com o posicionamento da imagem, pois ela tem a habilidade de detectar a classe estabelecida independentemente da disposição da imagem, outro aspecto importante é a capacidade de obter recursos abstratos quando a entrada se propaga para as camadas mais profundas. Por exemplo: numa classificação de imagem a borda é detectada nas primeiras camadas, em seguida, as formas mais simples e conforme o aprofundamento das camadas é realizada a detecção de recursos de níveis superiores, como a de um rosto. (ALBAWI; MOHAMMED; AL-ZAWI, 2017).

Todo esse processo de detecção é realizado por um conjunto de etapas, iniciando pela entrada, que pode ser imagens, vídeos ou textos que devem ser tratados até chegar num formato de representação matricial adequado. Uma imagem pode ser representada por uma matriz de pixels variando os seus valores entre 0 e 255, onde cada elemento da matriz pode ser representado por um número diferente de canais, por exemplo RGB para imagens coloridas Figura 2.8. Com isto, uma imagem colorida com representação RGB forma um tensor de terceira ordem (3D), onde cada canal é representado por um tensor de segunda ordem (2D) (WU, 2017).

Figura 2.8 – Representação de uma imagem em RGB.

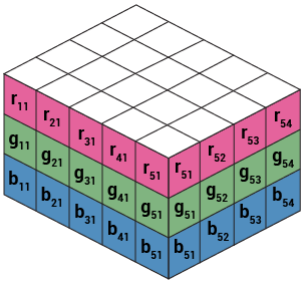

Fonte: (KWIATKOWSKI, 2018)

2.4.2.1 Camada convolucional

A camada convolucional é vital em uma CNN, podendo em uma rede existir uma ou mais camadas deste tipo, o uso reduz drasticamente a quantidade de parâmetro de uma rede. Isto ocorre devido ao uso de filtros espaciais lineares, conhecidos como kernel (O'SHEA; NASH, 2015). Para exemplificar uma convolução, supõe-se um vetor x e w, onde x é a entrada da camada convolucional e w o filtro de característica ou kernel, a convolução desses vetores é representada por y, gerando assim a Equação 2.1, (MASSUCATTO, 2018).

$$y = x * w \tag{2.1}$$

A convolução é capaz de reduzir a complexidade do modelo devido a otimização realizada em sua produção, composta por 3 hiperparâmetros: profundidade (do inglês *depth*), passada (do inglês *stride*) e preenchimento de zero (do inglês *zero-padding*). A profundidade é número de canais, exemplo uma imagem com representação RGB possui uma profundidade igual a 3. O preenchimento de zero é responsável pela adição de pixels vazios ao redor da imagem, sua função é preservar o tamanho original da imagem ao aplicar um filtro convolucional.

2.4.2.2 Camada *pooling*

O objetivo principal desta camada é reduzir gradualmente a dimensionalidade da representação resultante da convolução, reduzindo assim ainda mais os números de parâmetros e a complexidade computacional. Seu funcionamento é semelhante a um filtro, onde seu tamanho e passo é determinado previamente (O'SHEA; NASH, 2015). Quando seu tamanho é estabelecido em 2x2 com um passo de 2, há uma redução de 25% do tamanho original(O'SHEA; NASH, 2015)..

2.4.2.3 Camada totalmente conectada

Nesta camada o processo de *flattening* já ocorreu, ou seja, os resultados das camadas anteriores estão em formato de um vetor

coluna. Este vetor que representa os padrões extraídos é utilizado como entrada desta camada, que possui arquitetura de uma rede neural clássica.O passo é a capacidade de deslizamento do um filtro sobre a imagem de entrada, exemplo: com passo igual a 2 o filtro avança por dois pixels a cada passo. A Figura 2.9 representa uma arquitetura simplificada de uma CNN onde a última camada é totalmente conectada.

Figura 2.9 – Representação de uma CNN com camada totalmente conectada.

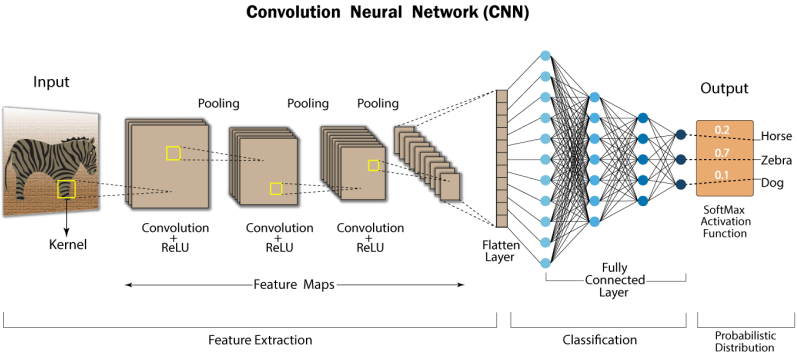

Fonte: (SWAPNA, 2021)

3 TRABALHOS RELACIONADOS

Para buscar trabalhos relacionados com a proposta desta dissertação, uma revisão integrativa foi elaborada buscando extrair as principais características dos dados utilizados para o treinamento dos modelos de aprendizado de máquina profundo. Além disso, um mapeamento dos sintomas, exames e padrões radiológicos foi elaborado. Esta revisão está apresentada no Apêndice A.

4 MATERIAIS

Esta pesquisa propõe uma arquitetura composta por algoritmos de aprendizagem profunda, denominada CovNet-UFCSPA, onde a metodologia é exploratória e quantitativa. Este capítulo descreve todos os materiais utilizados para atingir os objetivos descritos na subseção 1.0.2.

4.1 AQUISIÇÃO DOS DADOS

O processo de aquisição é dividido em duas formas. A primeira foi por meio da revisão integrativa realizada e apresentada no Apêndice A. Nesta revisão a Tabela 2 apresenta uma dados *open source*, os dados de raio-X desta tabela foram utilizados nos ensaios, principalmente nas etapas de treinamento e validação do modelo.

A segunda forma de obtenção dos dados, foi por meio do projeto "Aplicação de um algoritmo com inteligência artificial para auxílio no diagnóstico de COVID-19" registrado na Plataforma Brasil pelo pesquisador Alexandre Bacelar, com CAAE 35219020.1.0000.5327. Este projeto foi enviado para o Hospital de Clínicas de Porto Alegre da Universidade Federal do Rio Grande do Sul para o Comitê de Ética em Pesquisa (CEP), onde o parecer de número 4.508.683 foi aprovado, mais informações deste parecer encontra-se no Anexo A. Foram utilizadas 817 imagens de pacientes diagnosticados com COVID-19 e 721 imagens de pacientes sem COVID-19 para o teste de desempenho da arquitetura proposta.

4.2 PRÉ-PROCESSAMENTO DOS DADOS

Após a revisão integrativa realizada e disponibilizada no Apêndice A, foi possível observar que técnicas de pré-processamento de imagem vem sendo utilizadas em muitos trabalhos com imagens e AMP. Com isto, uma das primeiras iniciativas foi a elaboração de processos para realizar este pré-processamento das imagens.

4.2.1 Separação das imagens

As referências das imagens utilizadas neste trabalho estão na Tabela 1 do artigo de revisão integrativa presente no Apêndice A, além delas foram utilizadas as imagens do HCPA. Todos os ensaios realizados neste trabalho o aprendizado é do tipo supervisionado, ou seja, todos os dados foram rotulados. Para a rotulação dos dados a função create_metadata presente no *script* do Apêndice B foi utilizada. A Figura 4.1 representa um exemplo reduzido dos arquivos csv gerados. Neste arquivo o *filename* representa o local da imagem, *label* é o rótulo de cada classe, onde 0 são para classes não COVID-19 e 1 para classes COVID-19.

Figura 4.1 – Exemplos csv gerado pelo script.

```
filename,label,label_str
/scratch/covnet-ufcspa/nouara.xavier/images/validation/covid/COVID-2494.png,1,COVID-19
/scratch/covnet-ufcspa/nouara.xavier/images/validation/covid/COVID-2007.png,1,COVID-19
/scratch/covnet-ufcspa/nouara.xavier/images/validation/covid/COVID-178.png,1,COVID-19
/scratch/covnet-ufcspa/nouara.xavier/images/validation/covid/COVID-2067.png,1,COVID-19
/scratch/covnet-ufcspa/nouara.xavier/images/validation/covid/COVID-1070.png,1,COVID-19
/scratch/covnet-ufcspa/nouara.xavier/images/validation/covid/COVID-1138.png,1,COVID-19
/scratch/covnet-ufcspa/nouara.xavier/images/validation/normal/Normal-7065.png,0,non-COVID-19
/scratch/covnet-ufcspa/nouara.xavier/images/validation/normal/Normal-1839.png,0,non-COVID-19
/scratch/covnet-ufcspa/nouara.xavier/images/validation/normal/Normal-3779.png,0,non-COVID-19
/scratch/covnet-ufcspa/nouara.xavier/images/validation/normal/Normal-4529.png,0,non-COVID-19
```

Fonte:Autoria própria.

4.2.2 Recorte

Os raios-X obtidos pelo HCPA foram recortados, Figura 5.9b, devido às imagens conter informações fora da região de interesse, o tórax. Este procedimento de recorte foi realizado de forma manual, pois a disposição das imagens sofrem muita variação.

4.2.3 Redimensionamento

A entrada dos modelos, criado neste trabalho, foram ajustadas para que todas as imagens tenham a mesma dimensão. Para isto, a biblioteca OpenCV foi aplicada com o objetivo de redimensionar as imagens. Informações detalhadas da biblioteca estão disponíveis em `https://docs.opencv.org/3.4/da/d6e/tutorial_`

py_geometric_transformations.html. O uso detalhado da biblioteca encontra-se na função *reshape* presente no Apêndice B. A Figura 4.2c apresenta o resultado final da função criada.

4.2.4 Equalização de contraste global

A equalização de contraste global (ECG) busca equalizar o histograma de uma imagem com o objetivo de balancear os níveis de cinza dela. Isto ocorre por meio da distribuição de probabilidade de valores de intensidade da imagem, informações detalhadas da técnica esta disponível em https://docs.opencv.org/4.x/d5/daf/tutorial_py_histogram_equalization.html. O código utilizado para ECG pode ser encontrado na função *equalization* presente no Apêndice B. A Figura 4.2d apresenta o resultado desta técnica.

4.2.5 CLAHE

A aplicação de equalização de histograma adaptável limitada ao contraste (CLAHE do inglês *Contrast Limited Adaptive Histogram Equalization*) vem produzindo bons resultados em imagens médicas (LI; SI; JIA, 2018), (REZA, 2004) . Esta técnica é utilizada para a correção da intensidade das imagens. Além disto esta técnica busca destacar pequenos detalhes, texturas e contrastes na imagem. Para isto há uma divisão da imagem em pequenos blocos denominados "telhas" onde os histogramas são igualados por partes, diferentemente da equalização global. Detalhes desta técnica estão disponíveis em https://docs.opencv.org/4.x/d5/daf/tutorial_py_histogram_equalization.html . As imagens do HCPA foram submetidas a este processo, por meio da função *clahe* presente no Apêndice B. Na função criada o parâmetro *tileGridSize* representa o tamanho da "telha", o valor utilizado foi de 4x4 e *clipLimit* definido é de 2. A Figura 4.2e apresenta o resultado da aplicação de CLAHE.

Figura 4.2 – Pré-processamento nas imagens HCPA

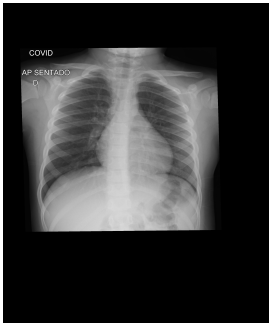

(a) Imagem original de um paciente com COVID-19 do HCPA

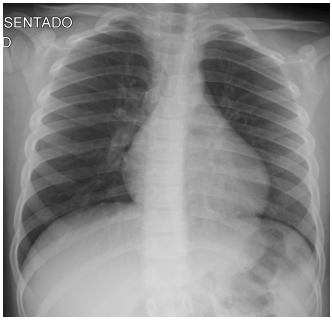

(b) Imagem recortada de um paciente com COVID-19 do HCPA



(c) Imagem redimensionada de um paciente com COVID-19 do HCPA

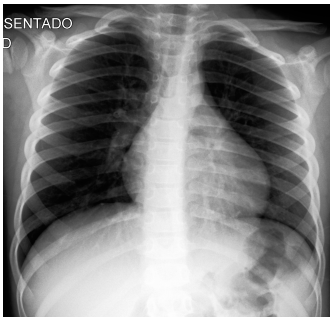

(d) Imagem com ECG de um paciente com COVID-19 do HCPA



(e) Imagem com CLAHE de paciente com COVID-19 do HCPA

Fonte:Autoria própria.

4.3 ARQUITETURAS

Esta seção busca descrever a arquitetura CovNet-UFCSPA e as redes pré-treinadas utilizadas para comparação de desempenho.

4.3.1 CovNet-UFCSPA

A arquitetura CovNet-UFCSPA foi criada utilizando a biblioteca do Keras. Informações da biblioteca disponível em `https://keras.io/`. Esta arquitetura é composta por uma camada inicial onde o parâmetro *input_ shape* recebe o valor de (224, 224, 3), também é aplicado um filtro com valor de 16 e o *kernel* recebe o valor de (3, 3). Para adicionar não linearidade foi utilizada a função de ativação *relu* em todas as camadas Cov2D. A segunda camada possui um filtro de 32 e *kernel* de (3, 3), a terceira, quarta e quinta camada possuem um filtro de 64. Todas as camadas convolucionais (Cov2D) são intercaladas por um *maxipolling* com tamanho (2,2). A camada densa é composta pela função *GlobalAveragePooling2D*, *BatchNormalization*, *Dropout* e duas camadas *Dense*. A Figura 4.3 representa o desenho final da arquitetura CovNet-UFCSPA.

Figura 4.3 – Arquitetura CovNet-UFCSPA.

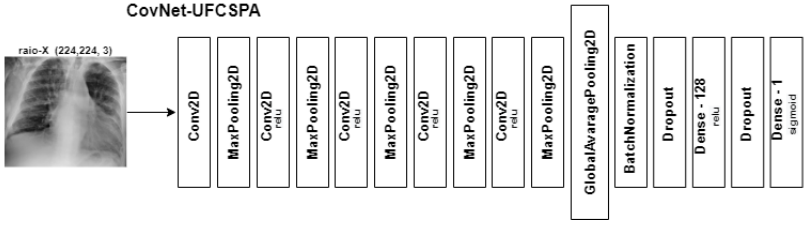

Fonte:Autoria própria

4.3.2 Redes pré-treinadas

O uso de redes pré-treinadas consiste em utilizar recursos aprendidos em um problema e aproveitá-los em um problema novo e semelhante. Esta técnica é utilizada quando o conjunto de dados não

é grande o suficiente. Este processo também é aplicado na tentativa de diminuir a profundidade das CNNs, visto que, quanto mais profunda a CNNs mais alto será seu custo computacional. Esta técnica pode ser usada de duas maneiras: extração de recurso e ajuste fino, neste trabalho é abordado a técnica de extração de recursos.

A extração de recurso utiliza o aprendizado obtido por uma rede anterior para extrair recursos significativos em um novo conjunto de amostra, no entanto um novo classificador é adicionado e treinado do zero. Uma economia é realizada, pois a base convolucional responsável por características como bordas, cores e texturas é reaproveitada. Com isso, um novo classificado foi criado para este trabalho, a sua composição apresenta uma função *GlobalAverage-Pooling2D BatchNormalization*, *Dropout* e quatro camadas *Dense.*A função de ativação do tipo *sigmoid* na última camada *Dense.* A Figura 4.4 apresenta o desenho final de uma ResNet 50V2. O classificador criado foi conectado às seguintes arquiteturas ResNet 50V2 e Inception V3. O modelo detalhado da Resnet e Inception encontra-se disponível em: `https://keras.io/api/applications/i`.

Figura 4.4 – Rede Pré-treinada.

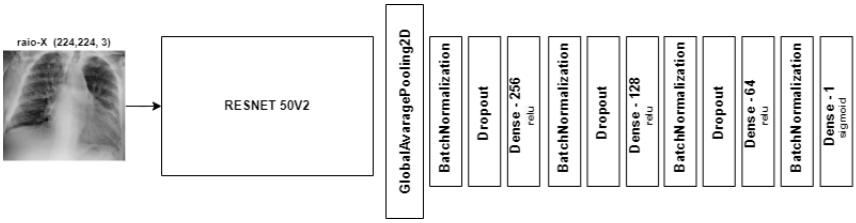

Fonte:Autoria própria

4.4 SANTOS DUMONT

O ambiente utilizado no desenvolvimento desta dissertação foi o Santos Dummont, sendo a solicitação do ambiente aprovada dentro do programa de alocação *Fast-track for COVID-19 SCALAC*, e mais informações da requisição podem ser encontradas no Anexo

B. Um total de mais de 20 mil imagens foram inseridas no ambiente, sendo que essas imagens foram refinadas e pré-processadas para serem usadas nos ensaios apresentados neste capítulo.

A submissão dos ensaios foram realizadas por meio de scripts e submetidos pelo comando *sbatch*. Um exemplo deste do *script* de submissão é apresentado no Apêndice C. Cada submissão é considerada um *job* no Santos Dumont. Informações de como submeter um *job* no Santos Dumont são detalhadas no manual da instituição `https://sdumont.lncc.br/support_manual.php?pg=support`.

4.4.1 Múltiplas GPUs

O ambiente Santos Dumont disponibiliza múltiplas GPUs, para um melhor aproveitamento do ambiente os modelos foram treinados utilizando treinamento distribuído. Para isto, a biblioteca Tensorflow disponibiliza o treinamento em várias GPUs com baixo impacto no código. Para os ensaios foram utilizados *MirroredStrategy* disponibilizado pelo TensorFlow, o qual possibilita o treinamento em várias GPUs. Sua utilização foi aplicada em conjunto com o Keras e mais detalhes de como realizar um implementação distribuída encontra-se disponível no site do Keras (`https://keras.io/guides/distributed_training/`.

4.5 ANÁLISE DE DESEMPENHO DA ARQUITETURA

Para análise quantitativa da arquitetura as seguintes métricas foram selecionadas: acurácia, F1-Score, recall, precisão, matriz de confusão e área da Curva Característica de Operação do Receptor (ROC do inglês *Receiver Operating Characteristic Curve*).

Um modelo de classificação binária submetido a teste produz uma sequência de classificações onde gera classificações que podem ser verdadeiro positivo (VP), verdadeiro negativo (VN), falso positivo (FP) e falso negativo(FN). Esses quatro rótulos de classificação geram a matriz de confusão, que permite analisar o desempenho do modelo proposto. A Figura 4.5 representa o modelo da matriz de

confusão que será utilizada neste projeto.

Figura 4.5 – Matriz de confusão.

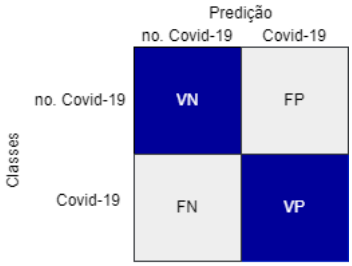

Fonte:Autoria própria

A curva ROC é a representação gráfica que ilustra o desempenho do modelo com classificação binária, ela é composta por dois parâmetros: a Taxa Positiva Verdadeira (TPV), que é sinônimo do *Recall* e a Taxa Falsa Positiva (TFP). O AUC Score é a área sob a curva ROC. A Figura 4.6 é um exemplo de curva ROC, esta figura foi gerada pelo Ensaio I, apresentado na seção 6.1, a AUC Score na Figura 4.6 é de 0.933.

$$TPV = \frac{VP}{VP + FN} \tag{4.1}$$

$$TFP = \frac{FP}{FP + VN} \tag{4.2}$$

Figura 4.6 – Curva ROC do Ensaio I - tamanho do lote 1500.

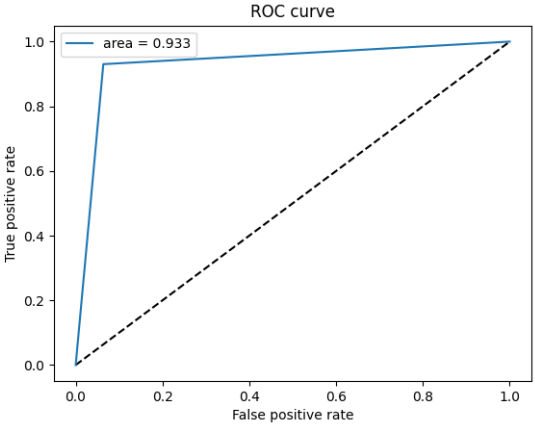

Fonte:Autoria própria

A acurácia é a medida que representa o comportamento do modelo perante as classes existentes. A fórmula da acurácia é definida pela Equação 4.3.

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \tag{4.3}$$

A precisão é calculada conforme apresentada na Equação 4.4 e sua função é apresentar a confiabilidade do modelo na classificação de amostras positivas. Já o *recall* tem a função de medir quantos amostras positivas foram corretamente classificadas. A fórmula para calcular o *recall* é apresentada na Equação 4.6. Quando o objetivo é detectar todas as amostras positivas, sem observar as amostras negativas o *recall* é considerada a melhor opção. A Equação 4.6 é a combinação de precisão com o *recall* gerando assim o F1-Score do modelo.

$$Precisão = \frac{VP}{VP + FP} \tag{4.4}$$

$$Recall = \frac{VP}{VP + FN} \tag{4.5}$$

$$F1 - Score = \frac{2 * Precisão * Recall}{Precisão + Recall} \tag{4.6}$$

4.6 MAPA DE CALOR

Traçar o mapa de calor tem como objetivo visualizar as regiões de ativação de uma imagem ao ser classificada pela CNN. Esta prática ajuda a entender quais partes da imagem foram identificadas como pertencentes a uma determinada classe, ajudando a depurar o processo de decisão da CNN criada (CHOLLET, 2021). A implementação desta funcionalidade é apresentada no Apêndice D. Na elaboração do mapa de calor foi criado um pacote utilizando Python, este pacote é composto por duas funções: *make_ gradcam_ heatmap* e *save_ and_ display_ gradcam*.

A função make_gradcam_heatmap possui três parâmetros obrigatórios: o array da imagem que será mapeada, o modelo da CNN e o nome da última camada convolucional. Essa função consiste em pegar o mapa de característica da última camada convolucional do modelo e analisa com que intensidade a entrada ativa diferentes canais, gerando assim uma mapa que possibilita identificar com que intensidade a imagem de entrada ativa uma determinada classe. A função *save_ and_ display_ gradcam* salva o resultado final do mapeamento de calor realizado pela função make_gradcam_heatmap

5 MÉTODOS

Este capítulo apresenta os procedimentos realizados para obtenção dos resultados apresentados no Capítulo 6

5.1 ENSAIOS

Três ensaios foram elaborados análise da arquitetura CovNet-UFCSPA, são eles:

1. Ensaio I: Efeitos do tamanho do lote.
2. Ensaio II: Arquitetura CovNet-UFCSPA auxiliando no diagnóstico da COVID-19 de pacientes do HCPA.
3. Ensaio III: Análise comparativa de redes pré-treinadas com a arquitetura CovNet-UFCSPA.
4. Ensaio IV: Identificação de casos com e sem COVID-19.

5.2 MÉTODOS DO ENSAIO I

Tamanho do lote do inglês *batch size* é um termo usado em aprendizado de máquina para representar o número de amostras de treinamento usados em uma iteração (CHOLLET, 2021). Buscando analisar o efeito deste hiperparâmetro em uma CNN este ensaio foi realizado.

5.2.1 Divisão dos dados

A composição dos dados para este ensaio é apresentada na Figura 5.1. Para a etapas de treinamento, validação e teste um total de 18 397 imagens foram utilizadas, aplicando uma divisão de 70/30, onde 70% foram das amostras utilizadas em treinamento e validação e 30% para teste do modelo. A Figura 5.1 mostra um desbalanceamento entre as classes, com isto a função *class_ weight* da biblioteca

Sklearn (SKLEARN..., 2022) foi aplicada. Esta função tem a responsabilidade de conscientizar o classificador do desbalanceamento entre as classes, assim o classificador aplicará pesos diferentes para elas.

Figura 5.1 – Composição dos dados do ensaio I.

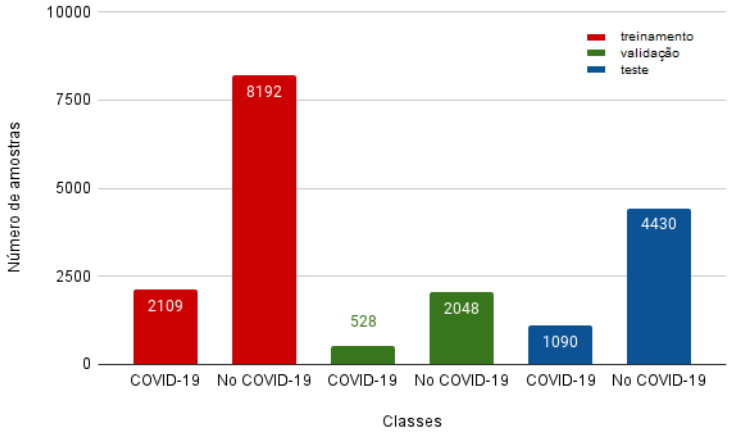

Fonte:Autoria própria

5.2.2 Procedimentos

Para este ensaio a arquitetura CovNet-UFCSPA foi utilizada e os parâmetros para o ensaio estão apresentados na Tabela 5.1.Para a definição da *learning rate* dos ensaio desta pesquisa foram testado os valores: 0.000001, 0.00001 e 0.0001, a que produziu melhores resultados foi a de 0000.1. Com isto, este ensaio e os demais ensaios utilizou uma *learning rate* de 0.00001. Para analisar o efeito do tamanho do lote foram escolhidos seis valores: 32, 200, 500, 1500, 2000 e 5000. Um *job* para cada valor de tamanho de lote foi levantado no Santos Dumont, gerando assim um total de seis *jobs*. 0s demais hiperparâmetros do modelo não variam e seguem os valores da Tabela 5.1. Buscando também avaliar a capacidade de generalização do modelo foi aplicado validação cruzada utilizando biblioteca Sklearn

que disponibiliza a função *StratifiedKFold*. Esta função é uma variação de KFold que retorna dobras estratificadas. As dobras são feitas preservando a porcentagem de amostras para cada classe (CROSS-VALIDATION:. . ., 2022). O número de dobras aplicadas é igual a cinco. A Figura 5.2 apresenta o desenho final do ensaio I.

Para apresentação dos resultados o seguintes critérios foram utilizados:

- Um *job* para cada tamanho de lote, gerando seis *jobs* executadas de forma paralela e independente. Assim, em cada *job* o modelo deve ser treinado, validado e testado.
- O único hiperparâmetro que muda é o tamanho do lote os demais hiperparâmetros possuem o mesmo valor em todos os *jobs* criados. Conforme apresentado na Tabela 5.1.
- Cada *job* realizará validação cruzada utilizando *StratifiedKFold* com valor de dobra igual a cinco.
- Cada *job* deve gerar cinco folds com resultados. O critério de escolha para apresentação do resultado de cada *job* será pegar a maior área da curva ROC dos cincos folds, caso esse valor seja igual em dos cinco folds o critério de desempate será analisar a próxima métrica até desempatar. A ordem das métricas analisadas são acurácia, F-Score, recall e precisão.
- O resultado completo de cada instância está disponível no repositório do GitHub `https://github.com/NouaraCandida/CovNet-UFCSPA`.

Tabela 5.1 – Informações do Ensaio: Efeitos do Tamanho do Lote

Informações	Valor
Arquitetura	CovNet-UFCSPA
Batch size	32/200/500/1500/2000/5000
Learning rate	0.00001
Optimizer	Adam
Dropout	0.4
Loss	Binary Crossentropy
Epoch	500
Cross Validation	StratifiedKFold com 5 dobras

Fonte: Autoria própria

Figura 5.2 – Desenho do Ensaio I.

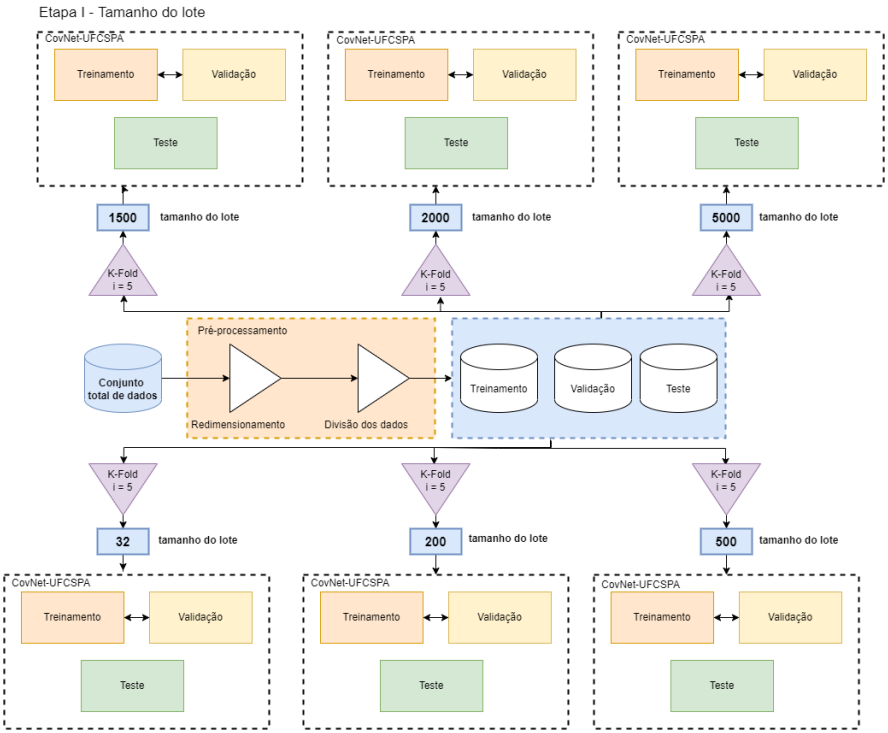

Fonte:Autoria própria

5.3 MÉTODOS DO ENSAIO II

Este ensaio busca identificar a eficiência da arquitetura CovNet-UFCSPA, que foi descrita na subseção 4.3.1, ao ser testada em um conjunto de dados de pacientes brasileiros do HCPA.

5.3.1 Divisão dos dados

Para este ensaio os dados foram divididos em três partes: treinamento, validação e teste. Os dados de treinamento e validação são dados obtidos por meio da revisão integrativa, Apêndice A. Os dados de teste são as imagens adquiridas em parceria com o HCPA. A Figura 5.3 apresenta o resultado desta divisão. Para o ensaio um total de 22 697 imagens foram utilizadas, sendo: 17 504 imagens de treinamento onde 7 504 são de pacientes com COVID-19. Para validação, um total de 4 376 raios-X foram aplicados, sendo 1 876 de pacientes com COVID-19.

A etapa de teste foi realizada exclusivamente com pacientes do HCPA, essas imagens foram adquiridas pelo no projeto "Aplicação de um algoritmo com inteligência artificial para auxílio no diagnóstico de COVID-19" detalhes sobre o projeto é apresentada no Anexo A. Neste projeto foram disponibilizadas raios-X de pacientes com e sem COVID-19, no entanto a disponibilização das imagens foram feitas em períodos diferentes, onde inicialmente o projeto só teve disponibilidade de imagens com COVID-19. Com isto, este ensaio foi realizado teste apenas com imagens de pacientes com COVID-19, visando mostrar a eficiência da rede ao analisar casos positivos.

Para o treinamento do modelo a função class_weight da biblioteca sklearn (SKLEARN..., 2022) foi aplicada, pois conforme é a apresentado na Figura 5.3 existe um desbalanceamento entre as classes na etapa de treinamento.

Figura 5.3 – Composição dos dados do ensaio II e III.

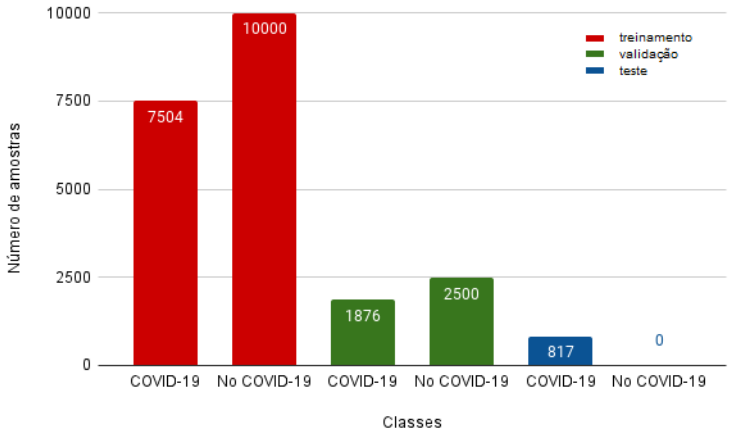

Fonte:Autoria própria

5.3.2 Procedimentos

Para este ensaio apenas um *job* foi submetido ao Santos Dumont. A Tabela 5.3 apresenta os valores dos hiperparâmetros utilizados neste ensaio. A técnica de validação cruzada foi aplicada utilizando a biblioteca sklearn e a função *StratifiedKFold* (CROSS-VALIDATION:. . ., 2022).

Para etapa de teste as imagens originais do HCPA foram pré-processadas, para poder analisar os efeitos de cada pré-processamento realizado o modelo foi testado quatro vezes. Na entrada do modelo todas as imagens foram redimensionadas, inclusive as originais. Os pré-processamentos realizados foram recorte subseção 4.2.2, ECG subseção 4.2.4 e CLAHE subseção 4.2.5.

A Figura 5.4 apresenta todos os procedimentos realizados no ensaio II, na etapa de pré-processamento realizado, as imagens originais foram submetidas a recorte deixando somente as áreas de interesse, em seguida foram aplicadas técnicas de ajuste de contrastes criando assim conjuntos de imagens separadamente. Ao final do pré-

processamento quatro conjuntos de imagens foram criados: imagens originais HCPA, imagens RECORTADAS HCPA, imagens ECG HCPA, imagens CLAHE HCPA. A Figura 5.5 apresenta os conjuntos finais para etapa de teste. A Tabela 5.3 apresenta detalhadamente os processos aplicados em cada conjunto.

A apresentação dos resultados segue os seguintes critérios:

- O modelo é treinado, validado e testado com dobra igual a cinco. No entanto, em cada dobra são executados quatro testes.
- As medidas de precisão, Área ROC, FP e VN não foram aplicadas devido a etapa de teste possuírem somente amostras de pacientes com COVID-19.

Figura 5.4 – Desenho do ensaio II.

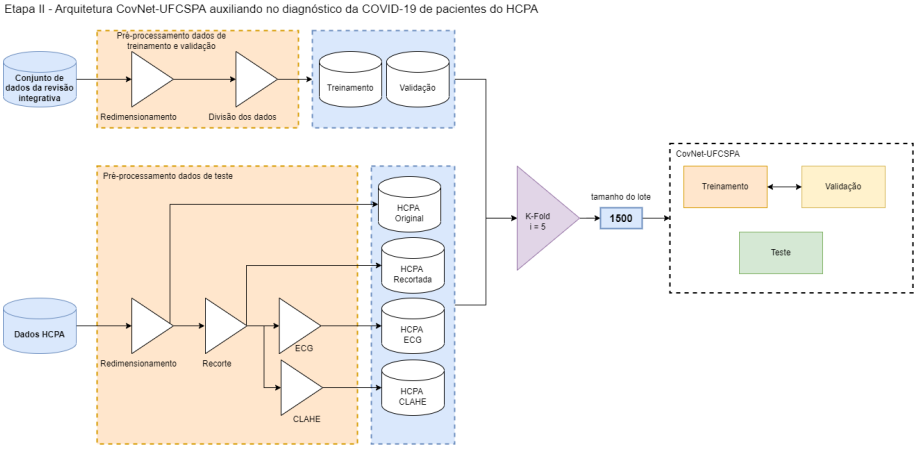

Fonte:Autoria própria

Figura 5.5 – Dados da etapa de teste.

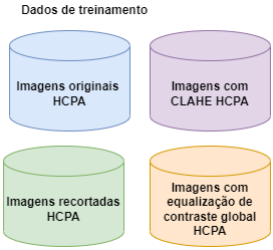

Fonte:Autoria própria

Tabela 5.2 – Conjunto de dados

Etapas	Redimensionamento	Recorte	ECG	CLAHE
Conjunto de treinamento	✓	X	X	X
Conjunto de validação	✓	X	X	X
Conjunto de teste - HCPA original	✓	X	X	X
Conjunto de teste - HCPA recorte	✓	✓	X	X
Conjunto de teste - HCPA ECG	✓	✓	✓	X
Conjunto de teste - HCPA CLAHE	✓	✓	X	✓

Fonte: Autoria própria

Tabela 5.3 – Informações do Ensaio: Arquitetura de CovNet-UFCSPA auxiliando no diagnóstico da COVID-19 de pacientes do HCPA

Informações	Valor
Arquitetura	CovNet-UFCSPA
Batch size	500
Learning rate	0000.1
Optimizer	Adam
Dropout	0.4
Loss	Binary Crossentropy
Epoch	500
Cross Validation	StratifiedKFold com 5 DOBRAS
Ambiente	Santos Dumont - 1 nó - 4 GPUs Tesla V100-SXM2-32GB
Tempo da etapa de pré-processamento	53 minutos
Tempo para treinar o fold 1	1 hora e 7 minutos
Tempo para treinar o fold 2	1 hora e 7 minutos
Tempo para treinar o fold 3	1 hora e 6 minutos
Tempo para treinar o fold 4	1 hora e 7 minutos
Tempo para treinar o fold 5	1 hora e 7 minutos

Fonte: Autoria própria

5.4 MÉTODOS DO ENSAIO III

O objetivo deste ensaio é realizar uma análise do desempenho da arquitetura CovNet-UFCSPA para identificação de pacientes com COVID-19. Para isto, este ensaio executará outros modelos pré-treinados:Resnet50 V2 e Inception V3. A arquitetura deste modelos foram descritas na subseção 4.3.2. Para avaliação quantitativa desta comparação as seguintes métricas serão utilizadas: acurácia, F-Score, recall, matriz de confusão, curva ROC e tempo de execução do ensaio. As medidas de precisão e as taxas de FP e VN não serão aplicadas devido ao conjunto de dados nesta etapa possuírem somente pacientes com COVID-19.

5.4.1 Procedimentos

Para este ensaio três *jobs* foram submetidos no Santos Dumont, cada *job* é responsável pelo treinamento, validação e teste de cada modelo. O conjunto de dados é o mesmo descrito na subseção 5.3.1, logo na etapa de teste 817 imagens de pacientes diagnosticados com COVID-19 pelo hospital HCPA serão utilizadas. As etapas de pré-processamento dos dados de teste são as mesmas aplicadas no Ensaio II, detalhes de cada etapa é apresentado na Tabela 5.2. A Figura 5.6 apresenta o desenho final do ensaio III e a Tabela 5.4 apresenta os valores dos hiperparâmetros e o tempo de execução de cada arquitetura testada.

Tabela 5.4 – Informações do Ensaio: Arquitetura de CovNet-UFCSPA auxiliando no diagnóstico da COVID-19 de pacientes do HCPA

Informações	**Valor**
Batch size	1500
Learning rate	0000.1
Optimizer	Adam
Dropout	0.4
Loss	Binary Crossentropy
Epoch	250
Cross Validation	Não aplicado
Ambiente	Santos Dumont - 1 nó - 4 GPUs Tesla V100-SXM2-32GB
Tempo da etapa de pré-processamento	53 minutos
Tempo para treinar CovNet-UFCSPA	1 hora e 7 minutos
Tempo para treinar ResNet 50 V2	1 hora e 20 minutos
Tempo para treinar Inception V3	1 hora e 15 minutos

Fonte: Autoria própria

Figura 5.6 – Desenho do ensaio III.

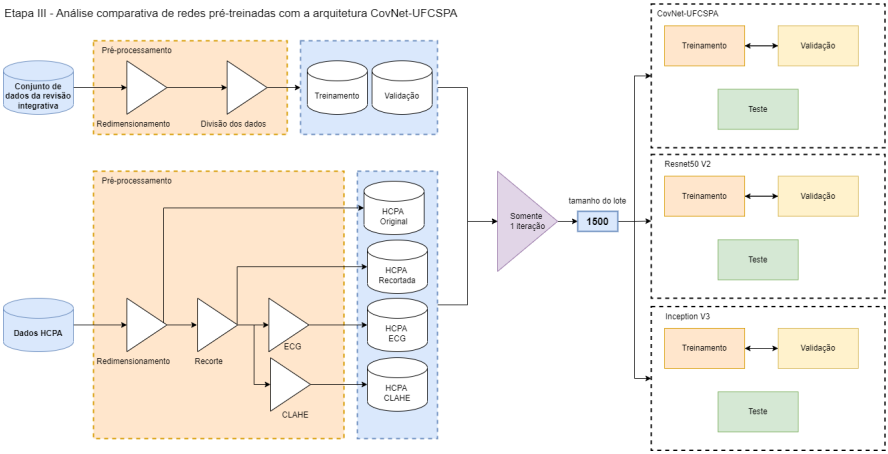

Fonte:Autoria própria

5.5 MÉTODOS DO ENSAIO IV: IDENTIFICAÇÃO DE CASOS COM E SEM COVID-19

O objetivo deste ensaio é realizar uma análise do comportamento das redes implementadas. Para isto, este ensaio executará os seguintes modelos: Resnet50 V2, Inception V3 e CovNet-UFCSPA. A arquitetura e detalhes da implementação destes modelos foram descritas na subseção 4.3.2 e na subseção 4.3.1. Para avaliação quantitativa deste ensaio as seguintes métricas serão utilizadas: acurácia, F-Score, recall, matriz de confusão, curva ROC e tempo de execução do ensaio. Além disso, as medidas de precisão e as taxas de FP e VN serão aplicadas devido a este conjunto de dados conter pacientes com e sem COVID-19.

5.5.1 Procedimentos

Para este ensaio quatro *jobs* foram submetidos no Santos Dumont, cada *job* realizou o teste de cada modelo. Neste ensaio não foi realizado o treinamento e validação, pois foi utilizado o melhor

resultado dos ensaios anteriores. Com isso um arquivo de extensão H5 foi carregado, neste arquivo foi salvo todo o progresso do modelo durante a etapa de treinamento (`https://www.tensorflow.org/tutorials/keras/save_and_load`).

A etapa de teste é composta por 817 imagens de pacientes diagnosticados com COVID-19 e 721 imagens sem COVID-19, todas essas imagens de teste receberam laudo do HCPA. Na figura Figura 5.7 apresenta a composição de dados deste ensaio, as etapas de treinamento e validação não foram realizadas neste ensaio, no entanto os arquivos H5 utilizados foram testados e validados com 21 880 imagens conforme apresentado na imagem abaixo.

Figura 5.7 – Composição dos dados do ensaio IV.

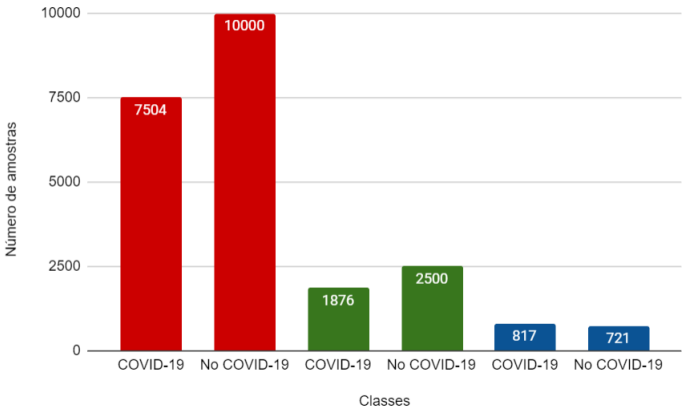

Fonte:Autoria própria

As etapas de pré-processamento dos dados de teste são as mesmas aplicadas no Ensaio II e III, no entanto mais um conjunto de dados foi criado, como apresentado na Figura 5.8. Este conjunto é identificado como Misto e é composto por 817 imagens com COVID-19 e 721 imagens sem COVID-19. Neste conjunto o pré-processamento executado foi de apenas recorte e redimensionamento para as imagens sem COVID-19 e recorte, redimensionamento e

CLAHE para imagens com COVID-19.

Figura 5.8 – Desenho do ensaio IV.

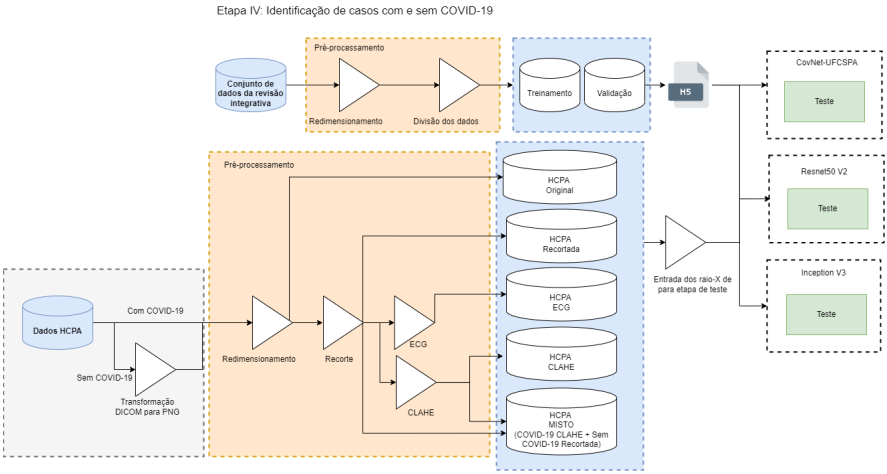

Fonte:Autoria própria

O recebimento das imagens sem COVID-19 ocorreu posteriormente ao recebimento da imagens com COVID-19. Este conjunto de dados recebido tem o formato DICOM, para utilização na etapa de teste as imagens recebidas foram transformadas para o formato PNG. A criação deste novo conjunto de dados ocorreu ao analisar o histograma das imagens sem COVID-19, onde foi possível observar que as imagens sem COVID-19 possui uma distribuição de escala cinza muito superior quando comparada com as imagens com COVID-19, conforme apresentado na Figura 5.9. A Tabela 5.5 apresenta todos os hiperparâmetros utilizados neste ensaio.

Figura 5.9 – Histograma de raio-X com COVID-19

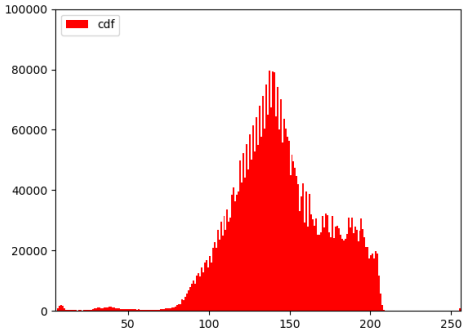

(a) Imagem original de um paciente com COVID-19 do HCPA

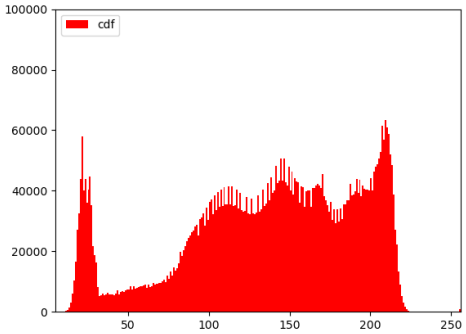

(b) Histograma de raio-X sem COVID-19

Tabela 5.5 – Informações do Ensaio: Identificação de casos com e sem COVID-19

Informações	**Valor**
Batch size	1500
Learning rate	0000.1
Optimizer	Adam
Dropout	0.4
Loss	Binary Crossentropy
Epoch	250
Cross Validation	Não aplicado
Ambiente	Santos Dumont - 1 nó - 4 GPUs Tesla V100-SXM2-32GB
Tempo da etapa de pré-processamento	30 minutos
Tempo para teste CovNet-UFCSPA	15 minutos
Tempo para teste ResNet 50 V2	17 minutos
Tempo para teste Inception V3	15 minutos

Fonte: Autoria própria

6 RESULTADOS E DISCUSSÃO

6.1 ENSAIO I: EFEITOS DO TAMANHO DO LOTE

6.1.1 Resultados

Seguindo os critérios de apresentação de resultados apresentado na subseção 5.2.2, a Figura 6.1a e Figura 6.1b apresenta a curva de acurácia na etapa de treinamento e validação respectivamente. A Figura 6.1c e Figura 6.1d apresenta a curva de erro na etapa de treinamento e validação respectivamente.

O ensaio mostra que ao utilizar um lote igual a 32 um alto nível de ruído é apresentado tanto na curva da acurácia, Figura 6.2a, quanto na do erro, Figura 6.3a, mostrando que não há uma estabilização do modelo, pois uma alta variância entre o conjunto de amostra de treinamento e validação é apresentada, caracterizando assim *overfitting* do modelo.

Ao aumentar o tamanho do lote para 200 ocorre um acréscimo de 625% nas amostras que são utilizadas a cada iteração. Isto acarreta em um nível de ruído menor, como apresentado na curva de acurácia Figura 6.2b. O mesmo acontece com a curva de erro, Figura 6.2b, onde o pico de erro que anteriormente teve valor máximo de dois não ocorre mais.

As curvas de erro na etapa de validação nos ensaios com lote de 1500, 2000 e 5000 geraram uma variação menor quando comparado os ensaios com tamanho do lote de 32, 200 e 500. Está menor variância pode ser observada na Figura 6.1c. No entanto, a curva de acurácia, conforme apresentado nas Figura 6.2e e Figura 6.2f, com tamanho de lote de 2000 e 5000 começa a apresentar sinais de *underfitting*, pois a precisão do conjunto de dados de validação é maior do que a precisão dos dados de treinamento.

A Tabela 6.1 apresenta os resultados finais deste ensaio. Um total de 5 520 imagens foram testadas, sendo 4 430 normal e 1 090

COVID-19. Esta tabela apresenta os resultados dos seis *job* criado, e os cincos folds de cada job, visto que a técnica de KFold foi aplicada neste ensaio. As variáveis medidas foram: precisão, recall, F-Score, acurácia e matriz de confusão.

O modelo onde o tamanho do lote é de 32 apresentou acurácia de 97% nos folds 1, 3 e 4, no entanto o fold 3 foi o que melhor classificou os pacientes com COVID-19, gerando 1 020 resultados VP e 70 FN. Além disto, o fold 5 foi o que gerou menor acurácia, neste fold o número de FP foi de 1 450 refletindo assim nas demais métricas. A baixa acurácia, 74%, do fold 5 mostra que o modelo com tamanho de lote igual a 32 possui dificuldade de prever diferentes conjuntos de amostras. Esta dificuldade pode ser correlacionada com as curvas apresentada na Figura 6.2a e Figura 6.3a onde é apresentada uma alta variância entre os resultados de treinamento e validação mostrando que o modelo apresenta sinais de *overfitting*.

O segundo *job* levantado processou o modelo onde o tamanho do lote é igual a 200 e a sua acurácia variou entre 91% a 97% nos cincos folds. Este modelo apresentou a melhor média de acurácia quando comparada aos demais modelos com diferentes tamanho de lote.

Os resultados dos modelos com tamanho de lote igual a 1500 apresentaram acurácia entre 91% e 94%. Já o modelo com lote igual a 2000 a acurácia varia entre 87% a 94%. Uma variação de 89% a 95% na acurácia é apresentada no modelo com tamanho de lote igual a 5000.

Figura 6.1 – Resultados do ensaio I

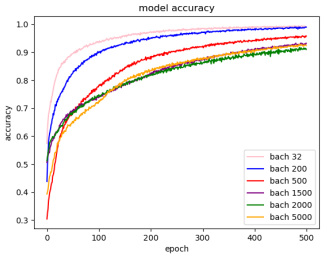

(a) Curva de acurácia na etapa de treinamento

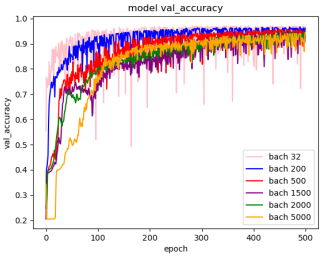

(b) Curva de acurácia na etapa de validação

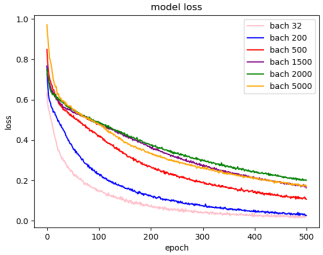

(c) Curva loss na etapa de treinamento

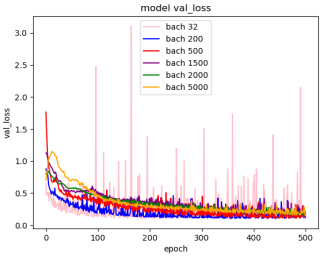

(d) Curva loss na etapa de validação

Fonte:Autoria própria.

Figura 6.2 – Curva de acurácia segmentado por batch do ensaio I

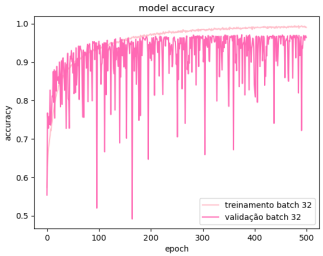

(a) Curva de acurácia na etapa de treinamento e validação com batch size de 32

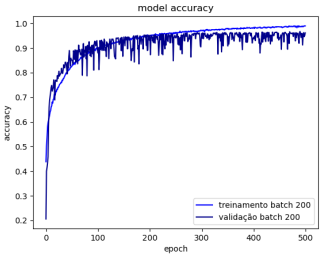

(b) Curva de acurácia na etapa de treinamento e validação com batch size de 200

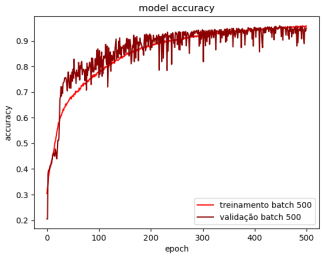

(c) Curva de acurácia na etapa de treinamento e validação com batch size de 500

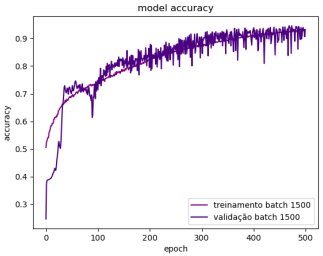

(d) Curva de acurácia na etapa de treinamento e validação com batch size de 1500

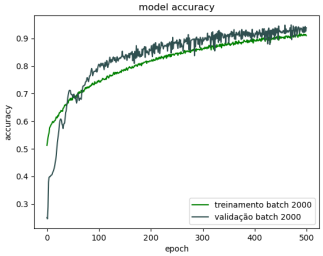

(e) Curva de acurácia na etapa de treinamento e validação com batch size de 2000

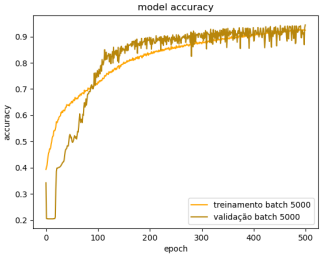

(f) Curva de acurácia na etapa de treinamento e validação com batch size de 5000

Fonte:Autoria própria.

Figura 6.3 – Curva de erro segmentado por batch do ensaio I

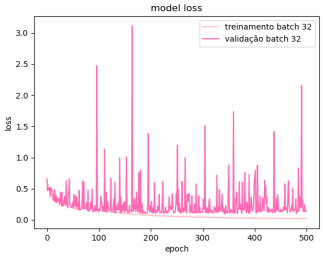

(a) Curva de erro na etapa de treinamento e validação com batch size 32

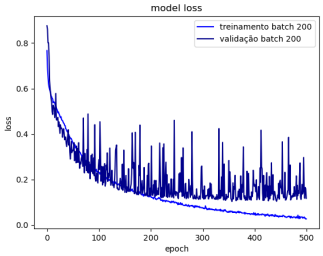

(b) Curva de erro na etapa de treinamento e validação com batch size 200

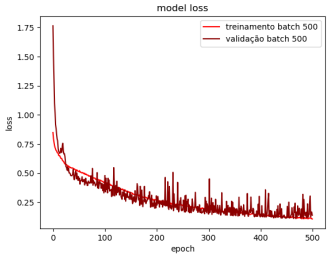

(c) Curva de erro na etapa de treinamento e validação com batch size 500

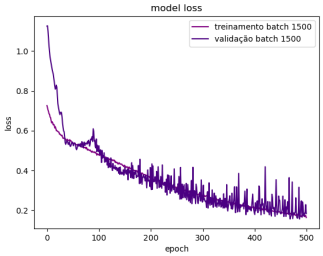

(d) Curva de erro na etapa de treinamento e validação com batch size 1500

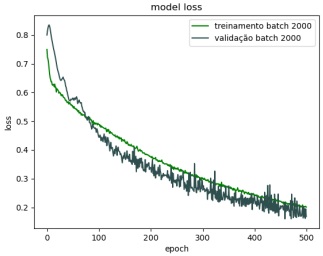

(e) Curva de erro na etapa de treinamento e validação com batch size 2000

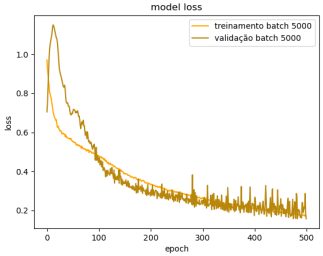

(f) Curva de erro na etapa de treinamento e validação com batch size 5000

Fonte:Autoria própria.

Tabela 6.1 – Tabela de resultados Ensaio I Arquitetura CovNet-UFCSPA

Arquitetura	Folds	Métricas								
		Precisão	Recall	F-Score	Acurácia	Área ROC	Matriz de confusão			
							VP	FN	FP	VN
Arquitetura CovNet-UFCSPA Tamanho do lote 32	Fold 1	92%	92%	92%	97%	0.953	1007	83	83	4347
	Fold 2	98%	81%	89%	96%	0.905	887	203	15	4415
	Fold 3	90%	93%	91%	97%	0.953	1017	73	116	4314
	Fold 4	93%	94%	93%	97%	0.959	1020	70	76	4354
	Fold 5	43%	99%	60%	74%	0.834	1084	6	1450	2980
Arquitetura CovNet-UFCSPA Tamanho do lote 200	Fold 1	93%	86%	89%	96%	0.922	938	152	76	4354
	Fold 2	89%	94%	91%	97%	0.955	1023	67	124	4306
	Fold 3	92%	90%	91%	97%	0.940	978	112	80	4350
	Fold 4	86%	94%	90%	96%	0.954	1030	60	162	4268
	Fold 5	73%	96%	83%	91%	0.935	1041	49	381	4049
Arquitetura CovNet-UFCSPA Tamanho do lote 500	Fold 1	81%	95%	87%	94%	0.946	1036	56	250	4180
	Fold 2	76%	94%	84%	93%	0.933	1023	67	321	4109
	Fold 3	81%	94%	87%	94%	0.942	1025	65	247	4183
	Fold 4	70%	97%	81%	91%	0.933	1056	34	456	3974
	Fold 5	82%	94%	87%	95%	0.944	1024	66	231	4199
Arquitetura CovNet-UFCSPA Tamanho do lote 1500	Fold 1	78%	93%	85%	94%	0.933	1014	76	282	4148
	Fold 2	81%	89%	85%	94%	0.920	974	116	234	4196
	Fold 3	81%	91%	85%	94%	0.927	989	101	237	4193
	Fold 4	77%	94%	85%	93%	0.936	1026	64	307	4123
	Fold 5	69%	95%	80%	91%	0.924	1038	52	459	3971
Arquitetura CovNet-UFCSPA Tamanho do lote 2000	Fold 1	61%	95%	74%	87%	0.898	1031	59	665	3765
	Fold 2	74%	88%	80%	91%	0.901	959	131	344	4086
	Fold 3	79%	93%	85%	94%	0.933	1009	81	262	4168
	Fold 4	76%	92%	83%	93%	0.923	1001	89	318	4112
	Fold 5	69%	93%	79%	90%	0.915	1019	71	451	3969
Arquitetura CovNet-UFCSPA Tamanho do lote 5000	Fold 1	83%	91%	87%	95%	0.931	968	102	201	4229
	Fold 2	68%	94%	79%	90%	0.917	1028	62	484	3946
	Fold 3	67%	94%	78%	90%	0.912	1021	69	503	3927
	Fold 4	72%	95%	82%	92%	0.931	1036	54	396	4034
	Fold 5	66%	94%	78%	89%	0.911	1024	66	524	3906

Fonte:Autoria própria.

6.2 ENSAIO II: ARQUITETURA COVNET-UFCSPA AUXILIANDO NO DIAGNÓSTICO DA COVID-19 DOS PACIENTES DO HCPA

6.2.1 Resultados

Os resultados da arquitetura CovNet-UFCSPA são apresentados nesta seção. As curvas de acurácia realizadas na etapa de treinamento e validação é apresentada nas Figura 6.4a e Figura 6.4b, é possível identificar que nos cinco folds o modelo possui convergência. Nas Figura 6.4c e Figura 6.4d é apresentado os resultados de erro na etapa de treinamento e validação respectivamente.

Figura 6.4 – Curvas de acurácia e erro utilizando CovNet-UFCSPA com imagens de pacientes com COVID-19 do HCPA

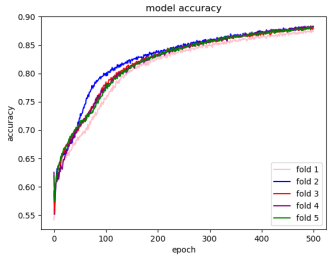

(a) Curvas de acurácia dos cinco folds na etapa de treinamento

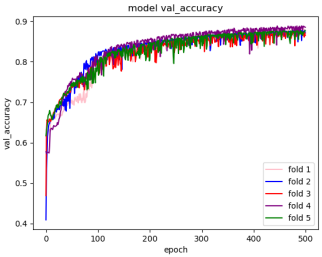

(b) Curvas de acurácia dos cinco folds na etapa de validação

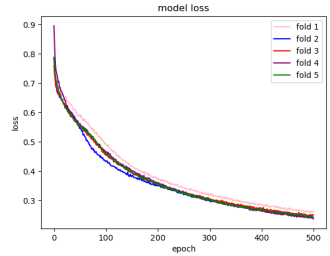

(c) Curvas de erro dos cinco folds na etapa de treinamento

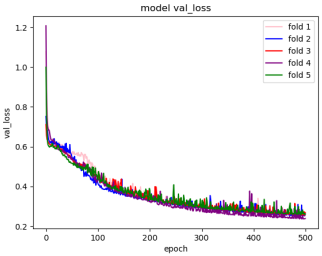

(d) Curvas de erro dos cinco folds na etapa de validação

Fonte:Autoria própria.

Conforme apresentado na subseção 5.3.1, os dados de teste foram dados de pacientes diagnosticados com COVID-19 do HCPA, este ensaio não utilizou dados de paciente com raio-x do tórax sem COVID-19. Assim, as métricas de FP, VN e área da curva ROC não apresentam valores. A Tabela 6.2 apresenta os resultados dos cinco folds aplicados a arquitetura CovNet-UFCSPA, na tabela é possível identificar o efeito do pré-processamento no conjunto de teste. O fold 1 do conjunto de dados com imagens originais obteve um *receall* de 86% sendo que das 817 imagens 706 foram diagnosticada corretamente. Já o teste do fold 1 que recebeu as imagens recortadas obteve um *recall* de 98% onde 804 imagens foram classificadas corretamente e 13 receberam uma classificação incorreta. Ao comparar estes dois

cenários é possível identificar que ao recortar as imagens originais e deixar somente as áreas de interesse um ganho de 12% no *recall* é apresentado.

A Figura 5.4 mostra que o conjunto de imagens com ECG e CLAHE sofreram o processo de recorte, no entanto quando comparamos o fold 1 das imagens que sofreram ECG com o fold 1 das imagens recortadas e das imagens com CLAHE é possível identificar que o uso de ECG trouxe uma perda no *recall* e na taxa de VP. No entanto, o fold 1 com aplicação de CLAHE mostra um ganho de 1% no *recall* quando comparada com o fold 1 do conjunto de imagens recortadas. Com isto, o fold 1 das imagens com CLAHE obteve um *recall* de 99% onde das 817 imagens, 806 foram classificadas corretamente.

Sinais de melhor *recall* do conjunto de dados com CLAHE podem ser verificados na Tabela 6.2, por exemplo: acréscimo de 5% no *recall* é apresentado no fold 2 quando realizada uma comparação com o fold 2 das imagens recortadas.

Tabela 6.2 – Tabela de resultados Ensaio I Arquitetura CovNet-UFCSPA

Arquitetura	Folds	Métricas								
		Precisão	Recall	F-Score	Acurácia	Área ROC	Matriz de confusão			
							VP	FN	FP	VN
CovNet-UFCSPA Imagens Originais	Fold 1	-	86%	93%	86%	-	705	112	0	0
	Fold 2	-	77%	87%	77%	-	627	190	0	0
	Fold 3	-	79%	88%	79%	-	647	170	0	0
	Fold 4	-	81%	90%	81%	-	663	154	0	0
	Fold 5	-	81%	89%	81%	-	660	157	0	0
CovNet-UFCSPA Imagens Recortadas	Fold 1	-	98%	99%	98%	-	804	13	0	0
	Fold 2	-	90%	95%	90%	-	733	84	0	0
	Fold 3	-	91%	95%	91%	-	740	77	0	0
	Fold 4	-	94%	97%	94%	-	769	48	0	0
	Fold 5	-	94%	97%	94%	-	764	53	0	0
CovNet-UFCSPA Imagens ECG	Fold 1	-	94%	97%	94%	-	768	49	0	0
	Fold 2	-	85%	92%	85%	-	692	125	0	0
	Fold 3	-	81%	90%	81%	-	665	152	0	0
	Fold 4	-	87%	93%	87%	-	709	108	0	0
	Fold 5	-	90%	90%	90%	-	733	84	0	0
CovNet-UFCSPA Imagens CLAHE	Fold 1	-	99%	99%	99%	-	806	11	0	0
	Fold 2	-	95%	97%	95%	-	777	40	0	0
	Fold 3	-	95%	98%	95%	-	780	37	0	0
	Fold 4	-	97%	98%	97%	-	789	28	0	0
	Fold 5	-	97%	99%	97%	-	793	24	0	0

Fonte:Autoria própria.

6.2.1.1 Mapa de Calor

A implementação do mapa de calor foi aplicada para rastrear quais são as áreas que a arquitetura CovNet-UFCSPA levou em

consideração ao classificar uma imagem com ou sem COVID-19, a execução deste ensaio foi realizado na subseção 6.2.1. Todas as 817 imagens foram mapeadas, nesta seção serão discutidos três casos, conforme apresentado na Tabela 6.3. Esta tabela apresenta a classe rotulada de cada caso, todos os casos selecionados foram obtidos de imagens de pacientes com COVID-19 do HCPA, nas demais colunas está apresentado o valor da predição gerada pelo modelo, assim quanto mais perto de 100% mais certeza o modelo teve ao classificar a classe da imagem, esse valor foi denominado de *score*

O primeiro caso mostra que o modelo, ao receber a imagem original do HCPA rotulou o *score* em 45%, porém ao classificar uma imagem recortada o *score* é de 94%. As imagens com ajuste de contraste receberam um *score* de 91% para imagens que passaram pelo processo de ECG e 98% para imagens com CLAHE. O mapa de calor das quatro imagens do primeiro caso é apresentado na Figura 6.5. Na figura as áreas que a tonalidade se aproxima do vermelho significa que o modelo entende que possui uma maior relevância para a classe de COVID-19. As áreas de ativação das Figura 6.5b e da Figura 6.5d possuem regiões de ativação similares. No entanto quando comparada às imagens que sofreram um processo de ajuste de contraste, como na Figura 6.5f e na Figura 6.5h, as áreas de ativação são diferentes.

O Caso II mostra um *score* de 35% quando o modelo é testado com uma imagem original do HCPA, classificando de forma errada como mais próxima da classe não COVID-19. A Figura 6.6b mostra a dificuldade do modelo ao classificar a imagem original, nela a área de ativação é distante da área de interesse, o tórax. Ao executar o recorte da imagem o modelo apresenta um *score* de 86% e a área de ativação está dentro da região de interesse, conforme apresentado na Figura 6.6d. Ao analisar as áreas de ativação das imagens que sofreram ajuste de contraste, Figura 6.6f e Figura 6.6h é possível identificar pontos comuns. No entanto, ao analisar o *score* uma grande diferença é apresentada, sendo o *score* de 36% para imagens com ECG e 98% para imagens com CLAHE.

No terceiro caso tanto a imagem original do HCPA quanto

as pré-processadas foram classificadas como não COVID-19, sendo esta classificação errada. Ao analisar as Figura 6.7b, Figura 6.7d, Figura 6.7f e Figura 6.7h é possível ver que o mapa de ativação são distintos nas quatros iamgens, porém observando as características da imagem é possível identificar grande presença de fios, cabos e objetos.

Tabela 6.3 – Conjunto de dados

Informações	Classe Rotulada	*Score* originais	*Score* recortadas	*Score* ECG	*Score* CLAHE
Caso I	COVID-19	45%	94%	91%	98%
Caso II	COVID-19	35%	86%	36%	98%
Caso III	COVID-19	0%	0%	0%	0%

Fonte: Autoria própria

Figura 6.5 – Mapa de calor - Caso I



(a) Imagem original

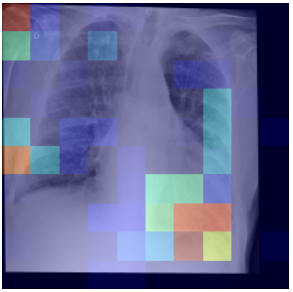

(b) Mapeamento da imagem original

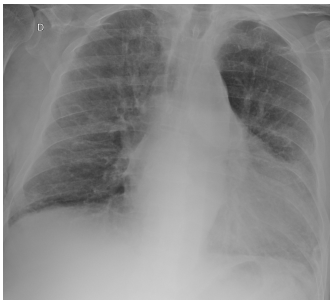

(c) Imagem recortada

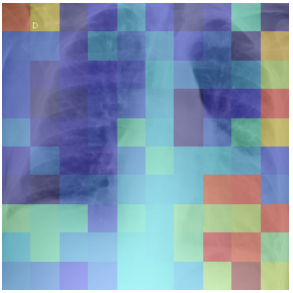

(d) Mapeamento da imagem recortada

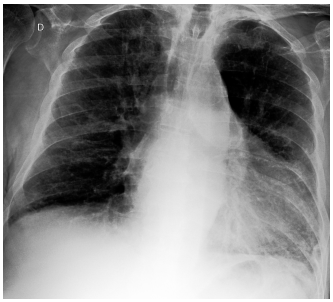

(e) Imagem EGC

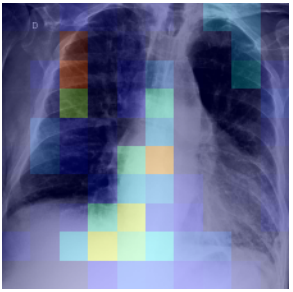

(f) Mapeamento da imagem ECG



(g) Imagem CLAHE

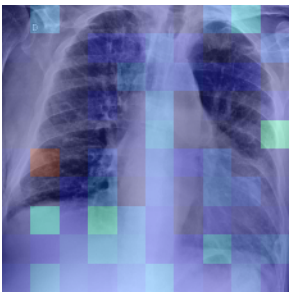

(h) Mapeamento da imagem CLAHE

Figura 6.6 – Mapa de calor - Caso II

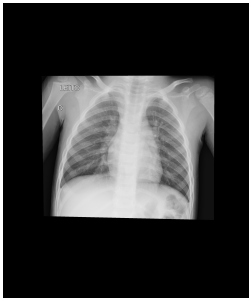

(a) Imagem original

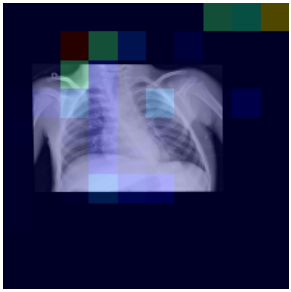

(b) Mapeamento da imagem original

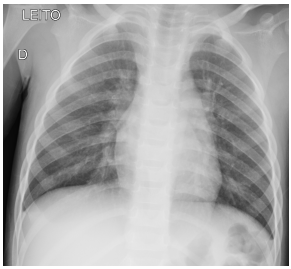

(c) Imagem recortada

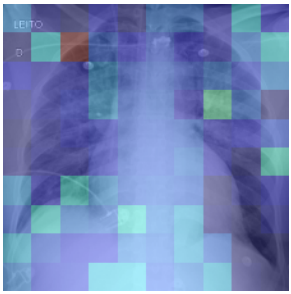

(d) Mapeamento da imagem recortada

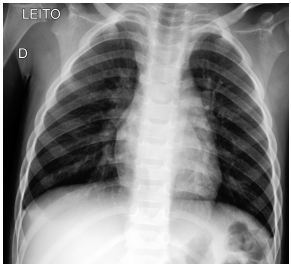

(e) Imagem EGC

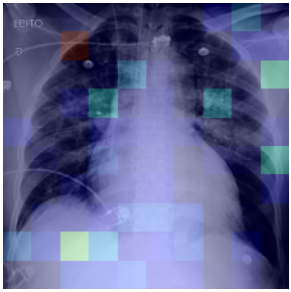

(f) Mapeamento da imagem ECG

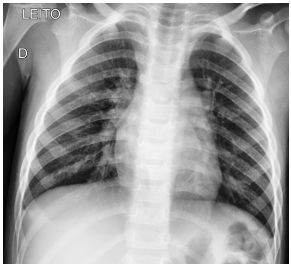

(g) Imagem CLAHE

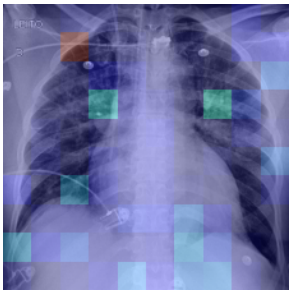

(h) Mapeamento da imagem CLAHE

Figura 6.7 – Mapa de calor - Caso III

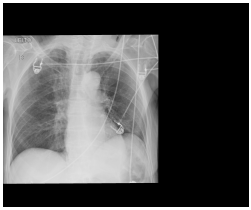

(a) Imagem original

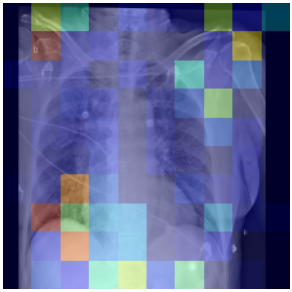

(b) Mapeamento da imagem original

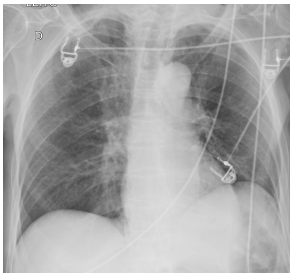

(c) Imagem recortada

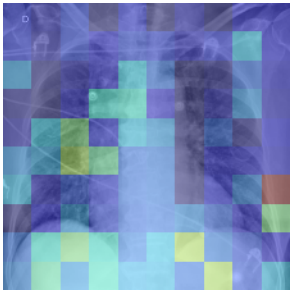

(d) Mapeamento da imagem recortada

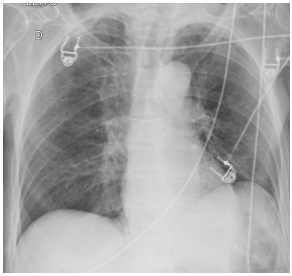

(e) Imagem EGC



(f) Mapeamento da imagem ECG

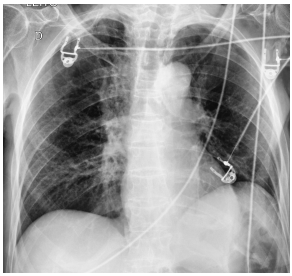

(g) Imagem CLAHE

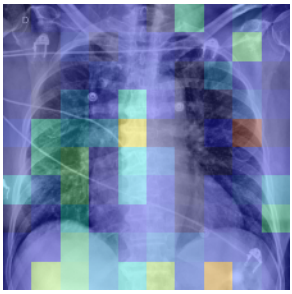

(h) Mapeamento da imagem CLAHE

6.3 ENSAIO III: ANÁLISE COMPARATIVA DE REDES PRÉ-TREINADAS COM A ARQUITETURA COVNET-UFCSPA

6.3.1 Resultados

A Tabela 6.4 apresenta os resultados deste ensaio. Ao comparar a matriz de confusão dos quatro conjuntos de teste, a técnica de CLAHE novamente mostrou-se relevante para o desempenho do modelo, pois as menores taxas de FN são deste conjunto de dados. A arquitetura CovNet-UFCSPA obteve as melhores métricas de VP e FN, em todos os quatro conjuntos de dados. Em seguida o modelo Resnet50 V2 obteve os melhores resultados, exceto no conjunto de dados de imagens recortadas, onde neste caso a Inception V3 teve uma taxa de FN menor.

O *recall* é a métrica que observa o desempenho da rede em relação às amostras positivas (com COVID-19) a CovNet-UFCSPA demonstrou melhor resultado com um valor de 99%, em seguida Resnet50 V2 com 97% e Inception V3 com 95% sendo todos no conjunto de dados com CLAHE.

O tempo de execução da arquitetura CovNet-UFCSPA é o menor, pois o modelo possui menos camadas convolucionais, levando 1 hora e 7 minutos para ser executado. Porém as redes pré-treinadas aplicaram a técnica de extração de recurso, devido a isto os modelos Resnet50 V2 e Inception V3 tiveram tempo de execução próximos da CovNet-UFCSPA. Porém mesmo utilizando redes pré-treinadas ao aplicar uma tamanho de lote igual a 1000,os modelos Resnet50 V2 e Inception V3 necessitam de treinamento distribuído. Para isto a técnica de *MirroredStrategy* foi aplicada, detalhes desta técnica é descrita na subseção 4.4.1.

Tabela 6.4 – Tabela de resultados Ensaio III

Conjunto de dados	Arquitetura	Métricas								
		Precisão	Recall	F-Score	Acurácia	Área ROC	Matriz de confusão			
							VP	FN	FP	VN
Imagens Originais	CovNet-UFCSPA	-	77%	87%	77%	-	631	187	0	0
	ResNet50 V2	-	62%	76%	62%	-	506	312	0	0
	Inception V3	-	71%	83%	71%	-	578	240	0	0
Imagens Recortadas	CovNet-UFCSPA	-	97%	98%	97%	-	792	25	0	0
	ResNet50 V2	-	80%	89%	80%	-	650	167	0	0
	Inception V3	-	81%	89%	81%	-	659	158	0	0
Imagens ECG	CovNet-UFCSPA	-	91%	96%	91%	-	747	70	0	0
	ResNet50 V2	-	89%	94%	84%	-	725	92	0	0
	Inception V3	-	83%	90%	83%	-	675	142	0	0
Imagens CLAHE	CovNet-UFCSPA	-	99%	99%	99%	-	808	9	0	0
	ResNet50 V2	-	94%	97%	94%	-	770	47	0	0
	Inception V3	-	90%	95%	90%	-	738	79	0	0

Fonte:Autoria própria.

6.4 MÉTODOS DO ENSAIO IV: IDENTIFICAÇÃO DE CASOS COM E SEM COVID-19

Para este ensaio um total de 1538 imagens foram utilizadas neste ensaio, onde 817 são de pacientes com COVID-19 e 721 são de pacientes sem COVID-19. A Tabela 6.5 apresenta os resultados deste ensaio para as arquiteturas CovNet-UFCSPA, ResNet50 V2 e Inception V3.

O conjunto de dados mistos obteve os melhores resultados, onde a arquitetura CovNet-UFCSPA apresentou 36 classificações de casos FN, compondo assim 2.34% das imagens, porém obteve 242 classificações de FP, gerando uma taxa 15.7% de FP. A Resnet50 V2 possui 63 FN e 175 FP gerando assim um taxa de 4.1% de FN e 11.38% de FP. Os resultados da Inception V3 mostraram ser menos satisfatório quando comparado às outras arquiteturas, suas classificações geraram 70 casos de FN e 407 casos de FP, gerando assim uma taxa de 4.55% de FN e 26.46% de FP.

A aplicação de CLAHE em todas as imagens, não mostrou bons resultados a acurácia da CovNet-UFCSPA foi de 59% e sua área ROC é de 0.574. A arquitetura Resnet50 V2 obteve uma acurácia de 78% e área ROC de 0.774 apresentando o melhor resultado deste conjunto de dados. A Inception V3 apresentou uma acurácia 55% e área ROC de 0.54.

O conjunto de dados recortadas apresentou o segundo melhores resultados, quando comparado aos outros conjuntos de teste

deste ensaio. Este conjunto de dados ao ser classificado pelas arquiteturas apresentou acurácia de 80% (CovNet-UFCSPA), 77% (ResNet50 V2) e 65% (Inception V3).

O ensaio III, seção 6.3, utilizou somente as imagens com COVID-19, e ao aplicar o pré-processamento de CLAHE mostrou uma redução de FN, onde as imagens originais tiveram uma classificação de 112 FN e as imagens com CLAHE 11 FN. Porém, no ensaio realizado nesta seção onde foi criado um conjunto de dados com e sem COVID-19 a aplicação de CLAHE em todas as imagens não mostrou-se eficiente. Quando analisada as métricas da Tabela 6.5 encontra-se uma precisão de 54% (CovNet-UFCSPA), 54% (Inception V3) e 72% (ResNet50- V2), com isto identifica-se que a aplicação de CLAHE diminuiu a confiabilidade dos modelos na classificação de amostras positivas neste ensaio. Está redução da precisão ocorreu devido ao conjunto de dados deste ensaio ser composto por imagens de diferentes qualidades, e ao extrair o histograma destas imagens, Figura 5.9, foi possível identificar que as imagens recebidas do HC-PA sem COVID-19 possui uma qualidade superior, sendo assim foi criado um conjunto de dados Misto, conforme descrito na seção 5.5.

A melhor acurácia obtida é a do conjunto de dados Misto onde a Resnet50 V2 apresentou 85% de acurácia e a CovNet-UFCSPA obteve uma valor de 82%, mostrando uma redução de mais de 10% quando comparado aos resultados do ensaio I. Essa redução da acurácia está relacionada a alguns fatores: número reduzido de imagens com COVID-19, pacientes com características sociodemográficas diferentes e diferenças na forma de obtenção das imagens, trazendo assim uma variação na qualidade das imagens.

Tabela 6.5 – Tabela de resultados Ensaio IV

Conjunto de dados	Arquitetura	Métricas								
		Precisão	Recall	F-Score	Acurácia	Área ROC	Matriz de confusão			
							VP	FN	FP	VN
Imagens Originais	CovNet-UFCSPA	72%	76%	74%	72%	0.720	619	199	244	527
	ResNet50 V2	70%	51%	59%	64%	0.641	417	401	176	595
	Inception V3	59%	71%	64%	59%	0.590	579	239	407	364
Imagens Recortadas	CovNet-UFCSPA	75%	91%	83%	80%	0.798	745	72	244	527
	ResNet50 V2	78%	78%	78%	77%	0.774	635	182	176	595
	Inception V3	62%	81%	70%	65%	0.641	662	155	407	364
Imagens ECG	CovNet-UFCSPA	70%	84%	77%	74%	0.732	687	130	290	481
	ResNet50 V2	80%	84%	82%	81%	0.810	685	132	169	602
	Inception V3	62%	83%	71%	65%	0.650	678	139	409	362
Imagens CLAHE	CovNet-UFCSPA	56%	96%	70%	59%	0.574	781	36	623	148
	ResNet50 V2	72%	92%	81%	78%	0.774	754	63	289	482
	Inception V3	54%	91%	68%	55%	0.540	747	70	644	127
Imagens Misto	CovNet-UFCSPA	76%	96%	85%	82%	0.820	781	36	242	526
	ResNet50 V2	81%	92%	86%	85%	0.848	754	63	175	593
	Inception V3	65%	91%	76%	70%	0.692	747	70	407	361

Fonte:Autoria própria.

7 CONCLUSÃO

A construção da arquitetura da CovNet-UFCSPA envolveu diversas etapas, desde a coleta de dados e o seu tratamento, até as estratégias de execução do modelo. A necessidade da alta disponibilidade de *hardware* foi identificada precocemente quando realizado o Ensaio I, pois um consumo excessivo de memória foi apresentado. Com isso, o primeiro fator predominante ao se escolher o tamanho do lote é a quantidade de *hardware* disponível. O estouro de memória ao aumentar o tamanho do lote está relacionado ao fator de que quanto maior o tamanho do lote, mais amostras estão sendo propagadas no modelo em uma mesma iteração, exigindo assim cálculos mais complexos em suas camadas (JIN; HONG, 2019).

Os ensaios inicialmente foram aplicados em uma máquina com 16.0 GB de RAM, uma GPU NVIDIA GeForce RTX 2060(8GB) e um processador Intel® Core™ i7 da 10ª Geração. No entanto, neste ambiente somente as instâncias de ensaios com tamanho de lote de 32 e 200 puderam ser executadas. Modelos com mais camadas como Resnet 50V2 e Inception V3 o ambiente não suportava a execução. Para realização dos ensaios a necessidade de um ambiente onde a GPU tenha um maior *range*de memória surgiu. Levando assim todos os testes a serem executados no Santos Dumont, onde na fila *sequana* cada nó possui quatro GPUs Tesla V100-SXM2-32GB.

A execução da arquitetura CovNet-UFCSPA no Santos Dumont não apresentou problemas e não exigiu a aplicação de técnicas de treinamento distribuído. No entanto, ao executar os modelos Resnet50 V2 e Inception V3 com tamanho de lote maior que 500, ocorreu o problema de estouro de memória. Com isso os modelos mais profundos exigiram a necessidade treinamento distribuído em várias GPUs, para isto, a estratégia do Keras *MirroredStrateg* foi aplicada. Além disto, o uso de *ModelCheckpoint* foi uma técnica utilizada para garantir que o treinamento não seja desperdiçado em caso de parada brusca, como por exemplo estouro de memória ou erro não tratado.

O Ensaio I demonstrou que a análise individual de uma métrica não deve ser feita, pois ao analisar as curvas de aprendizado é possível identificar um alto nível de ruído nas curvas com tamanho de lote entre 32 e 200. Porém, mesmo com alto índice de ruído nas curvas de treinamento e validação, a acurácia no modelo com tamanho de lote igual a 32 foi a mais alta, recebendo o valor de 97%. Todavia, como o recurso de validação cruzada foi aplicado é possível identificar esta acurácia alta não permanece em todos os folds, visto que o pior fold recebeu uma acurácia de 74%. Isto mostra a importância de uma análise detalhada do resultado, deve ser observado todas as métricas, como: acurácia, precisão, *recall*. No entanto, a análise das curvas de aprendizado também deve ser considerada. A validação cruzada é outro fator importante na construção de um modelo, o seu uso permite melhorar a robustez do modelo pois ao ser aplicada a divisão aleatória e iterativa do dados de treinamento, validação e teste a possibilidade de vieses no é diminuída.

O Ensaio II utilizou o modelo final da arquitetura CovNet-UFCSPA, este ensaio busca identificar a capacidade de classificação de casos positivos de COVID-19. Como este ensaio utilizou somentes amostras positivas há um desbalanceamento de classes na etapa de teste, com isto as variáveis enfatizadas para análise de desempenho foram *recall* e a matriz de confusão. Essa medidas foram escolhidas, pois, o *recall* é a medida que detecta todas as amostras positivas, sem observar as amostras negativas. Já a matriz de confusão permite visualizar os acertos e erros da classificação da rede. As imagens de teste passaram por recorte, e ajuste de contraste, gerando assim 4 conjuntos de teste. Destes conjuntos a aplicação da técnica de CLAHE se sobressaiu quando realizada uma análise na matriz de confusão, pois neste conjunto de dados encontra-se ter o menor número de FN quando comparado aos outros três conjuntos. ECG foi outra técnica de ajuste de contraste aplicada, os seus resultados foram melhores que as imagens originais, no entanto o número de FN é maior que o conjunto de imagens recortadas e com CLAHE. O conjunto de dados com imagens originais tiveram a maior quantidade de FN dos quatro conjuntos. Com este cenário é possível afirmar que o pré-processamento de dados tem grande relevância no desempenho

do modelo.

Na tentativa de auditar quais áreas da imagem a arquitetura CovNet-UFCSPA considera relevante em sua classificação, o mapa de calor foi extraído das imagens de teste do Ensaio II. Dos três casos apresentados é possível identificar que os raios-x que contém ruídos como fios ou outros objetos levam o modelo a ter uma classificação incorreta. Além disso, o mapa de calor permitiu identificar que ao recortar as imagens deixando somente a área de interesse o modelo terá maior convergência.

Para mostrar o comparativo entre o modelo da arquitetura CovNet-UFCSPA e outros modelos já consolidados, foi executado o Ensaio III. Neste ensaio o mesmo conjunto de dados foram aplicados para treinamento, validação e teste dos seguintes modelos: CovNet-UFCSPA, Resnet50 V2, Inception V3. A arquitetura CovNet-UFCSPA obteve o melhor desempenho ao atingir um *recall* de 99% e ter um FN de 9. O menor FN da Resnet50 V2 e Inception V3 foram 47 e 79 respectivamente. Ao analisar a taxa de FN neste ensaio, é possível notar que o conjunto de imagens tratadas com CLHAE obteve a menor quantidade de classificações incorretas, esse mesmo cenário ocorreu no Ensaio II. Com isto, é possível identificar que técnicas pré-processamento de dados têm grande relevância no desempenho do modelo.

Na Etapa I o modelo foi testado, validado e treinado com banco de dados públicos obtidos por meio da revisão integrativa realizada neste projeto. O conjunto de dados de teste do Ensaio I é composto de 4 430 raios-X normal e 1 090 raios-X com COVID-19 , a arquitetura CovNet-UFCSPA para este cenário obteve uma acurácia de 97%.

Nos Ensaio II e III as etapas de treinamento e validação dos raio-X utilizados foram todos obtidos em banco públicos identificados na revisão integrativa. As nacionalidades dos pacientes, deste bancos, são múltiplas e nenhuma brasileira. No entanto, quando a arquitetura CovNet-UFCSPA é exposta a dados de um hospital público brasileiro mostrou-se eficiente ao classificar, na etapa de teste, 808 imagens do HCPA corretamente e 9 como falso negativo. A ar-

quitetura CovNet-UFCSPA forneceu a possibilidade de profissionais de saúde analisarem a classificação por *score*, abrindo a possibilidade de investigação mais detalhada no profissional. Outro diferencial da arquitetura é a entrega do mapa de calor com as áreas consideradas relevantes para o score aplicado. Porém, a arquitetura precisa ser submetida a mais casos pacientes do HCPA com raio-X normal para que o modelo obtenha maior robustez ao analisar pacientes brasileiros.

O ensaio IV teve como objetivo analisar o desempenho da rede na identificação de casos com e sem COVID-19, a melhor acurácia obtida foi a da Renest50 V2 com valor de 85%, em seguida a arquitetura CovNet-UFCSPA apresentou uma acurácia de 82%. Apesar da CovNet-UFCSPA apresentar menor acurácia, neste ensaio, seu desempenho ao analisar a matriz de confusão mostra que gerou menos FN que as demais arquiteturas e atingiu o melhor *recall* com valor de 96%.

Este trabalho, possui o foco no auxílio ao diagnóstico de COVID-19 e a resistência das arquiteturas a FN é uma prioridade, pois um FN pode levar a triagem errada do paciente. Um número considerável de FP também ocorreu no ensaio IV, no entanto ao analisar o seu efeito na triagem do paciente se torna menos grave do que um FN, pois ao receber um FP a equipe de profissionais de saúde poderia iniciar uma análise mais criteriosa do diagnóstico.

A aplicação de mais de um modalidade, como por exemplo TC e exames clínicos de pacientes foi cogitada no início deste trabalho, no entanto dificuldades foram encontradas para obtenção de novos dados, como a falta de confiabilidade dos dados encontrados na internet, dificuldade de compartilhamento de dados anonimazados pelo SUS e número de dados escasso para aplicação de inteligência artificial. A inserção de novas modalidades podem ser aplicadas em trabalhos futuros, realizando por exemplo, a junção de exames clínicos e dados sociodemográficos de paciente com o objetivo de trazer mais robustez na classificação de um paciente. Além disso, o treinamento constante da rede CovNet-UFCSPA dentro das redes de hospitais do SUS pode melhorar o desempenho da rede, para que o

modelo fique adequado para auxiliar os profissionais de saúde. Outra evolução deste trabalho é a criação de um ferramenta online onde ao ser inserido um raio-X de paciente com suspeita de COVID-19, um serviço *backend* realiza o teste da imagem e retorna o *score* e mapa de calor para a ferramenta, dando assim a possibilidade do profissional de saúde realizar uma análise imediata do raio-X e realizar a triagem adequada, enquanto o exame de RT-PCR é realizado.

REFERÊNCIAS

ACADEMY, Data Science. **Capítulo 3 - O Que São Redes Neurais Artificiais Profundas ou Deep Learning?** [S.l.: s.n.], mar. 2018. Disponível em: <http://deeplearningbook.com.br/o-que-sao-redes-neurais-artificiais-profundas/>. Citado 0 vez na página 42.

AI, Tao et al. Correlation of chest CT and RT-PCR testing for coronavirus disease 2019 (COVID-19) in China: a report of 1014 cases. **Radiology**, Radiological Society of North America, v. 296, n. 2, e32–e40, 2020. Citado 1 vez na página 38.

AKIN, Levent; GÖZEL, Mustafa Gökhan. Understanding dynamics of pandemics. **Turkish journal of medical sciences**, The Scientific e Technological Research Council of Turkey, v. 50, SI-1, p. 515–519, 2020. Citado 1 vez na página 24.

ALBAWI, Saad; MOHAMMED, Tareq Abed; AL-ZAWI, Saad. Understanding of a convolutional neural network. In: IEEE. 2017 International Conference on Engineering and Technology (ICET). [S.l.: s.n.], 2017. P. 1–6. Citado 1 vez na página 44.

ALBUQUERQUE, Victor Hugo C de et al. A new solution for automatic microstructures analysis from images based on a backpropagation artificial neural network. **Nondestructive Testing and Evaluation**, Taylor & Francis, v. 23, n. 4, p. 273–283, 2008. Citado 2 vezes nas páginas 41, 42.

ALPAYDIN, Ethem. **Introduction to machine learning**. [S.l.]: MIT press, 2020. Citado 3 vezes nas páginas 39, 40.

ALTAF, Wasif; SHAHBAZ, Muhammad; GUERGACHI, Aziz. Applications of association rule mining in health informatics: a survey. **Artificial Intelligence Review**, Springer, v. 47, n. 3, p. 313–340, 2017. Citado 2 vezes nas páginas 39, 40.

ARDAKANI, Ali Abbasian et al. COVIDiag: A clinical CAD system to diagnose COVID-19 pneumonia based on CT findings. **European radiology**, Springer, v. 31, n. 1, p. 121–130, 2021. Citado 1 vez na página 26.

BAI, Harrison X et al. Performance of radiologists in differentiating COVID-19 from non-COVID-19 viral pneumonia at

chest CT. **Radiology**, Radiological Society of North America, v. 296, n. 2, e46–e54, 2020. Citado 1 vez na página 38.

BASTOS, Luís Felipe Cunha Sardenberg. **OPAS/OMS Brasil - OMS lança nova estratégia mundial para controle da influenza: OPAS/OMS**. [S.l.: s.n.], mar. 2019. Disponível em: <https://www.paho.org/bra/index.php?option=com_content&view=article&id=5885%5C%3Aoms-lanca-nova-estrategia-mundial-para-controle-da-influenza&Itemid=820>. Citado 1 vez na página 24.

BERNHEIM, Adam et al. Chest CT findings in coronavirus disease-19 (COVID-19): relationship to duration of infection. **Radiology**, Radiological Society of North America, p. 200463, 2020. Citado 1 vez na página 38.

BRENTANO, Vicente Bohrer et al. Interpretando a radiografia de tórax na emergência. **Acta méd.(Porto Alegre)**, p. 8–8, 2014. Citado 1 vez nas páginas 32, 34.

CARUANA, Rich; NICULESCU-MIZIL, Alexandru. An empirical comparison of supervised learning algorithms. In: PROCEEDINGS of the 23rd international conference on Machine learning. [S.l.: s.n.], 2006. P. 161–168. Citado 1 vez na página 40.

CASTRO-DE-ARAUJO, Luis Fernando S. et al. **Aspectos clínicos e terapêuticos da infecção da COVID-19**. [S.l.: s.n.], jan. 2020. Disponível em: <https://www.arca.fiocruz.br/handle/icict/40662>. Citado 1 vez na página 25.

CHASSAGNON, Guillaume et al. Artificial intelligence applications for thoracic imaging. **European journal of radiology**, Elsevier, v. 123, p. 108774, 2020. Citado 2 vezes nas páginas 25, 26.

CHEN, Matthew C et al. Deep learning to classify radiology free-text reports. **Radiology**, Radiological Society of North America, v. 286, n. 3, p. 845–852, 2018. Citado 1 vez na página 43.

CHOLLET, Francois. **Deep learning with Python**. [S.l.]: Simon e Schuster, 2021. Citado 2 vezes nas páginas 57, 58.

CROSS-VALIDATION: evaluating estimator performance. [S.l.: s.n.], 2022. Disponível em: <https://scikit-learn.org/stable/modules/cross_validation.html>. Citado 2 vezes nas páginas 60, 63.

DAS, Karuna M et al. CT correlation with outcomes in 15 patients with acute Middle East respiratory syndrome coronavirus. **American Journal of Roentgenology**, Am Roentgen Ray Soc, v. 204, n. 4, p. 736–742, 2015. Citado 1 vez na página 38.

ESCUISSATO, Dante L. **Bases Radiológicas das Doenças Tor ocicas**. [S.l.: s.n.], 2018. Disponível em: <https://bvsms.saude.gov.br/bvs/dicas/233_pneumonia.html#:~:text=Pneumonia%5C%20%5C%C3%5C%A9%5C%20uma%5C%20infec%5C%C3%5C%A7%5C%C3%5C%A3o%5C%20que,entre%5C%20um%5C%20alv%5C%C3%5C%A9olo%5C%20e%5C%20outro>. Acesso em: 13 fev. 2021. Citado 1 vez na página 32.

FIGUEIREDO, Luiz Tadeu Moraes. Viral pneumonia: epidemiological, clinical, pathophysiological and therapeutic aspects. **Jornal Brasileiro de Pneumologia**, Citeseer, v. 35, n. 9, 2009. Citado 3 vezes nas páginas 30, 31.

GALLANT, Stephen I; GALLANT, Stephen I. **Neural network learning and expert systems**. [S.l.]: MIT press, 1993. Citado 1 vez na página 41.

GONG, Jing et al. Correlation analysis between disease severity and inflammation-related parameters in patients with COVID-19 pneumonia. **MedRxiv**, Cold Spring Harbor Laboratory Press, 2020. Citado 2 vezes nas páginas 24, 31.

GOODFELLOW, Ian et al. **Deep learning**. [S.l.]: MIT press Cambridge, 2016. v. 1. Citado 1 vez na página 42.

GUAN, Wei-jie et al. Clinical characteristics of coronavirus disease 2019 in China. **New England journal of medicine**, Mass Medical Soc, v. 382, n. 18, p. 1708–1720, 2020. Citado 1 vez na página 38.

GÜNEYLI, Serkan et al. Radiological approach to COVID-19 pneumonia with an emphasis on chest CT. **Diagnostic and Interventional Radiology**, Turkish Society of Radiology, v. 26, n. 4, p. 323, 2020. Citado 0 vez na página 37.

GUO, Wenzhong; WANG, Jianwen; WANG, Shiping. Deep multimodal representation learning: A survey. **IEEE Access**, IEEE, v. 7, p. 63373–63394, 2019. Citado 1 vez na página 38.

HAENSCH, Wilfried; GOKMEN, Tayfun; PURI, Ruchir. The next generation of deep learning hardware: Analog computing. **Proceedings of the IEEE**, IEEE, v. 107, n. 1, p. 108–122, 2018. Citado 1 vez na página 43.

HAYKIN, Simon. **Redes neurais: princıpios e prática**. [S.l.]: Bookman Editora, 2007. Citado 3 vezes nas páginas 41, 42.

JACOBI, Adam et al. Portable chest X-ray in coronavirus disease-19 (COVID-19): A pictorial review. **Clinical imaging**, Elsevier, 2020. Citado 1 vez nas páginas 24, 36.

JANGAMREDDY, Nikhil. A Survey on Specialised Hardware for Machine Learning, 2019. Citado 2 vezes nas páginas 42, 43.

JIANG, Tammy; GRADUS, Jaimie L; ROSELLINI, Anthony J. Supervised machine learning: a brief primer. **Behavior Therapy**, Elsevier, v. 51, n. 5, p. 675–687, 2020. Citado 1 vez na página 40.

JIN, Tian; HONG, Seokin. Split-cnn: Splitting window-based operations in convolutional neural networks for memory system optimization. In: PROCEEDINGS of the Twenty-Fourth International Conference on Architectural Support for Programming Languages and Operating Systems. [S.l.: s.n.], 2019. P. 835–847. Citado 1 vez na página 90.

KHAN, Saddam Hussain; SOHAIL, Anabia; KHAN, Asifullah. COVID-19 Detection in Chest X-Ray Images using a New Channel Boosted CNN. **arXiv preprint arXiv:2012.05073**, 2020. Citado 1 vez na página 40.

KOO, Hyun Jung et al. Radiographic and CT features of viral pneumonia. **Radiographics**, Radiological Society of North America, v. 38, n. 3, p. 719–739, 2018. Citado 2 vezes na página 30.

KWIATKOWSKI, Sebastian. **Machine Learning From Scratch: Part 3**. [S.l.]: Towards Data Science, mar. 2018. Disponível em: <https://towardsdatascience.com/machine-learning-from-scratch-part-3-ed572330367d>. Citado 0 vez na página 44.

LAI, Siwei et al. Recurrent convolutional neural networks for text classification. In: 1. PROCEEDINGS of the AAAI Conference on Artificial Intelligence. [S.l.: s.n.], 2015. v. 29. Citado 1 vez na página 43.

LEE, Kyung-Yil et al. Mycoplasma pneumoniae pneumonia, bacterial pneumonia and viral pneumonia. **Jornal de pediatria**, SciELO Brasil, v. 86, n. 6, p. 448–450, 2010. Citado 1 vez na página 30.

LI, Liangliang; SI, Yujuan; JIA, Zhenhong. Medical image enhancement based on CLAHE and unsharp masking in NSCT domain. **Journal of Medical Imaging and Health Informatics**, American Scientific Publishers, v. 8, n. 3, p. 431–438, 2018. Citado 1 vez na página 50.

LI, Yan; XIA, Liming. Coronavirus disease 2019 (COVID-19): role of chest CT in diagnosis and management. **American Journal of Roentgenology**, Am Roentgen Ray Soc, v. 214, n. 6, p. 1280–1286, 2020. Citado 1 vez na página 38.

MACKEY, Tim et al. Machine learning to detect self-reporting of symptoms, testing access, and recovery associated with COVID-19 on Twitter: retrospective big data infoveillance study. **JMIR public health and surveillance**, JMIR Publications Inc., Toronto, Canada, v. 6, n. 2, e19509, 2020. Citado 1 vez na página 40.

MASSUCATTO, Jean Daniel Prestes. **Aplicação de conceitos de redes neurais convolucionais na classificação de imagens de folhas**. 2018. B.S. thesis – Universidade Tecnológica Federal do Paraná. Citado 1 vez na página 45.

MCCRACKEN JR, George H. Etiology and treatment of pneumonia. **The Pediatric infectious disease journal**, LWW, v. 19, n. 4, p. 373–377, 2000. Citado 1 vez na página 31.

MEIRELLES, Gustavo de Souza Portes. **Padrão acinar**. [S.l.: s.n.]. Disponível em: <hhttp://professor.pucgoias.edu.br/SiteDocente/admin/arquivosUpload/17723/material/1403.pdf>. Acesso em: 13 fev. 2021. Citado 0 vez na página 35.

MITTAL, Ansh et al. Detecting pneumonia using convolutions and dynamic capsule routing for chest X-ray images. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 20, n. 4, p. 1068, 2020. Citado 1 vez na página 25.

MOHAN, Anant et al. Prevalence of viral infection detected by PCR and RT-PCR in patients with acute exacerbation of COPD: A

systematic review (Respirology (2010) 15 (536-542)). **Respirology**, Wiley-Blackwell, v. 15, n. 5, 2010. Citado 1 vez na página 32.

NAÇÕES UNIDAS - NEWS, Organização das. **Unicef: pneumonia matou uma criança a cada 39 segundos no ano passado**. [S.l.: s.n.]. Disponível em: <https://news.un.org/pt/story/2020/01/1702292>. Acesso em: 13 fev. 2021. Citado 1 vez na página 29.

NAHID, Abdullah-Al et al. A novel method to identify pneumonia through analyzing chest radiographs employing a multichannel convolutional neural network. **Sensors**, Multidisciplinary Digital Publishing Institute, v. 20, n. 12, p. 3482, 2020. Citado 2 vezes nas páginas 25, 26.

O'SHEA, Keiron; NASH, Ryan. An introduction to convolutional neural networks. **arXiv preprint arXiv:1511.08458**, 2015. Citado 3 vezes na página 45.

ORGANIZATION, World Health. **Pneumonia**. [S.l.: s.n.]. Disponível em: <https://www.who.int/health-topics/pneumonia#tab=tab_1>. Acesso em: 13 fev. 2021. Citado 1 vez na página 29.

OZTURK, Tulin et al. Automated detection of COVID-19 cases using deep neural networks with X-ray images. **Computers in biology and medicine**, Elsevier, v. 121, p. 103792, 2020. Citado 1 vez na página 25.

PEREIRA, Ezequiel. TOMÓGRAFOS X COVID-19, 2020. Disponível em: <https://arquivos.cruzeirodosuleducacional.edu.br/criacao/arquivos/PESQUISA-UDF-TOMOGRAFOS-COVID19-BRASIL.pdf>. Citado 1 vez na página 25.

RAJARAMAN, Sivaramakrishnan; ANTANI, Sameer. Training deep learning algorithms with weakly labeled pneumonia chest X-ray data for COVID-19 detection. **medRxiv**, Cold Spring Harbor Laboratory Preprints, 2020. Citado 1 vez na página 25.

REZA, Ali M. Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement. **Journal of VLSI signal processing systems for signal, image and video technology**, Springer, v. 38, n. 1, p. 35–44, 2004. Citado 1 vez na página 50.

RIBEIRO, Marcela X et al. Supporting content-based image retrieval and computer-aided diagnosis systems with association rule-based techniques. **Data & Knowledge Engineering**, Elsevier, v. 68, n. 12, p. 1370–1382, 2009. Citado 1 vez na página 39.

RODRIGUES, Joaquim Carlos;
SILVA FILHO, Luiz Vicente Ferreira da; BUSH, Andrew. Diagnóstico etiológico das pneumonias: uma visão crıtica. **Jornal de Pediatria**, SciELO Brasil, v. 78, p. 129–140, 2002. Citado 1 vez na página 32.

SAÚDE DO MINISTÉRIO DA SAÚDE, Biblioteca Virtual em. **Aumentar o acesso ao oxigênio médico é o tema deste 12/11 - Dia Mundial da Pneumonia**. [S.l.: s.n.]. Disponível em: <http://bvs.saude.gov.br/component/content/article?id=3354>. Acesso em: 13 fev. 2021. Citado 3 vezes nas páginas 29, 30.

_____. **Pneumonia**. [S.l.: s.n.], 2011. Disponível em: <https://bvsms.saude.gov.br/bvs/dicas/233_pneumonia.html#:~:text=Pneumonia%5C%20%5C%C3%5C%A9%5C%20uma%5C%20infec%5C%C3%5C%A7%5C%C3%5C%A3o%5C%20que,entre%5C%20um%5C%20alv%5C%C3%5C%A9olo%5C%20e%5C%20outro>. Acesso em: 13 fev. 2021. Citado 1 vez na página 29.

SHARMA, Sat; MAYCHER, Bruce; ESCHUN, Gregg. Radiological imaging in pneumonia: recent innovations. **Current opinion in pulmonary medicine**, LWW, v. 13, n. 3, p. 159–169, 2007. Citado 1 vez na página 33.

SHI, Heshui et al. Radiological findings from 81 patients with COVID-19 pneumonia in Wuhan, China: a descriptive study. **The Lancet infectious diseases**, Elsevier, v. 20, n. 4, p. 425–434, 2020. Citado 2 vezes nas páginas 35, 36, 38.

SILVA, C Isabela S; MÜLLER, Nestor L. Modelo de interpretação da tomografia computadorizada de alta resolução do diagnóstico diferencial das doenças intersticiais crônicas. **Radiologia Brasileira**, SciELO Brasil, v. 38, n. 2, p. 125–132, 2005. Citado 0 vez na página 35.

SKLEARN.UTILS.CLASS$_W EIGHT.COMPUTE_C LASS_W EIGHT$.

[S.l.: s.n.], 2022. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.utils.class_weight.compute_class_weight.html>. Citado 2 vezes nas páginas 59, 62.

SONG, Fengxiang et al. Emerging 2019 novel coronavirus (2019-nCoV) pneumonia. **Radiology**, Radiological Society of North America, v. 295, n. 1, p. 210–217, 2020. Citado 2 vezes na página 38.

STRUYF, Thomas et al. Signs and symptoms to determine if a patient presenting in primary care or hospital outpatient settings has COVID-19 disease. **Cochrane Database of Systematic Reviews**, John Wiley & Sons, Ltd, n. 7, 2020. Citado 1 vez na página 31.

SWAPNA, E. **Convolutional Neural Network: Deep Learning**. [S.l.: s.n.], mar. 2021. Disponível em: <https://developersbreach.com/convolution-neural-network-deep-learning/>. Citado 0 vez na página 46.

SZEPESVÁRI, Csaba. Algorithms for reinforcement learning. **Synthesis lectures on artificial intelligence and machine learning**, Morgan & Claypool Publishers, v. 4, n. 1, p. 1–103, 2010. Citado 1 vez nas páginas 40, 41.

UDUGAMA, Buddhisha et al. Diagnosing COVID-19: the disease and tools for detection. **ACS nano**, ACS Publications, v. 14, n. 4, p. 3822–3835, 2020. Citado 2 vezes nas páginas 24, 31.

WHO Coronavirus (COVID-19) Dashboard. [S.l.]: World Health Organization, mai. 2020. Disponível em: <https://covid19.who.int/>. Citado 1 vez na página 24.

WHO Director-General's opening remarks at the media briefing on COVID-19 - 13 May 2020. [S.l.]: World Health Organization, mar. 2020. Disponível em: <https://www.who.int/dg/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---13-may-2020>. Citado 1 vez na página 24.

WU, Jianxin. Introduction to convolutional neural networks. **National Key Lab for Novel Software Technology. Nanjing University. China**, v. 5, p. 23, 2017. Citado 1 vez na página 44.

YAMASHITA, Rikiya et al. Convolutional neural networks: an overview and application in radiology. **Insights into imaging**, Springer, v. 9, n. 4, p. 611–629, 2018. Citado 1 vez na página 43.

ZHAO, Wei et al. Relation between chest CT findings and clinical conditions of coronavirus disease (COVID-19) pneumonia: a multicenter study. **American Journal of Roentgenology**, Am Roentgen Ray Soc, v. 214, n. 5, p. 1072–1077, 2020. Citado 2 vezes nas páginas 31, 38.

Apêndices

APÊNDICE A – REVISÃO INTEGRATIVA:CARACTERÍSTICAS DOS DADOS UTILIZADOS EM REDES NEURAIS ARTIFICIAIS QUE AUXILIAM NA IDENTIFICAÇÃO DA COVID-19

Revisão Integrativa: Características dos Dados Utilizados em Redes Neurais Artificiais que Auxiliam na Identificação da COVID-19

Nouara Cândida Xavier
Dra. Carla Diniz Lopes Becker
Dr. Tathiane Alves Pianoschi Alva
Universidade Federal de Ciências da Saúde de Porto Alegre, Brasil

Abstract

Diagnostic assistance using deep machine learning algorithms is being used to assist health professionals in combating the COVID-19 pandemic. Through an integrative review, this article seeks to extract the main characteristics of the data used for training these networks. The results show that fever and cough are the main symptoms found in the patients, and imaging tests performed on patients infected by the virus showed mainly radiological patterns such as bilateral and ground glass. In addition, an open-source data source mapping was created.

Resumo

A assistência ao diagnóstico usando algoritmos de aprendizado de máquina profundo vem auxiliando os profissionais de saúde no combate à pandemia de COVID-19. Por meio de uma revisão integrativa, este artigo busca extrair as principais características dos dados utilizados para o treinamento dos modelos de aprendizado de máquina profundo propostos. Os resultados desta revisão apresenta mais de 16 sintomas onde febre e tosse são os mais recorrentes nos pacientes acometidos pela doença, entre 11 comorbidades foram encontradas em diferentes pacientes sendo a diabete e hipertensão as mais comuns. Além disso, os exames de pacientes com COVID-19 mostraram padrões radiológicos como consolidação bilateral e vidro fosco. Um mapeamento dos dados utilizados nesses algoritmos também foi criado.

1. Introdução

A Organização Mundial de Saúde (OMS) vem destacando medidas preventivas para amortizar os efeitos das epidemias em todo o mundo, a exemplo: o controle da influenza. Em 2019, a OMS declarou que existia um risco potencialmente contínuo de que um novo vírus da influenza poderia ocasionar uma pandemia, reforçando assim o discurso de que medidas preventivas e preparação para este cenário são de extrema importância. Após a declaração da pandemia da COVID-19 mais de 5,856,224 mortes

foram registradas, destacando assim, a importância de medidas sanitárias com impacto global [1].

Atualmente, algoritmos de aprendizado de máquina profundo (AMP) podem diagnosticar determinadas patologias como tuberculose e câncer de pulmão, utilizando dados de raio-X do tórax, os resultados chegam a um nível comparável a radiologistas [2] . A utilização de AMP em conjunto com técnicas de pré-processamento de imagens vem se mostrando uma ferramenta precisa no auxílio ao diagnóstico de pneumonia [3]. Com isso, diversos trabalhos buscando otimizar, acelerar e auxiliar na triagem de pacientes com COVID-19 estão sendo desenvolvidos utilizando AMP, como por exemplo, S. Rajaraman el al [4], que ao fazer uso de AMP identifica pacientes com pneumonia induzida pela COVID-19 utilizando raio-X do tórax fracamente rotulados. Técnicas semelhantes também foram utilizadas nos trabalhos de T. Ozturk et al. (2020), e A. Mittal et al. (2020). Sendo assim, o propósito deste artigo é realizar uma revisão integrativa para reunir as principais características dos dados utilizados em algoritmos de aprendizado de máquina profundo que auxiliam no diagnóstico da COVID-19.

Na seção 2 é apresentada os materiais e métodos desta revisão, esse processo foi dividido em pergunta norteadora presente na seção 2.1, questões da revisão abordada na seção 2.2, na seção 2.3 encontra-se o processo de busca na literatura e por na seção 2.4 a síntese de resultados. Os resultados e discussão são apresentados na seção 3 que é dividida em 4 tópicos, são eles: base de dados, características da COVID-19, padrões radiológicos da pneumonia e padrões radiológicos da pneumonia induzida pela COVID-19. Por fim na seção 4 é apresentada a conclusão desta revisão integrativa.

2. Materiais e Métodos

Na construção desta revisão integrativa foram aplicadas seis etapas, são elas: elaboração da pergunta norteadora, busca na literatura, coleta de dados, análise crítica dos estudos incluídos, discussão dos resultados, e construção.

2.1. Pergunta Norteadora

A pergunta norteadora desta revisão foi: Quais são as características dos dados utilizados em redes neurais artificiais que têm por objetivo auxiliar o diagnóstico da COVID-19?

2.2. Questões da revisão

Buscando detalhar ainda mais o objetivo desta revisão foram elaboradas cinco questões de pesquisa:

- "Como a inteligência artificial (IA) é aplicada para auxiliar a medicina no diagnóstico de pneumonia causadas pela COVID-19?" - o objetivo é identificar que técnicas de IA são empregadas no meio científico para auxiliar profissionais de saúde no diagnóstico de pneumonia ocorridas pelo agravamento da COVID-19.
- "Como redes neurais artificiais que utilizam raios-X ou tomografia e/ou dados do paciente são usadas para o diagnóstico médico?" - a pergunta tem por objetivo verificar como a literatura utiliza estes dados para construção de uma rede neural artificial que tem por função identificar a pneumonia ocorrida pela COVID-19.
- "Como é o tratamento dos dados que são utilizados na solução proposta pelo autor?" - essa questão tem por função identificar quais as técnicas de pré-processamento utilizadas no treinamento de uma rede neural artificial.
- "Qual a fonte de dados utilizado pelos autores?" - seu objetivo é identificar bases com acesso público.
- "Quais os sintomas e características da COVID-19?"- tem por objetivo identificar as características das doenças e seus principais sintomas.

2.3. Busca da literatura

A expressão de busca utilizada ((‘neural network’ OR ‘deep learning’ OR ‘artificial intelligence’) AND (‘x-ray’ OR ct OR ‘computed tomography’ OR ‘medical image’) AND medical AND diagnosis AND ((respiratory AND disease) OR ‘respiratory disease’ OR influenza OR pneumonia))’’, obtendo assim um retorno de 108 artigos. Os critérios de inclusão e exclusão são apresentados na Tabela 1, após a aplicação dos critérios 90 artigos foram selecionados, a base para busca foi a PubMed.

Além da busca por artigos, essa revisão realizou busca de banco de dados com imagens de raio x e tomografia de pacientes com COVID-19, essa busca foi realizada através da leitura dos artigos obtidos pela expressão de busco descrita acima e pela busca no site Kaggle [7].

Tabela 1 - Critérios de inclusão e exclusão

Inclusão	Exclusão
Artigos a partir de 2015	Artigos duplicados
Artigos escritos em inglês	Artigos escritos em inglês
Artigos que utilizam técnicas de IA para solução do proposta apresentada pelo autor	Artigos que o foco não são doenças respiratórias
Artigos com resumo onde seja possível identificar se o artigo apresenta IA	Artigos que não descrevem a metodologia da técnica de IA utilizada
Artigos que descrevem seus resultados	-

Fonte:: Autoria própria

2.4. Síntese dos resultados

Os resultados encontrados buscaram detectar bases de dados públicas conhecidas como *open source* e também um mapeamento da doença, para que seja possível a identificação de quais as principais características dos dados que estão sendo utilizados nas pesquisas de redes neurais artificiais que utilizam imagens como principal modalidade de suas redes. Esse processo levou a criação de tabelas, descritas na seção de resultados, onde é possível identificar a origem dos bancos de dados e as principais características sociodemográficas, clínicas e laboratoriais de pacientes acometidos pela COVID-19.

3. Resultados

3.1. Base de dados

A análise dos artigos permitiu um mapeamento de todas as fontes de dados *open source*, resultando na Tabela 2. Os trabalhos mapeados utilizaram os dados para aplicação de diversas técnicas de IA, os autores G.Jain et al. (2020), D. Dansana et aL. (2020) e H.X Bai et aL (2020) aplicaram arquiteturas de redes amplamente conhecidas

na literatura, como ResNet50, ResNetet101, VGG-16 e Inception-V3. Essas arquiteturas são conhecidas por gerar excelentes resultados para tarefas de classificação de imagens. Os autores aplicaram essas arquiteturas para a detecção da pneumonia causada pela COVID-19 trazendo resultados que chegam a 100% de acurácia ao utilizar a arquitetura ResNet101[8] e 91% de acurácia ao utilizar uma VGG-16[9].

A predominância de arquiteturas que utilizam com técnica de neurais convolucionais foi identificada, mas trabalho como Angelov et al[11] utilizaram outras técnicas como, por exemplo: árvore de decisão, o qual obteve uma acurácia de 76% um resultado não tão satisfatório quando comparado com um arquitetura Resnet50 testada pelos autores que obteve 94,96% de acurácia.

A tabela 2 apresenta a *url* das bases *open sources* encontradas nesta revisão. Além disto é apresentada a composição de classes das imagens utilizadas nos trabalhos e a técnica de IA aplicada nestes dados. As arquiteturas foram aplicadas com o objetivo de classificação e/ou segmentação das imagens. Autores com Zhang et al[12] e Harmon et al[13] utilizaram técnicas de IA que buscam a segmentação das imagens médicas, onde seu objetivo é identificar as áreas do pulmão afetadas pela pneumonia induzida pela COVID-19

3.2. Características da COVID-19

O diagnóstico precoce da COVID-19 vem se mostrando extremamente eficiente para diminuição de risco de morte de um paciente e também diminui a evolução da doença para um estágio crítico. O agravamento do estado clínico do paciente acometido pela COVID-19 pode ocasionar o desenvolvimento de pneumonia, sendo esta do tipo viral com agente etiológico SARS-CoV-2[14].

A detecção da COVID-19 é realizada principalmente por métodos de detecção do DNA, através do teste de reação em cadeia da polimerase por transcrição reversa (RT-PCR, do inglês *Reverse Transcription Polymerase Chain Reaction*). No entanto, a análise de sintomatologia e exames de imagem do tórax, sendo raio-X e/ou tomografia computadorizada são comuns para o diagnóstico e verificação da evolução da doença [15].

A necessidade de mapear os sintomas e suas consequências é constante para melhor compreensão da doença, e autores como T.Struyf et aL (2020) detectaram após uma revisão de 16 estudos com um total de 7.706 participantes, que os principais sintomas são febre, fadiga, mialgia ou artralgia, sendo menos comum a tosse, dor de garganta, febre, mialgia ou artralgia, fadiga e cefaléia. Sintomas similares também são apresentados pelo Zhao et al.(2020) onde febre e tosse são predominantes nos pacientes deste estudo. Os autores concluem que sinais ou sintomas não trazem precisão suficiente para excluir ou descartar a doença.

A Tabela 3 e a Tabela 4 foram construídas a partir do estudo elaborado pelo Departamento de Radiologia Koc University School of Medicine localizado em Istambul[18], este trabalho traz uma tabela as características sociodemográficas e os achados encontrados em tomografias de pacientes com COVID-19. Esta revisão adaptou a tabela original utilizando os mesmo autores para identificar outros achados além dos apresentados. Com isto, as tabelas 4 e 5 apresentam os principais sintomas, comorbidades e resultados de exames laboratoriais de pacientes com a doença.

A Tabela 3 apresenta as principais características clínicas de pacientes com pneumonia induzida pela COVID-19, a tabela identifica o número de pacientes e a porcentagem em relação ao total geral que apresentaram os sintomas clínicos elencados. Foram mapeados 14 sintomas estes foram os mais recorrentes encontrados nos trabalhos, além disso o mapeamento das comorbidades mais comuns também foi realizado. Os sintomas de febre, tosse e fadiga são identificados em maior escala, quando comparados a escarro e corrimento nasal. A febre é um sintoma identificado em 96% dos pacientes[19], por mais que este sintoma seja o mais comum nos trabalhos encontrados no artigo de Guan et al.(2020) somente 44% dos pacientes apresentaram febre na admissão do hospital.

As comorbidades de maior ocorrência entre os pacientes foram a diabetes, hipertensão e doença cardiovascular, conforme apresentado na Tabela 3. Cerca de 165 pacientes, representando 15% do total de pacientes possuem hipertensão [20], a mesma porcentagem também ocorre no trabalho dos autores Shi et al.(2020).

A Tabela 4 apresenta resultados de exames laboratoriais de pacientes com pneumonia induzida pela COVID-19. A contagem de células brancas identifica a

defesa do corpo contra organismos infecciosos, um número crescente de estudos abordam a relação entre esses tipos de células e a gravidade da COVID-19, no entanto essa relação ainda permanece obscura[22]. Nos trabalhos apresentados na Tabela 4 é relatado que 68% dos pacientes[21] (dando um total de 58 pacientes) apresentaram um valor elevado na contagem, no entanto 90% dos pacientes possuíam sua contagem nomal[23]. Porém, o estudo abordado por Guan et al possui um valor maior de pacientes, um total de 1099 pacientes, sendo que somente 6% dos pacientes do estudo apresentaram contagem elevada[20].

Tabela 2 - Bancos de dados *open source*

Referências	Composição do dataset	Técnica de IA	Tipo Imagem	Link para o *dataset* ou código fonte
(JAIN et al., 2020)	Normal: 1373 Pneumonia viral: 1 493 Pneumonia bacteriana: 2 780	ResNet50 e ResNet101: para classificação *Rede pré-treinada pelo dataset ImagemNet	Raio x	Dataset: https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia https://github.com/ieee8023/covid-chestxray-dataset
(DANSANA et al., 2020)	Pneumonia viral: 38 COVID-19: 468 Pneumonia bacteriana: 48	VGG-16, Inception-V2 e Árvore de decisão: para classificação	Raio x	Dataset https://github.com/ieee8023/covid-chestxray-dataset
(ANGELOV; SOARES, 2020)	Normal: 1 252 COVID-19: 1 229	Resnet, VGG-16, GoogleNet, Árvore de decisão, AlexNet, AdaBoost.	Tomografia	Dataset https://github.com/Plamen-Eduardo/xDNN-SARS-CoV-2-CT-Scan
(RAIKOTE, 2020)	Normal: 90 COVID-19: 137 Pneumonia viral: 90	-	Raio x	Dataset https://www.kaggle.com/pranavraikokte/covid19-image-dataset
(ANAS M. TAHIR et al., 2022)	Normal:10 701 COVID-19:11 956 Pneumonia não COVID-19: 1 263	-	Raio x	Dataset: https://www.kaggle.com/anasmohammedtahir/covidqu
(RAHAMAN, 2021)	COVID-19: 2616 Viral: 1345	-	Raio x	Dataset https://www.kaggle.com/tawsifurrahman/covid19-radiography-database
(YANG et al., 2020)	COVID-19: 349 + 589 Normal: 463	Resnest-50 e DenseNet-169	Tomografia	DataSet https://paperswithcode.com/dataset/covid-ct https://github.com/ieee8023/covid-chestxray-dataset
(ZHANG et al., 2020)	COVID-19: 1 578 Pneumonia não COVID-19: 1614 Normal 1 164	DeepLabv3: segmentação do pulmão. 3D ResNet: para classificação	Tomografia	Deeplabv3: https://github.com/pytorch/vision Código e Dataset: http://ncov-ai.big.ac.cn/download?lang=en
(BAI et al., 2020)	COVID-19: 521 Pneumonia não COVID-19: 665	EfficienteNets B4: para classificação.	Tomografia	https://github.com/robinwang08/COVID19

(HARMON et al., 2020)	COVID-19: 1 029 Não COVID-19: 1695	SDK disponibilizada pela NVIDIA: para classificação AH-Net: para segmentação do pulmão	Tomografia	AH-Net: https://github.com/lsqshr/AH-Net DataSet: https://wiki.cancerimagingarchive.net/display/Public/LIDC-IDRI
(VAYÁ et al., 2020)	COVID-19: 3 642 Não COVID-19: 2 120	-	Raio x	dataset: https://paperswithcode.com/dataset/padchest https://b2drop.bsc.es/index.php/s/BIMCV-COVID19

Fonte: Autoria própria

Tabela 3 - Características clínicas de pacientes com pneumonia induzida pela COVID-19

Informações	**Autores**										
	(HAN et al., 2020)	(SONG et al., 2020)	(WU et al., 2020)	(LI; XIA, 2020)	(ZHAO et al., 2020)	(BAI et al., 2020)	(BERNHEIM et al., 2020)	(AI et al., 2020)	(SHI et al., 2020)	(LI et al., 2020)	(GUAN et al., 2020)
Sintomas Clínicos											
Febre	94(≅87%)	49 (≅96%)	61(≅76%)	46 (≅90%)	79 (≅78%)	142 (≅65%)	74 (≅62%)	-	59 (≅73%)	72 (≅87%)	473 (≅44%)
Tosse	65(≅60%)	23 (≅47%)	58 (≅73%)	1 (≅2%)	63 (≅62%)	-	58 (≅48%)	-	65 (≅78%)	65 (≅78%)	745 (≅68%)
Fatiga	42(≅39%)	16 (≅31%)	-	-	17 (≅16%)	-	-	-	7 (≅9%)	-	-
Dor no peito	17(≅39%)	7 (≅14%)	5 (≅6%)	-	-	-	-	-	18 (≅22%)	5 (≅6%)	419 (≅38%)
Diarreia	15(≅14%)	5 (≅10%)	7 (≅9%)	-	3 (≅3%)	-	-	-	3 (≅4%)	7 (≅8%)	42 (≅4%)
Dor faríngea	14(≅13%)	3 (≅6%)	9 (≅11%)	-	12 (≅12%)	-	-	-	-	6 (≅7%)	153 (≅14%)
Dor de cabeça	14(≅13%)	8 (≅16%)	8 (≅10%)	-	-	-	-	-	5 (≅6%)	9 (≅11%)	150 (≅14%)
Dor no músculo	12(≅11%)	-	13 (≅16%)	-		-	-	-	-	15 (≅18%)	164 (≅15%)
Pequena fleuma	-	10(≅20%)	11 (≅14%)	-	-	-	20 (≅17%)	-	15 (≅19%)	15 (≅18%)	370 (≅34%)
Perda de apetite	-	9(≅18%)	-	-	-	-	-	-	1 (≅1%)	-	-
Corrimento Nasal	-	2 (≅4%)	-	-	-	-	-	-	21 (≅26%)	-	53 (≅5%)
Sangue no escarro	-	-	3 (≅4%)	-	-	-	-	-	-	-	10 (<1%)
Náusea e vômito	-	3 (≅6%)	-	-	2 (≅2%)	-	-	-	2 (≅2%)	-	55 (≅5%)
Perda de Ar	12(≅11	-	-	-	1	-	-	-	34	9	205

	%)				(≅1%)				(≅42%)	(≅11%)	(≅19%)
Sem sintomas	-	-	-	1(≅2%)	2 (≅2%)	-	-	-	-	-	-
Comorbidades											
Diabetes	-	3 (≅6%)	4 (≅5%)	-	-	18 (≅8%)	-	-	10 (≅12%)	7 (≅8%)	81 (≅7%)
Hipertensão	-	5 (≅10%)	4 (≅5%)	-	-	31 (≅14%)	-	-	12 (≅15%)	5 (≅6%)	165 (≅15%)
Doenças crônicas do fígado	-	1 (≅2%)	-	-	-	6 (≅3%)	-	-	7 (≅9%)	-	1 (< 1%)
Obstrução crônica pulmonar	-	1 (≅2%)	-	-	-	-	-	-	9 (≅11%)	-	12 (≅1%)
Doença cardiovascular	-	1 (≅2%)	1 (≅1 %)	-	16 (≅16%)	-	-	-	8 (≅10%)	1 (≅1%)	27 (≅2%)
Doença cerebrovascular	-	-	-	-	16 (≅16%)	-	-	-	6 (≅7%)	-	15 (≅1%)
Doença no sistema respiratório	-	-	3 (≅4%)	-	5 (≅5%)	9 (≅4%)	-	-	-	5 (≅6%)	-
Imunossupressão	-	-	3 (≅3%)	-	-	-	-	-	-	-	2(< 1'%)
Doença no sistema endócrino	-	-	-	-	3 (≅3%)	2 (≅1%)	-	-	3 (≅4%)	-	8 (<1%)
Doença no sistema digestivo	-	-	-	-	6 (≅6%)	-	-	-	-	-	-
Histórico cirúrgico	-	-	-	-	7 (≅7%)	-	-	-	-	-	-
Tumor maligno	-	-	-	-	-	3 (≅1%)	-	-	4 (≅5%)	-	10 (< 1%)

Fonte: Autoria própria

Tabela 4 - Exames laboratoriais de pacientes com pneumonia induzida pela COVID-19

Informações	**Autores**									
	(HAN et al., 2020)	(SONG et al., 2020)	(WU et al., 2020)	(LI; XIA, 2020)	(ZHAO et al., 2020)	(BAI et al., 2020)	(BERNHEIM et al., 2020)	(AI et al., 2020)	(SHI et al., 2020)	(LI et al., 2020)	(GUAN et al., 2020)
Contagem de células brancas											

Elevada	-	-	10 (≅10%)	-	-	64 (≅ 29%)	-	-	55 (≅ 68%)	9 (≅ 11%)	58 (≅ 6%)
Normal	97 (≅90%)	37 (≅73%)	-	-	-	155 (≅ 71%)	-	-	-	-	
Reduzida	11 (≅10%)	-	7 (9≅%)	-	-	-	-	-	26 (≅ 32%)	10 (≅ 12%)	330 (≅ 34%)
Contagem de neutrófilos											
Elevada	-	-	16 (≅20%)	-	-	-	-	-	-	17 (≅ 20%)	-
Normal	-	44 (≅51%)	-	-	-	-	-	-	-	-	-
Reduzida	-	-	5 (6≅%)	-	-	-	-	-	-	5 (≅ 6%)	-
Contagem de linfócitos											
Normal	43 (≅ 40%)	17 (≅ 35%)	-	-	-	36 (≅ 16 %)	-	-	27 (≅ 33%)	-	-
Reduzida	65 (≅ 60%)	33 (≅ 65%)	34 (≅ 43%)	-	-	183 (≅ 84 %)	-	-	54 (≅ 67%)	44 ≅ 48%)	731 (≅ 83%)
Contagem de monócitos											
Elevada	-	-	8 (≅10%)	-	-	-	-	-	-	12 (≅ 14%)	-
Normal	-	-	1 (<1%)	-	-	-	-	-	-	-	-
Reduzida	-	-	-	-	-	-	-	-	-	2 (≅ 2%)	-
Nível de proteína C reativa											
Normal	1 (<1%)	41 (≅ 80%)	-	-	-	-	-	-	-	-	-
Reduzida	-	-	-	-	-	-	-	-	-	-	-
Elevada	-	-	37 (≅ 46%)	-	-	-	-	-	-	44 (≅ 53%)	481 (≅ 61%)
Contagem de linfócito T auxiliar											
Baixo	-	31 (≅ 61%)	-	-	-	-	-	-	-	-	-
Procalcitoni											

na											
Elevada	-	-	32 (≅ 46%)	-	-	-	-	-	-	44 (≅ 53%)	35 (≅ 5%)
Saturação de Oxihemoglobina											
Reduzida	-	-	-	-	-	-	-	-	-	16 (≅ 19%)	-

Fonte: Autoria própria

3.3. Padrões Radiológicos da Pneumonia

O diagnóstico radiológico, baseado em imagens, leva em consideração aspectos como: densidade, tamanho, número, homogeneidade, nitidez, definição de margens, localização, presença ou não de calcificações ou de escavações. Doenças alveolares apresentam características de consolidações pulmonares, que são criadas pela substituição do ar dos alvéolos por líquido, células ou a combinação destes dois. Nesta revisão a principal característica mapeada é a pneumonia, que é uma doença alveolar aguda [24].

Para a identificação de pneumonia os principais exames de imagens utilizados são a radiografia e a tomografia do tórax, as quais apresentam os seguintes planos: sagital, coronal ou frontal e transversal ou axial. A Figura 1 apresenta um raio-X com projeções axial e coronal em póstero-anterior (PA) onde o tórax é dividido em um compartimento mediano (mediastino) e dois laterais: pleuras e pulmões. O pulmão direito possui cissura oblíqua e horizontal que se divide em lobos superior, médio e inferior, já o pulmão esquerdo há apenas a cissura oblíqua que compõem os lobos superior e inferior [25]. Estas imagens buscam mostrar aos profissionais de saúde o estado dos pulmões para que um possível diagnóstico de pneumonia seja dado. Todavia, a literatura observa que existem padrões radiológicos para esta doença que variam de acordo com o agente etiológicos. Porém, em várias situações estes padrões se sobrepõem. Em função disto uma classificação comum é a separação por mecanismo de origem, podendo ser: pneumonia adquirida na comunidade (PAC), pneumonia nosocomial e pneumonia aspirativa. Essas pneumonias apresentam padrões como: consolidação do espaço aéreo conforme as Figura 2 e Figura 3 , vidro

fosco presentes nas Figura 4 e Figura 5, padrão nodular (composto por nódulos, reação granulomatosa e bronquiolite) e padrão reticular (com opacidades lineares intralobulares)[26].

Figura 1: Radiografia de tórax normal em PA e axial apontando as principais estruturas anatómicas identificáveis. AE – Átrio Esquerdo, VE – Ventrículo Esquerdo, AD – Átrio direito, LS – lobo superior, LM – lobo médio, LI – lobo inferior.

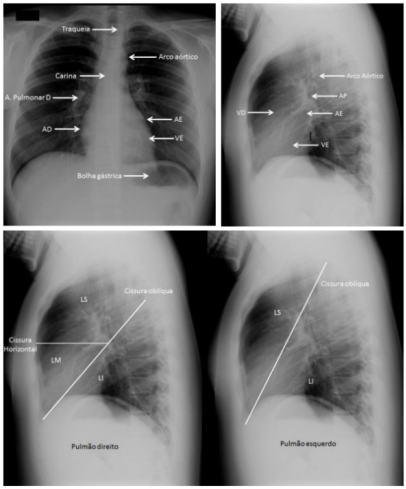

3.4. Padrões Radiológicos da Pneumonia Induzida pela COVID-19

A pneumonia induzida pela COVID-19 possui alguns padrões particulares identificados em exames de raio-X e tomografia do tórax como a presença de opacidade de vidro fosco, consolidação padrão reticular e linhas subpleurais. Os autores Shi et al.(2020) apresentaram um estudo com 81 pacientes da China acometidos pela COVID-19, onde foram encontrados padrões de anormalidade nos exames radiológicos, sendo que dos 81 pacientes a porcentagem de anomalias mapeadas são: 79% bilateral, 54% periférico e em 81% apresentaram anomalias mal definidas, além disso, 79% dos pacientes apresentaram opacidade de vidro fosco, Figura 4 e Figura 5.

Figura 2: Bronquiolite obliterante com pneumonia em organização. Corte axial na tomografia computadorizada de alta resolução onde evidencia áreas de consolidação bilaterais com típica distribuição Peribrônquica.

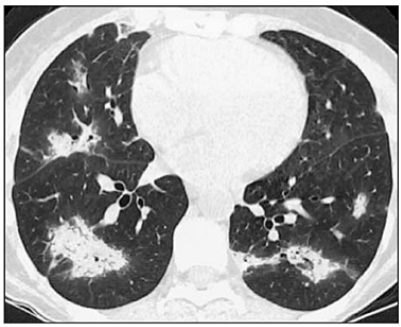

Figura 3: Pneumonia bacteriana no pulmão esquerdo, na forma de consolidação do espaço aéreo (seta). Com contornos mal definidos, algodonosos, e na distribuição segmentar.

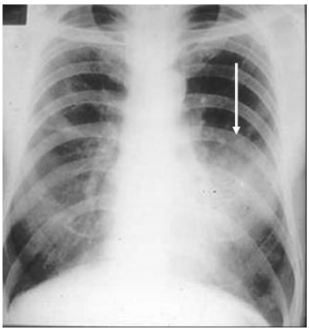

Figura 4: Tomografia de seção fina transversal do tóráx com padrão de vidro fosco em paciente com COVID-19.

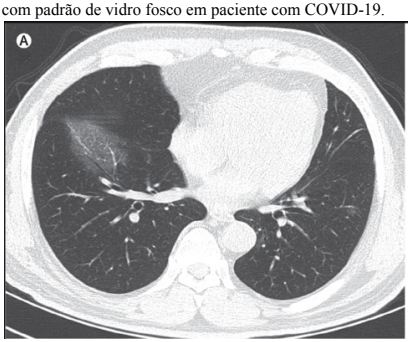

Figura 5: Raio-X com opacidades em vidro fosco (seta preta) em paciente com COVID-19.

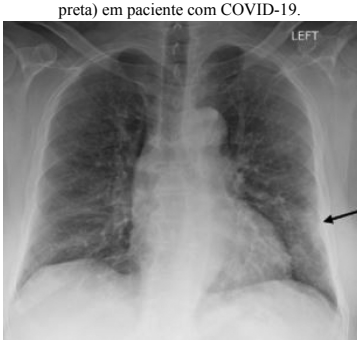

Os achados radiológicos mais comuns da pneumonia ocasionada pela COVID-19 são predominados por padrões periféricos, opacidades bilaterais de vidro fosco, consolidações, também é comum a combinação de vidro fosco com consolidações sobreposto com espessamento septal interlobular/intralobular criando assim o padrão conhecido como *crazy paving* [18 27 28] .

Baseados nesses padrões radiológicos diversos estudos vêm sendo desenvolvidos, como por exemplo os dos autores Delli Pizzi et al que utilizando aprendizado de máquina diferenciar opacidade de vidro fosco de pacientes com doença pulmonares, com o objetivo auxiliar a identificação mais rápida do diagnóstico de COVID-19 para que uma triagem adequada seja dada ao paciente [29]. A busca por

quantificação de achados de vidro fosco utilizando redes neurais é presente no trabalho de et al, os seus resultados atingiram uma acurácia de 78% para predição de positiva de COVID-19 [30], a Figura 6 apresenta a segmentação da rede neural criada pelos autores para identificação de vidro fosco.

Figura 6: Áreas segmentadas para identificação de vidro fosco.

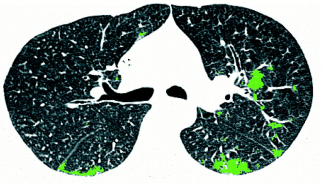

4. Conclusão

A análise dos trabalhos permitiu um mapeamento de todas as fontes de dados *open source* para a qual gerou-se a Tabela 2, essa tabela facilita possíveis trabalhos que buscam dados de imagens médicas de pacientes com COVID-19. Os autores Jain et al.(2020), Dansana et al.(2020), Bai et al.(2020), Zhang et al.(2020) e Harmon et al.(2020) foram um dos poucos artigos adquiridos pela expressão de busca que disponibilizaram código e/ou dados do algoritmo para a comunidade, devido isto a busca foi estendida à plataforma Kaggle. O mapeamento também permitiu identificar que grande parte dos dados disponíveis são de pacientes chineses com idade entre 40 a 60 anos, podendo trazer um possível viés para os algoritmos de predição apresentados. A febre, tosse e fadiga é identificada em grande parte dos pacientes, entre as comorbidades mais comuns encontra-se a diabetes e hipertensão, no entanto o número de pessoas analisadas na Tabela 3 e 4 que trazem um médias desses sintomas e comorbidade é muito reduzido.

De maneira geral, a revisão integrativa realizada possibilitou o mapeamento dos sintomas mais comuns da doença, e também os principais padrões de exames de imagens dos pacientes que foram acometidos pela COVID-19. A disponibilidade de dados ainda é baixa, no entanto foi possível detectar que a principal técnica de aprendizado profundo utilizada quando a entrada de dados são imagens é rede neural convolucional.

Referências

1. World Health Organization. WHO Coronavirus (COVID-19) Dashboard [Internet]. 2022. Disponível em: https://covid19.who.int/
2. Rajpurkar P, Irvin J, Zhu K, Yang B, Mehta H, Duan T, et al. CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. ArXiv171105225 Cs Stat [Internet]. 25 de dezembro de 2017 [citado 18 de fevereiro de 2022]; Disponível em: http://arxiv.org/abs/1711.05225
3. Nahid A-A, Sikder N, Bairagi AK, Razzaque MdA, Masud M, Z. Kouzani A, et al. A Novel Method to Identify Pneumonia through Analyzing Chest Radiographs Employing a Multichannel Convolutional Neural Network. Sensors. 19 de junho de 2020;20(12):3482.
4. Rajaraman S, Antani S. Training deep learning algorithms with weakly labeled pneumonia chest X-ray data for COVID-19 detection [Internet]. Radiology and Imaging; 2020 maio [citado 18 de fevereiro de 2022]. Disponível em: http://medrxiv.org/lookup/doi/10.1101/2020.05.04.20090803
5. Ozturk T, Talo M, Yildirim EA, Baloglu UB, Yildirim O, Rajendra Acharya U. Automated detection of COVID-19 cases using deep neural networks with X-ray images. Comput Biol Med. junho de 2020;121:103792.
6. Mittal A, Kumar D, Mittal M, Saba T, Abunadi I, Rehman A, et al. Detecting Pneumonia Using Convolutions and Dynamic Capsule Routing for Chest X-ray Images. Sensors. 15 de fevereiro de 2020;20(4):1068.
7. Kaggle Dataset [Internet]. Disponível em: https://www.kaggle.com/datasets
8. Jain G, Mittal D, Thakur D, Mittal MK. A deep learning approach to detect Covid-19 coronavirus with X-Ray images. Biocybern Biomed Eng. outubro de 2020;40(4):1391–405.
9. Dansana D, Kumar R, Bhattacharjee A, Hemanth DJ, Gupta D, Khanna A, et al. Early diagnosis of COVID-19-affected patients based on X-ray and computed tomography images using deep learning algorithm. Soft Comput [Internet]. 28 de agosto de 2020 [citado 18 de fevereiro de 2022]; Disponível em: https://link.springer.com/10.1007/s00500-020-05275-y
10. Bai HX, Wang R, Xiong Z, Hsieh B, Chang K, Halsey K, et al. Artificial Intelligence Augmentation of Radiologist Performance in Distinguishing COVID-19 from Pneumonia of Other Origin at Chest CT. Radiology. setembro de 2020;296(3):E156–65.
11. Angelov P, Soares E. EXPLAINABLE-BY-DESIGN APPROACH FOR COVID-19 CLASSIFICATION VIA CT-SCAN [Internet]. Health Informatics; 2020 abr [citado 19 de fevereiro de 2022]. Disponível em: http://medrxiv.org/lookup/doi/10.1101/2020.04.24.20078584
12. Zhang K, Liu X, Shen J, Li Z, Sang Y, Wu X, et al. Clinically Applicable AI System for Accurate Diagnosis, Quantitative Measurements, and Prognosis of COVID-19 Pneumonia Using Computed Tomography. Cell. junho de 2020;181(6):1423-1433.e11.
13. Harmon SA, Sanford TH, Xu S, Turkbey EB, Roth H, Xu Z, et al. Artificial intelligence for the detection of COVID-19 pneumonia on chest CT using multinational datasets. Nat Commun. dezembro de 2020;11(1):4080.
14. Gong J, Dong H, Xia Q, Huang Z, Wang D, Zhao Y, et al. Correlation Analysis Between Disease Severity and Inflammation-related Parameters in Patients with COVID-19 Pneumonia [Internet]. Infectious Diseases (except HIV/AIDS); 2020 fev [citado 18 de fevereiro de 2022]. Disponível em: http://medrxiv.org/lookup/doi/10.1101/2020.02.25.20025643
15. Udugama B, Kadhiresan P, Kozlowski HN, Malekjahani A, Osborne M, Li VYC, et al. Diagnosing COVID-19: The Disease and Tools for Detection. ACS Nano. 28 de abril de 2020;14(4):3822–35.
16. Struyf T, Deeks JJ, Dinnes J, Takwoingi Y, Davenport C, Leeflang MM, et al. Signs and symptoms to determine if a patient presenting in primary care or hospital outpatient settings has COVID-19 disease. Cochrane Infectious Diseases Group, organizador. Cochrane Database Syst Rev [Internet]. 7 de julho de 2020 [citado 18 de fevereiro de

2022]; Disponível em: https://doi.wiley.com/10.1002/14651858.CD013665
17. Zhao W, Zhong Z, Xie X, Yu Q, Liu J. Relation Between Chest CT Findings and Clinical Conditions of Coronavirus Disease (COVID-19) Pneumonia: A Multicenter Study. Am J Roentgenol. maio de 2020;214(5):1072–7.
18. Department of Radiology, Koc University School of Medicine, Istanbul, Turkey, Guneyli S, Atceken Z, Department of Radiology, Koc University School of Medicine, Istanbul, Turkey, Dogan H, Department of Radiology, Koc University School of Medicine, Istanbul, Turkey, et al. Radiological approach to COVID-19 pneumonia with an emphasis on chest CT. Diagn Interv Radiol. 2 de julho de 2020;26(4):323–32.
19. Song F, Shi N, Shan F, Zhang Z, Shen J, Lu H, et al. Emerging 2019 Novel Coronavirus (2019-nCoV) Pneumonia. Radiology. abril de 2020;295(1):210–7.
20. Guan W, Ni Z, Hu Y, Liang W, Ou C, He J, et al. Clinical Characteristics of Coronavirus Disease 2019 in China. N Engl J Med. 30 de abril de 2020;382(18):1708–20.
21. Shi H, Han X, Jiang N, Cao Y, Alwalid O, Gu J, et al. Radiological findings from 81 patients with COVID-19 pneumonia in Wuhan, China: a descriptive study. Lancet Infect Dis. abril de 2020;20(4):425–34.
22. Sun Y, Zhou J, Ye K. White Blood Cells and Severe COVID-19: A Mendelian Randomization Study. J Pers Med. 12 de março de 2021;11(3):195.
23. Han R, Huang L, Jiang H, Dong J, Peng H, Zhang D. Early Clinical and CT Manifestations of Coronavirus Disease 2019 (COVID-19) Pneumonia. Am J Roentgenol. agosto de 2020;215(2):338–43.
24. Escuissato DL. Bases Radiológicas das doenças torácicas [Internet]. 2018. Disponível em: https://dapi.com.br/wp-content/uploads/2018/11/bases-radiologicas-das-doencas-toracicas.pdf
25. Brentano V, Schnorr A, Lima M, Perez J. Interpretando a radiografia ed tórax na emergência [Internet]. 2018. Disponível em: https://docs.bvsalud.org/biblioref/2018/04/882682/interpretando-a-radiografia-de-torax-na-emergencia.pdf
26. Sharma S, Maycher B, Eschun G. Radiological imaging in pneumonia: recent innovations: Curr Opin Pulm Med. maio de 2007;13(3):159–69.
27. Duzgun SA, Durhan G, Demirkazik FB, Akpinar MG, Ariyurek OM. COVID-19 pneumonia: the great radiological mimicker. Insights Imaging. dezembro de 2020;11(1):118.
28. Sule A, ÖZLÜ T, YILMAZ A. Radiological approaches to COVID-19 pneumonia. Turk J Med Sci [Internet]. 16 de abril de 2020; Disponível em: https://journals.tubitak.gov.tr/medical/issues/sag-20-50-si-1/sag-50-si-1-17-2004-160.pdf
29. Delli Pizzi A, Chiarelli AM, Chiacchiaretta P, Valdesi C, Croce P, Mastrodicasa D, et al. Radiomics-based machine learning differentiates “ground-glass” opacities due to COVID-19 from acute non-COVID-19 lung disease. Sci Rep. dezembro de 2021;11(1):17237.
30. Kauczor H-U, Heitmann K, Heussel CP, Marwede D, Uthmann T, Thelen M. Automatic Detection and Quantification of Ground-Glass Opacities on High-Resolution CT Using Multiple Neural Networks: Comparison with a Density Mask. Am J Roentgenol. novembro de 2000;175(5):1329–34.

APÊNDICE B – CÓDIGO FONTE DAS ETAPAS DE PRÉ-PROCESSAMENTO

```
1  import csv
2  import os
3
4  import cv2
5  import numpy as np
6  import yaml
7  from matplotlib import pyplot as plt
8
9
10 def histogram(path_image):
11     im1 = cv2.imread(path_image)
12     img = cv2.cvtColor(im1, cv2.COLOR_BGR2GRAY)  #
           converte P&B
13
14     hist, bins = np.histogram(img.flatten(), 256, [0,
           256])
15     cdf = hist.cumsum()
16     cdf_normalized = cdf * float(hist.max()) / cdf.max()
17
18     plt.plot(cdf_normalized, color='b')
19     plt.hist(img.flatten(), 256, [0, 256], color='r')
20     plt.xlim([0, 256])
21     plt.legend(('cdf', 'histogram'), loc='upper left')
22     plt.show()
23
24
25 def equalization(path_image, path_image_salve):
26     #
           https://docs.opencv.org/4.x/d5/daf/tutorial_py_histogram_equal
27     im1 = cv2.imread(path_image)
28     img = cv2.cvtColor(im1, cv2.COLOR_BGR2GRAY)  #
           converte P&B
```

```
29      hist, bins = np.histogram(img.flatten(), 256, [0,
            256])
30      cdf = hist.cumsum()
31      cdf_normalized = cdf * float(hist.max()) / cdf.max()
32      cdf_m = np.ma.masked_equal(cdf, 0)  # For masked
            array, all operations are performed on
            non-masked elements.
33      cdf_m = (cdf_m - cdf_m.min()) * 255 / (
34              cdf_m.max() - cdf_m.min())  # ver função de
                    transferência em detalhes: Gonzalez &
                    Woods (capítulo 3).
35      cdf2 = np.ma.filled(cdf_m, 0).astype('uint8')
36      img2 = img.copy()
37
38      # Agora temos a tabela de consulta que nos dá as
            informações sobre qual é o valor do pixel de
            saída para
39      # cada valor do pixel de entrada. Então, apenas
            aplicamos a transformação:
40
41      img2 = cdf2[img]
42      cv2.imwrite(path_image_salve, img2)
43
44
45  def paths_equalizalization(input_path,
        output_path_final):
46      cont = 0
47      for paths, subpaths, files in os.walk(input_path):
48          for name_image in files:
49              explod_file = name_image.split('.')
50              extension = explod_file[-1]
51              if extension == 'png' or extension == 'jpg'
                    or extension == 'jpeg':
52                  equalization(input_path + name_image,
                        output_path_final + name_image)
53                  cont = cont + 1
54                  print(str(cont))
```

```
55
56
57 def clahe(input_path, output_path_final):
58     cont = 0
59     for paths, subpaths, files in os.walk(input_path):
60         for name_image in files:
61             explod_file = name_image.split('.')
62             extension = explod_file[-1]
63             if extension == 'png' or extension == 'jpg'
                   or extension == 'jpeg':
64                 #
                       https://docs.opencv.org/4.x/d5/daf/tutorial_py_hist
65                 im1 = cv2.imread(input_path +
                       name_image)
66                 img = cv2.cvtColor(im1,
                       cv2.COLOR_BGR2GRAY)  # converte P&B
67                 clahe = cv2.createCLAHE(clipLimit=2.0,
                       tileGridSize=(4, 4))
68                 cl1 = clahe.apply(img)
69                 cv2.imwrite(output_path_final +
                       name_image, cl1)
70                 cont = cont + 1
71                 print(str(cont))
72
73
74 def reshape(path_image):
75     X = []
76     image = cv2.imread(path_image)
77     image = cv2.resize(image, (224, 224),
           interpolation=cv2.INTER_AREA)
78     print(image.shape)
79     X.append(image)
80     print(X)
81     X = np.array(X)
82     print(X)
83     x_train = np.reshape(X, (len(X), 224, 224,
           3)).astype('float32')
```

```
84      print(x_train)
85
86
87
88  def transform_img_1channel_to_3channel(path_image):
89      try:
90          image = cv2.imread(path_image)
91          image = cv2.resize(image, (224, 224),
                interpolation=cv2.INTER_AREA)
92          print(image.shape)
93          cv2.imwrite('teste1.jpg', image)
94          image = cv2.imread(path_image)
95          image = cv2.resize(image, (224, 224), 1,
                interpolation=cv2.INTER_AREA)
96          cv2.imwrite('teste2.jpg', image)
97          print(image.shape)
98          print('OK: ' + path_image)
99      except Exception as e:
100         print('ERRO: ' + path_image)
101
102     img = cv2.imread(path_image)
103     print(img.shape)
104     gray = cv2.cvtColor(img, cv2.COLOR_BGR2HSV)
105     img2 = np.zeros_like(img)
106     img2[:, :, 0] = gray
107     img2[:, :, 1] = gray
108     img2[:, :, 2] = gray
109     cv2.imwrite('10524.jpg', img2)
110
111
112
113 def cut_images_hcpa():
114     cfg =
            yaml.full_load(open("C:/Users/nouar/PycharmProjects/LNCC-
            'r'))
115     path_image = cfg['PATHS']['LOCAL_IMAGES_HCPA']
116     path_images = cv2.imread(path_image, 0)
```

```
117     img_grey1 = path_images
118     # Binarizando
119     # T = mahotas.thresholding.rc(img_grey1)
120     T = 255
121     temp1 = img_grey1.copy()
122     temp1[temp1 > T] = 255
123     temp1[temp1 < T] = 0
124     temp1 = cv2.bitwise_not(temp1)
125     # Calculando os momentos da imagem
126     M = cv2.moments(temp1)
127     print(M)
128
129     # Calculando o centroide
130     cx = int(M['m10'] / M['m00'])
131     cy = int(M['m01'] / M['m00'])
132
133     # M['m00'] --> momento não normalizado:
            www.lapix.ufsc.br/ensino/reconhecimento-de-padroes/gerando-pad
134
135     lado = cv2.countNonZero(temp1[cy])
136
137     plt.figure(figsize=(15, 15))
138     plt.subplot(1, 3, 1)
139     plt.imshow(temp1[::4, ::4], cmap='gray')
140     plt.title("Imagem Binarizada")
141
142     plt.subplot(1, 3, 2)
143     plt.imshow(img_grey1[::4, ::4], cmap='gray')
144     plt.title("Resultado do Recorte a ser realizado")
145
146     coor_1 = cy - lado / 2
147     coor_2 = cy + lado / 2
148     coor_3 = cx - lado / 2
149     coor_4 = cx + lado / 2
150
151     recorte = img_grey1[int(coor_1):int(coor_2),
            int(coor_3):int(coor_4)]
```

```
152     plt.subplot(1, 3, 3)
153     plt.imshow(recorte, cmap='gray')
154     plt.title("imagem Recortada")
155
156
157 def process_clahe(image, output_path_clahe):
158     # create a CLAHE object (Arguments are optional).
159     clahe = cv2.createCLAHE(clipLimit=2.0,
            tileGridSize=(8, 8))
160     cl1 = clahe.apply(image)
161     cv2.imwrite(output_path_clahe, cl1)
162
163
164 def process_remove_text(local_image):
165     print('Lendo:' + local_image)
166     image = cv2.imread(local_image)
167     mask = cv2.threshold(image, 230, 255,
            cv2.THRESH_BINARY)[1][:, :, 0].astype(np.uint8)
168     image = image.astype(np.uint8)
169     result = cv2.inpaint(image, mask, 10,
            cv2.INPAINT_NS).astype(np.float32)
170     return result
171
172
173 def process_images(input_path, output_path_clahe,
        output_path_final):
174     for paths, subpaths, files in os.walk(input_path):
175         for name_image in files:
176             explod_file = name_image.split('.')
177             extension = explod_file[-1]
178             if extension == 'png' or extension == 'jpg'
                    or extension == 'jpeg':
179                 image = cv2.imread(input_path +
                        name_image, 0)
180                 print(input_path + name_image)
181                 print('-----')
182                 process_clahe(image, output_path_clahe
```

```
                    + name_image)
183                 print(output_path_clahe + name_image)
184                 print('-----')
185                 image_processed =
                        process_remove_text(output_path_clahe
                        + name_image)
186                 print(output_path_final + name_image)
187                 print('ffffffff')
188                 cv2.imwrite(output_path_final +
                        name_image, image_processed)
189
190
191 def process_images_BIMCV(input_path, output_path_8bit):
192     try:
193         for paths, subpaths, files in
                os.walk(input_path):
194             for file in files:
195                 explod_file = file.split('.')
196                 extension = explod_file[-1]
197                 if extension == 'png' or extension ==
                        'jpg' or extension == 'jpeg':
198                     try:
199                         file_local =
                                os.path.join(paths, file)
200                         print(file)
201                         print(file_local)
202                         img = cv2.imread(file_local)
203                         img = np.array(img, dtype=float)
204                         img = (img - img.min()) /
                                (img.max() - img.min()) *
                                255.0
205                         img = img.astype(np.uint8)
206                         cv2.imwrite(os.path.join(output_path_8bit,
                                file), img)  # write png
                                image
207                     except Exception as e:
208                         print("ERRO: " + file_local)
```

```
209     except Exception as e:
210         print(str(e))
211
212
213 def remove_error_8bit(input_path):
214     try:
215         for paths, subpaths, files in
                os.walk(input_path):
216             for file in files:
217                 explod_file = file.split('.')
218                 extension = explod_file[-1]
219                 if extension == 'png' or extension ==
                        'jpg' or extension == 'jpeg':
220                     try:
221                         if '8bit' in str(file):
222                             file_local = input_path +
                                    file
223                             if
                                    os.path.exists(file_local):
224                                 os.remove(file_local)
225                                 print(file_local)
226                                 print('----')
227                     except Exception as e:
228                         print("ERRO: " + file_local)
229     except Exception as e:
230         print(str(e))
231
232
233 def create_metadata(path, flag_covid, name_csv):
234     f = open(name_csv, 'w')
235     file_csv = csv.writer(f)
236     data = ['filename, label, label_str, filename_ro']
237     file_csv.writerow(data)
238     for diretorio, subpastas, arquivos in os.walk(path):
239         for arquivo in arquivos:
240             print(os.path.join(diretorio, arquivo))
241             explod_file = arquivo.split('.')
```

```
242             extension = explod_file[-1]
243             if extension == 'png' or extension == 'jpg'
                    or extension == 'jpeg':
244                 if flag_covid is True:
245                     data = [os.path.join(diretorio,
                            arquivo), '1', 'COVID-19']
246                     file_csv.writerow(data)
247                 else:
248                     data = [os.path.join(diretorio,
                            arquivo), '0', 'non-COVID-19']
249                     file_csv.writerow(data)
```

APÊNDICE C – SCRIPT PARA SUBMISSÃO DE UM *JOB* NO SANTOS DUMONT

```
1
2  #!/bin/bash
3  #SBATCH --nodes=1
                          #Número de nós
4  #SBATCH --ntasks-per-node=1
                          #Numero de tarefas por nós
                           #SBATCH --ntasks=1
                                                  #Numero
       de tarefas
5  #SBATCH -p sequana_gpu
                          #Fila (partition) a ser utilizada
6  #SBATCH -J str-101-hcpa
                          #Nome job
                                               #SBATCH
       --exclusive

       #Solicitação de exclusividade do nó
7  #SBATCH --time=12:00:00
                          #Tempo de alocação de recurso
8
9  #Exibe os nos alocados para o Job
10 echo $SLURM_JOB_NODELIST
11 nodeset -e $SLURM_JOB_NODELIST
12
13 cd $SLURM_SUBMIT_DIR
14 #Configura as libs necessárias para o modelo rodar
15 module load anaconda3/2020.11
16 source activate
       /scratch/covnet-ufcspa/nouara.xavier/conda3/ambiente_conda_3_
17 source install -c anaconda numpy
18 source install -c anaconda pandas
19 source install -c conda-forge pyaml
```

```
20 source install -c anaconda scikit-learn
21 source install -c conda-forge matplotlib
22 source install -c conda-forge keras
23 source install -c conda-forge opencv
24
25
26
27 #Acessa diretório onde está o modelo a ser treinado
28 cd
       /scratch/covnet-ufcspa/nouara.xavier/strategic/resnet101v2
29
30 #Executa o arquivo principal para treinamento
31 python train_3chanel_multiplostestes.py
```

APÊNDICE D – CÓDIGO FONTE DO MAPA DE CALOR

```
1  import numpy as np
2  from tensorflow import keras
3  import tensorflow as tf
4
5  # Display
6  from IPython.display import Image, display
7  import matplotlib.cm as cm
8
9
10 def get_img_array(img_path, size):
11     img = keras.preprocessing.image.load_img(img_path,
           target_size=size)
12     array = keras.preprocessing.image.img_to_array(img)
13     array = np.expand_dims(array, axis=0)
14     return array
15
16
17 def make_gradcam_heatmap(img_array, model,
       last_conv_layer_name, pred_index=None):
18     grad_model = tf.keras.models.Model(
19         [model.inputs],
               [model.get_layer(last_conv_layer_name).output,
               model.output]
20     )
21     with tf.GradientTape() as tape:
22         last_conv_layer_output, preds =
               grad_model(img_array)
23         if pred_index is None:
24             pred_index = tf.argmax(preds[0])
25         class_channel = preds[:, pred_index]
26
27     # This is the gradient of the output neuron (top
```

```
        predicted or chosen)
28      # with regard to the output feature map of the last
            conv layer
29      grads = tape.gradient(class_channel,
            last_conv_layer_output)
30
31      # This is a vector where each entry is the mean
            intensity of the gradient
32      # over a specific feature map channel
33      pooled_grads = tf.reduce_mean(grads, axis=(0, 1, 2))
34
35      # We multiply each channel in the feature map array
36      # by "how important this channel is" with regard to
            the top predicted class
37      # then sum all the channels to obtain the heatmap
            class activation
38      last_conv_layer_output = last_conv_layer_output[0]
39      heatmap = last_conv_layer_output @
            pooled_grads[..., tf.newaxis]
40      heatmap = tf.squeeze(heatmap)
41
42      # For visualization purpose, we will also normalize
            the heatmap between 0 & 1
43      heatmap = tf.maximum(heatmap, 0) /
            tf.math.reduce_max(heatmap)
44      return heatmap.numpy()
45
46
47  def save_and_display_gradcam(img, heatmap,
        cam_path="cam.png", alpha=0.4):
48      # Load the original image
49      #img = keras.preprocessing.image.load_img(img_path)
50      #img = keras.preprocessing.image.img_to_array(img)
51      #print(img.shape)
52
53
54      # Rescale heatmap to a range 0-255
```

```
    heatmap = np.uint8(255 * heatmap)

    # Use jet colormap to colorize heatmap
    jet = cm.get_cmap("jet")

    # Use RGB values of the colormap
    jet_colors = jet(np.arange(256))[:, :3]
    jet_heatmap = jet_colors[heatmap]

    # Create an image with RGB colorized heatmap
    jet_heatmap =
        keras.preprocessing.image.array_to_img(jet_heatmap)
    jet_heatmap = jet_heatmap.resize((img.shape[1],
        img.shape[0]))
    jet_heatmap =
        keras.preprocessing.image.img_to_array(jet_heatmap)

    # Superimpose the heatmap on original image
    superimposed_img = jet_heatmap * alpha + img
    superimposed_img =
        keras.preprocessing.image.array_to_img(superimposed_img)

    # Save the superimposed image
    superimposed_img.save(cam_path)

    # Display Grad CAM
    display(Image(cam_path))
```

Anexos

ANEXO A – PARECER CONSUBSTANCIADO DO CEP

HOSPITAL DE CLÍNICAS DE PORTO ALEGRE DA UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - HCPA UFRGS

PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: APLICAÇÃO DE UM ALGORITMO COM INTELIGÊNCIA ARTIFICIAL PARA O AUXÍLIO NO DIAGNÓSTICO DE COVID-19

Pesquisador: ALEXANDRE BACELAR

Área Temática:

Versão: 4

CAAE: 35219020.1.0000.5327

Instituição Proponente: Fundo de Incentivo à Pesquisa e Eventos

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 4.508.683

Apresentação do Projeto:

O diagnóstico por imagens médicas é uma realidade em diversos serviços hospitalares ao redor do mundo. Dentre as imagens mais solicitadas por radiologistas, especificamente, de suspeitas de doenças pulmonares são as imagens radiográficas. O princípio físico da geração de uma imagem pelo método de imagens por raios-X está relacionado, basicamente, pela interação da radiação ionizante, com energia de até 250 kV, que atravessa o corpo do paciente e forma uma imagem em sistema detector da radiação. O contraste radiológico é uma característica mais significativa de uma imagem, apresentado como diversos tons de cinza, resultado da atenuação diferencial dos raios-X devido aos diferentes números atômicos das estruturas e tecidos do paciente. Assim, o diagnóstico, mas acurado irá depender da qualidade da imagem, por a qual, podem se diferenciar estruturas anatômicas distintas do paciente, especificamente as torácicas. A interpretação e identificação de alguma patologia, como aquelas causadas pela nova pandemia COVID-19 requer de um radiologista com experiência, o qual também, pode cometer alguns erros enquanto aos seus limites como ser humano estejam comprometidos, como por exemplo, o cansaço. Alguns mecanismos computacionais como inteligência artificial (IA) poderiam ser uma ferramenta para o auxílio no diagnóstico de patologias torácicas causadas pelo COVID-19, por meio de imagens radiológicas, que se apresentam com intensidades diversas em preto e branco, contornos e

Endereço: Rua Ramiro Barcelos 2.350 sala 2229
Bairro: Santa Cecília **CEP:** 90.035-903
UF: RS **Município:** PORTO ALEGRE
Telefone: (51)3359-7640 **Fax:** (51)3359-7640 **E-mail:** cep@hcpa.edu.br

Continuação do Parecer: 4.508.683

formas, as quais podem ser analisadas por IA.

Objetivo da Pesquisa:

Objetivo

Aprimorar um algoritmo baseado em inteligência artificial para diagnóstico de doenças respiratórias já desenvolvido e reportado em (ELKINS et al., 2019), e aplicá-lo no diagnóstico de COVID-19 utilizando dados de imagens de raios-x do Hospital das Clínicas de Porto Alegre.

Objetivos específicos:

I Analisar o estado das radiografias digitais de tórax, especificamente, de imagens com diagnóstico de doenças pulmonares causadas pelo vírus COVID-19.

II Construção de um banco de imagens de raios X de tórax com diagnóstico confirmado por outros exames, proveniente do sistema PACAS do Hospital de Clínicas de Porto Alegre.

III Aplicar métodos estatísticos para classificar as características da base de dados, relativo a doença causada pelo vírus.

IV Teste da arquitetura das redes neurais utilizando softwares PyTorch.

V Treinar e melhorar o algoritmo desenvolvido pelos pesquisadores do presente projeto na determinação de diagnóstico induzido, por meio de padrões de reconhecimento das doenças.

VI Desenvolver um aplicativo para uso dos funcionários do setor de radiodiagnóstico do Hospital de Clínicas de Porto Alegre.

VII Avaliar, validar quantitativamente e qualitativamente a qualidade do algoritmo em termos de capacidade de detecção das doenças pulmonares. Uma vez realizadas os objetivos específicos serão elaborados artigos científicos, de relatórios técnicos e de produtos.

Avaliação dos Riscos e Benefícios:

Riscos: Os potenciais riscos desta pesquisa se limitam a quebra de sigilo.

Benefícios: Os benefícios são indiretos, relacionados aos achados para indicação de diagnóstico de COVID19.

HOSPITAL DE CLÍNICAS DE PORTO ALEGRE DA UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - HCPA UFRGS

Continuação do Parecer: 4.508.683

Comentários e Considerações sobre a Pesquisa:
A pesquisa em questão tem como tema o estudo de imagens aliado a Inteligência artificial para diagnóstico da COVID-19, amplamente abordado atualmente.

Considerações sobre os Termos de apresentação obrigatória:
Vide "Conclusões ou Pendências e Lista de Inadequações".

Recomendações:
Não localizamos a nova versão de TCLE para profissionais, mas, as respostas às pendências estão adequadas, portanto, deverá ser utilizadas versão atualizada conforme resposta ao parecer N.º 4.329.399.

Conclusões ou Pendências e Lista de Inadequações:
As pendências emitidas para o projeto nos pareceres N.º 4.254.904 e N.º 4.329.399 foram respondidas pelos pesquisadores, conforme cartas de resposta adicionadas em 18/09/2020 e 18/01/2021. Não apresenta novas pendências.

Considerações Finais a critério do CEP:
Lembramos que a presente aprovação (projeto e TCLE versão de 18/01/2021 e demais documentos que atendem às solicitações do CEP) refere-se apenas aos aspectos éticos e metodológicos do projeto.

Os pesquisadores devem atentar ao cumprimento dos seguintes itens:
a) Este projeto está aprovado para inclusão de 1500 participantes no Centro HCPA, de acordo com as informações do projeto. Qualquer alteração deste número deverá ser comunicada ao CEP e ao Serviço de Gestão em Pesquisa para autorizações e atualizações cabíveis.
b) O projeto está cadastrado no sistema AGHUse Pesquisa (20200296) para fins de avaliação logística e financeira e somente poderá ser iniciado após aprovação final do Grupo de Pesquisa e Pós-Graduação.
c) Qualquer alteração nestes documentos deverá ser encaminhada para avaliação do CEP. Informamos que obrigatoriamente a versão do TCLE a ser utilizada deverá corresponder na íntegra à versão vigente aprovada.
d) Deverão ser adicionados relatórios semestrais e um relatório final do projeto no cadastro do mesmo, no Sistema AGHUse Pesquisa.
e) Eventos adversos deverão ser comunicados de acordo com as orientações da Comissão Nacional

Endereço: Rua Ramiro Barcelos 2.350 sala 2229
Bairro: Santa Cecília **CEP:** 90.035-903
UF: RS **Município:** PORTO ALEGRE
Telefone: (51)3359-7640 **Fax:** (51)3359-7640 **E-mail:** cep@hcpa.edu.br

HOSPITAL DE CLÍNICAS DE PORTO ALEGRE DA UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - HCPA UFRGS



de Ética em Pesquisa - Conep (Carta Circular nº 13/2020-CONEP/SECNS/MS). Os desvios de protocolo também deverão ser comunicados em relatórios consolidados, por meio de Notificação.

Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1592337.pdf	18/01/2021 23:33:37		Aceito
Outros	01_2021_Parecer_Comite_Estrategico.pdf	18/01/2021 23:32:36	MIRKO SALOMON ALVA SÁNCHEZ	Aceito
Outros	V3_Conclusoes_ou_Pendencias_3.pdf	18/01/2021 23:31:22	MIRKO SALOMON ALVA SÁNCHEZ	Aceito
Brochura Pesquisa	Versao3_IACOVID_CEP.pdf	18/01/2021 23:29:19	MIRKO SALOMON ALVA SÁNCHEZ	Aceito
Outros	Pendencias_ultimas.pdf	18/09/2020 16:42:10	MIRKO SALOMON ALVA SÁNCHEZ	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	Modelo_TCLE.pdf	18/09/2020 16:40:47	MIRKO SALOMON ALVA SÁNCHEZ	Aceito
Projeto Detalhado / Brochura Investigador	IA_COVID_CEP_atual.pdf	18/09/2020 16:40:20	MIRKO SALOMON ALVA SÁNCHEZ	Aceito
Outros	Pendencias.pdf	26/08/2020 00:15:09	MIRKO SALOMON ALVA SÁNCHEZ	Aceito
Outros	Autrorizacao_Chefia.pdf	09/07/2020 23:39:09	MIRKO SALOMON ALVA SÁNCHEZ	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE.pdf	09/07/2020 23:37:59	MIRKO SALOMON ALVA SÁNCHEZ	Aceito
Folha de Rosto	FolhasdeRosto.pdf	09/07/2020 23:35:03	MIRKO SALOMON ALVA SÁNCHEZ	Aceito
Cronograma	Cronograma.pdf	09/07/2020 15:22:51	MIRKO SALOMON ALVA SÁNCHEZ	Aceito

Situação do Parecer:
Aprovado

Necessita Apreciação da CONEP:

Endereço: Rua Ramiro Barcelos 2.350 sala 2229
Bairro: Santa Cecília **CEP:** 90.035-903
UF: RS **Município:** PORTO ALEGRE
Telefone: (51)3359-7640 **Fax:** (51)3359-7640 **E-mail:** cep@hcpa.edu.br

HOSPITAL DE CLÍNICAS DE PORTO ALEGRE DA UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - HCPA UFRGS

Continuação do Parecer: 4.508.683

Não

PORTO ALEGRE, 25 de Janeiro de 2021

Assinado por:
Marcia Mocellin Raymundo
(Coordenador(a))

Endereço: Rua Ramiro Barcelos 2.350 sala 2229
Bairro: Santa Cecília **CEP:** 90.035-903
UF: RS **Município:** PORTO ALEGRE
Telefone: (51)3359-7640 **Fax:** (51)3359-7640 **E-mail:** cep@hcpa.edu.br

ANEXO B – PROPOSTA DE USO SUPERCOMPUTADORES SANTOS DUMONT E LOBO CARNEIRO

LNCC
www.lncc.br
Laboratório Nacional de Computação Científica

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES

PÁTRIA AMADA BRASIL GOVERNO FEDERAL

Av. Getúlio Vargas 333, Quitandinha, Petrópolis, RJ - Cep 25651-075

Formulário de Proposta de uso dos Supercomputadores Santos Dumont (SDumont/LNCC) e Lobo Carneiro (LoboC/UFRJ)

POR FAVOR, NÃO PREENCHER ESTE CAMPO	
Proposta Número	

ATENÇÃO: antes de preencher este formulário, leia atentamente em http://sdumont.lncc.br/alloc.php a definição dos Programas de Alocação disponíveis. Leia também em http://sdumont.lncc.br/machine.php e em http://www.nacad.ufrj.br/pt/recursos/sgiicex, as respectivas características técnicas. Recomenda-se o uso dos seguintes programas para preenchimento deste formulário: Windows - Adobe Acrobat DC; Linux - Evince; Mac - Preview.

Selecionar um Programa de Alocação

○	**Premium**
○	**Standard**
⊙	**Educacional**

Dados do Projeto

Título
Arquitetura de Aprendizado de Máquina Multimodal para Auxílio do Diagnóstico da Covid-19
Áreas de Pesquisa: escolher de 1 a 4 áreas de pesquisa
Área 1: Ciência da computação
Área 2: Ciências da saúde
Área 3: Engenharias
Outra:

Dados do Proponente (coordenador do projeto)

Nome
Carla Diniz Lopes Becker
Instituição
Fundação Universidade Federal de Ciência da Saúde de Porto Alegre
Departamento
Departamento de Ciências Exatas, Sociais e Aplicadas (DECESA)
Telefone
(51) 984421143
E-mail
becker.diniz@gmail.com

LNCC
www.lncc.br
Laboratório Nacional de Computação Científica

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES

PÁTRIA AMADA BRASIL GOVERNO FEDERAL

Av. Getúlio Vargas 333, Quitandinha, Petrópolis, RJ - Cep 25651-075

Endereço do CV Lattes (formato http://lattes.cnpq.br/xxxxxxxxxxxxxxx)
http://lattes.cnpq.br/6270631588851891
Endereço de correspondência
Logradouro: Rua Sarmento Leite
Número: 245
Complemento: Prédio 3
CEP: 90050170
Caixa Postal:
Bairro: Centro Histórico
Cidade: Porto Alegre
UF: Rio Grande do Sul

Detalhamento do Projeto

Resumo do Projeto: aqui, deve ser destacada a excelência científica e sua relevância no contexto da pesquisa brasileira, explicando a inovação, os aspectos transformadores e impacto científico esperado. A identificação de possíveis aplicações práticas, resultantes do projeto, é desejável. (Limite: 2400 caracteres)

Com a chegada do SARS-CoV-2, devido às suas características regionais e populacionais, um alto índice de contágio é verificado, sobrecarregando o Sistema de Saúde Pública (SUS) e causando um número significativo de óbitos (até o dia 30/07/20, 90 mil mortes), segundo o consórcio de veículos da imprensa.

As estratégias para a identificação do SARS-CoV-2 variam entre a aplicação de testes sorológicos, a realização de testes por reação em cadeia da polimerase por transcrição reversa (RT-PCR), vigilância de casos e a análise da tomografia computadorizada (CT). Dentre essas, a combinação do RT-PCR com a CT é descrita como as que oferecem o diagnóstico mais preciso da COVID-191. Todavia, a RT-PCR é custosa e complexa para ser realizada em larga escala, demandando equipes treinadas e equipamentos especializados2, restringindo a disponibilidade. Em locais afastados dos grandes centros, geralmente, a capacidade dos testes é limitada, devido à carência de suprimentos, e onde não há disponibilidade de aparelhos e estrutura para a realização de exames de CT, o raio X (RX) de tórax acabam sendo o único método de investigação. As imagens radiográficas por RX permitem a triagem rápida de pacientes com suspeita de COVID-19, e podem ser realizadas paralelamente a testes virais - cujo resultado pode ser demorado -, ajudando a aliviar o volume de pacientes, especialmente nas áreas mais afetadas.

Este projeto propõe uma arquitetura que permita a partir do treinamento de uma rede neural multimodal, utilizando dados clínicos e imagens médicas de pacientes com COVID-19, auxiliar na triagem de novos pacientes, apresentando uma ferramenta para apoio a tomada de decisão clínica. O objetivo principal é automatizar o processo de identificação de casos de COVID-19 através de técnicas de análise de dados e de Inteligência Artificial, utilizando dados clínicos e imagens médicas de pacientes.

[1] UDUGAMA, B.; KADHIRESAN, P.; KOZLOWSKI, H. N.; MALEKJAHANI, A.; OSBORNE, M.; LI, V. Y. C.; CHEN, H.; MUBAREKA, S.; GUBBAY, J. B.; CHAN, W. C. W. Diagnosing COVID-19: The Disease and Tools for Detection. ACS Nano, v. 14 n. 4, 3822–3835, 2020. https://doi.org/10.1021/acsnano.0c02624.

[2] CASTRO-DE ARAÚJO, L.; STRINA, A.; GRASSI, M.; TEIXEIRA, M. Aspectos clínicos e terapêuticos da infecção da COVID-19. Disponível em https://www.arca.fiocruz.br/handle/icict/40662. Acessado em 13 de maio de 2020.

LNCC
www.lncc.br
Laboratório Nacional de Computação Científica

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES

PÁTRIA AMADA BRASIL GOVERNO FEDERAL

Av. Getúlio Vargas 333, Quitandinha, Petrópolis, RJ - Cep 25651-075

Aplicações científicas a serem empregadas

OBSERVAÇÃO: havendo outras aplicações, para cada uma, copiar e colar a tabela acima, preenchendo-a com os dados de cada aplicação

A instalação ou transmissão de quaisquer programa de computador(software) não autorizado previamente pela área de suporte será de inteira responsabilidade do usuário.

DADOS DA APLICAÇÃO 1
Nome da aplicação e versão (acrônimo e por extenso):
COV-NET-UFCSPA 1.0.0.0

Tipo de Licença (Proprietária, Software Livre, In-house):
Software Livre

Linguagem (C, C++, FORTRAN, Python, e/ou outras):
Python

Compiladores necessários (GNU, Intel, PGI, e/ou outros):
GCC, CUDA 9.1

Biblioteca de processamento paralelo (MPI, OpenMP, OpenACC, OpenCL, e/ou outras):
opencv, python, tensorflow, gpu

Detalhes dos experimentos a serem conduzidos com as aplicações: quando pertinente, descrever o trabalho já feito para desenvolver códigos e/ou scripts, como eles foram implementados e paralelizados, seus principais gargalos de desempenho e as soluções planejadas para enfrentar eventuais problemas de desempenho em um supercomputador (Limite: 2.000 caracteres)

Quatro ensaios serão realizados. No primeiro ensaio o algoritmo utilizará imagens de raio X de pacientes com pneumonia causada por Sars-CoV-2 e por outros patógenos, e raio X de pacientes saudáveis. O segundo experimento utilizará somente dados tabulares, composto por exames clínicos e informações sociodemográficas. Este ensaio será completamente supervisionado, ou seja, todos os dados de treinamento serão rotulados. O terceiro experimento ocorrerá no formato de multi thread, em que o treinamento será realizado utilizando as imagens de raio X em uma thread, e em na outra thread será realizado um treinamento com dados tabulares, após todo o processamento do treinamento, de cada thread, os valores serão cruzados, esse experimento é classificado como uma rede neural multimodal com fusão tardia. O quarto experimento utilizará as imagens de raio X e os dados tabulares, que após o processamento das imagens na etapa de flattening fará o cruzamento dos dados e em seguida o treinamento, classificando assim o experimento como fusão intermediária.
Os gargalos de desempenho estão principalmente nas etapas de pré-processamento e treinamento das imagens. Algumas técnicas estão sendo adotadas na arquitetura em desenvolvimento, como o carregamento parcial das imagens, ou seja, as imagens são carregadas em lotes, conforme a necessidade da evolução do treinamento otimizando assim o uso de GPU e memória. Atualmente o lote de imagens da rede neural COVID-NET é de 14001 e a tendência é de crescimento, pois, técnicas como shift, onde a partir do deslocamento da imagem no eixo x e y é gerada outras imagens serão utilizada na criação de dados artificiais para etapa de treinamento.
[1]INVESTIGATION of Explainable Predictions of COVID-19 Infection from Chest X-rays with Machine Learning. [S. l.], 27 mar. 2020. Disponível em: https://towardsdatascience.com/investigation-of-explainable-predictions-of-covid-19-infection-from-chest-x-rays-with-machine-cb370f46af1d. Acesso em: 29 jul. 2020.

LNCC
www.lncc.br
Laboratório Nacional de Computação Científica

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES

PÁTRIA AMADA BRASIL GOVERNO FEDERAL

Av. Getúlio Vargas 333, Quitandinha, Petrópolis, RJ - Cep 25651-075

Justificativa da necessidade real de uso de um supercomputador como SDumont e LoboC (Limite: 1.400 caracteres)

Os dados de entrada são primordiais para o desempenho da arquitetura de aprendizado de máquina. A classificação das imagens do tórax do paciente desempenha um importante no auxílio ao diagnóstico.

A arquitetura identificará que a entrada é uma imagem e aplicará os algoritmos de redes convolucionais. A diferença entre o treinamento do dados tabulares e imagens está na convolução. Para o processamento da imagem as camadas de convolução e pooling são extremamente importantes e possuem o maior consumo de recursos de hardware.

A camada de convolução é responsável por obter um mapa de características (MCs) da imagem de entrada. Para obter as informações mais importantes do MCs, a camada de pooling atua na saída da camada convolucional buscando a redução do número de características para que haja uma redução no número de parâmetros nas camadas posteriores.

As etapas de pré-processamento, convolução e treinamento apresentam o maiores as complexidade da arquitetura, isso ocorre devido a elevada quantidade de cálculos matriciais e estatísticos, e também pela estrutura computacional massivamente paralelizada, sendo estas as principais motivações para a necessidade de um supercomputador, onde os recursos de GPU, memória RAM e multiprocessadores são primordiais para o desempenho da tarefa de predição proposta para a arquitetura em desenvolvimento.

Especificação do tipo de recurso necessário (ex.: uso de CPU multicore, aceleradores, aplicação intensiva de memória/CPU/I-O etc).

Neste campo pode-se também, opcionalmente, indicar uma preferência pelo uso de um dos dois supercomputadores (SDumont ou LoboC), que poderá ser levada em conta pelo Comitê Gestor quando da eventual implementação da proposta, se aprovada (Limite: 1000 caracteres)

Os recursos necessários utilizados na arquitetura estão especificados abaixo:
NVIDIA® GPU drivers —CUDA® 10.1 requires 418.x or higher.
CUDA® Toolkit —TensorFlow supports CUDA® 10.1 (TensorFlow >= 2.1.0)
CUPTI ships with the CUDA® Toolkit.
cuDNN SDK 7.6
TensorRT 6.0
HDF5

Número de tarefas que espera-se executar simultaneamente	4
Tempo de execução previsto de uma tarefa (em horas)	1 hora

Estimativa de número de núcleos de CPU e da quantidade de memória a ser utilizada por tarefa

	Número de núcleos computacionais	Memória (GB)
Mínimo		
Médio		
Máximo		