

Ednara Aparecida dos Santos Pereira

**Reconhecimento de COVID-19 e Pneumonia
Viral em Imagens de Raio-X através de Redes
Neurais Convolucionais**

São Luís - MA

2021

Ednara Aparecida dos Santos Pereira

**Reconhecimento de COVID-19 e Pneumonia Viral em
Imagens de Raio-X através de Redes Neurais
Convolucionais**

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão como parte dos requisitos necessários para obtenção do grau de bacharel em Ciência da Computação.

Orientador: Prof. Dr. Geraldo Braz Júnior

São Luís - MA

2021

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Diretoria Integrada de Bibliotecas/UFMA

Pereira, Ednara Aparecida dos Santos.

Reconhecimento de COVID-19 e Pneumonia Viral em Imagens de Raio-X através de Redes Neurais Convolucionais / Ednara Aparecida dos Santos Pereira. - 2021.

35 f.

Orientador(a): Geraldo Braz Júnior.

Monografia (Graduação) - Curso de Ciência da Computação, Universidade Federal do Maranhão, São Luís - MA, 2021.

1. COVID-19. 2. Deep Learning. 3. Radiografia. 4. Redes Neurais Convolucionais. I. Braz Júnior, Geraldo. II. Título.

Ednara Aparecida dos Santos Pereira

Reconhecimento de COVID-19 e Pneumonia Viral em Imagens de Raio-X através de Redes Neurais Convolucionais

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão como parte dos requisitos necessários para obtenção do grau de bacharel em Ciência da Computação.

Aprovado em:

Prof. Dr. Geraldo Braz Júnior
Orientador
Universidade Federal do Maranhão

Profª. Dra. Simara Vieira da Rocha
Examinador
Universidade Federal do Maranhão

Prof. Me. Carlos Eduardo Portela Serra De
Castro
Examinador
Universidade Federal do Maranhão

São Luís - MA

2021

Agradecimentos

A Deus e a meus pais que tudo fizeram e fazem por mim, e sempre apoiando e incentivando em todas as minhas escolhas.

A meu irmão Eduardo que sempre me incentivou a ser um exemplo mesmo sem nem ao menos ter ideia disso.

À toda à minha grande família que sempre me apoiou e ajudou.

Ao meu namorado, Gabriel, que me ajudou com o que pôde e com o que não pôde desde o início até aqui e por ter me proporcionado momentos incríveis nessa etapa da minha vida.

Às minhas amigas de infância Rayssa, Jordana e Bianca que fizeram parte de toda a minha história como estudante e como a pessoa que sou hoje.

Ao meu orientador Prof. Dr. Geraldo por além de aceitar ser meu orientador ter sido meu mentor neste curso desde o início, sempre me dando oportunidade e acreditando em mim, mesmo quando nem eu mesma acreditei.

À Profa. Dra. Simara por ser uma coordenadora incrível e fazer de tudo pelo os alunos do curso, além de ser uma pessoa maravilhosa que sempre me incentivou e contribuiu para a minha formação como cientista da computação e como pessoa.

À Profa. Ma. Greiciane, por ter acreditado em mim e me ajudado quando eu MUITO precisei.

Ao Prof. Dr. João Dallyson por ter me dado uma nova oportunidade em Estrutura de Dados II que foi um divisor de águas na minha graduação.

Aos meus amigos Yandson e Jéssica com quem compartilhei tantos momentos de alegria e aprendizado.

A todos os professores do curso não citados que construíram essa vitória junto comigo.

Ao PETComp que se tornou minha casa e família na UFMA com tantas experiências, aprendizados, amizades e momentos inesquecíveis.

Aos meus colegas de turma e todos os outros que não faço ideia de qual turma são por terem feito parte e contribuído com diversos momentos dessa jornada.

À todos aqueles que contribuíram diretamente e indiretamente para a realização deste trabalho e da construção desta etapa incrível da minha vida.

E a mim mesma, por não ter desistido.

Resumo

A COVID-19 é uma doença provocada pelo coronavírus SARS-CoV-2 podendo causar síndrome respiratória aguda e levar a óbito. Por ser de fácil contaminação logo se espalhou pelo mundo todo, resultando em uma grave pandemia. Para diminuir a contaminação e consequentemente casos graves e mortes é necessário que a contaminação seja contida, e com isso, os diagnósticos precisam ser rápidos e precisos, o que é uma dificuldade em muitos locais. A utilização de imagens de raio-x do pulmão para diagnóstico da COVID-19 é uma alternativa para situações em que a quantidade de testes é insuficiente ou inacessível, mas ainda é necessário a presença de um especialista para realizar esses diagnósticos, resultando em um outro problema. O uso de Redes Neurais Convolucionais é um aliada, e já vem sendo utilizadas para diversas tarefas de classificação e detecção. Neste trabalho foram utilizadas as arquiteturas VGG, Xception e ResNet para detectar COVID-19 e pneumonia em imagens de raio-x, atingindo resultados 93% de Acurácia com a Xception e 95% com as demais, além de 100% de Sensibilidade com as redes ReNet e 100% de Precisão com a VGG16.

Palavras-chaves: Deep Learning; Redes Neurais Convolucionais; COVID-19; Radiografia.

Abstract

COVID-19 is a disease caused by the SARS-CoV-2 coronavirus that may cause acute respiratory syndrome and death. Due to easy contamination it has spread all over the world, resulting in a serious pandemic. To reduce contamination and consequently severe cases it is necessary that the contamination be contained, and then, the diagnostics have to be fast and accurate, which is difficult in many places. The use of lungs x-ray images for for diagnosing COVID-19 is an alternative when the number of tests is not enough or inaccessible, however, the presence of specialists is still necessary to do these diagnoses, resulting in another problem. Convolutional Neural Networks employment it is an ally, they have been used to different classification and detection tasks. In this work, VGG, Xception and ResNet architectures were used to detect COVID-19 and pneumonia in x-ray images, reaching 93% Accuracy with Xception and 95% with the other ones, as well as 100% Sensitivity with ReNet networks and 100% Accuracy with VGG16.

Keywords: Deep Learning; Convolutional Neural Networks; COVID-19; Radiography.

Lista de ilustrações

Figura 1 – Radiografias (A) Normal (B) COVID-19	15
Figura 2 – Aprendizado de Máquina x Aprendizado Profundo	16
Figura 3 – Rede Neural Convolutacional	17
Figura 4 – Aprendizado por Transferência	18
Figura 5 – Arquitetura da VGG16 e VGG19	19
Figura 6 – Arquitetura da Xception	20
Figura 7 – Convolução Residual	21
Figura 8 – <i>Random Forest</i>	22
Figura 9 – Metodologia Proposta	23
Figura 10 – Amostras de COVID-19 (a), (b), (c) e (d) classificadas corretamente pelas arquiteturas.	28
Figura 11 – Amostras classificadas incorretamente.	29

Lista de tabelas

Tabela 1 – Configuração GridSearchCV	24
Tabela 2 – Resultados das Redes Neurais para Classificação de COVID-19	26
Tabela 3 – Resultados das Redes Neurais para Classificação de Pneumonia Viral	26
Tabela 4 – Resultados das Redes Neurais para Classificação de pacientes saudáveis	27
Tabela 5 – Comparação com trabalhos relacionados	29

Sumário

1	INTRODUÇÃO	9
1.1	Trabalhos Relacionados	10
1.2	Objetivos	11
1.2.1	Objetivo geral	11
1.2.2	Objetivos específicos	11
1.3	Organização do trabalho	11
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	Infecções por coronavirus	13
2.1.1	Surtos de CoVs	13
2.2	Imagens de Raio-X	14
2.3	Aprendizado Profundo	16
2.4	Redes Neurais Convolucionais	17
2.4.1	Aprendizado por transferência	17
2.4.2	VGG	19
2.4.3	Xception	19
2.4.4	Resnet	20
2.5	<i>Random Forest</i>	21
3	METODOLOGIA PROPOSTA	23
3.1	Aquisição das Imagens	23
3.2	Extração de Características	23
3.3	Classificação	24
3.4	Avaliação	24
4	RESULTADOS	26
5	CONCLUSÃO	31
	REFERÊNCIAS	32

1 Introdução

A COVID-19 causada pelo novo coronavírus SARS-CoV-2 é uma doença caracterizada por causar síndrome respiratória aguda que pode levar à morte. A doença é transmitida por via aérea (tosse ou espirro), por contato direto com superfície contaminada e por saliva (SAÚDE, 2021). Por ser de fácil contaminação, o número de casos rapidamente cresceu na China e posteriormente no mundo todo, alcançando o estágio de pandemia de acordo com a Organização Mundial de Saúde, tendo como consequência o colapso de sistemas de saúde por superlotação, falta de insumos, equipamentos e até mesmo equipes médicas. Desde a identificação do novo coronavírus em Wuhan na China até atualmente foram 219.456.675 casos confirmados e 4.549.975 óbitos no mundo todo, no Brasil, segundo país com maior número de casos, são 20.928.008 casos confirmados e 584.421 óbitos (TRADINGVIEW, 2021).

De acordo com a Organização Mundial de Saúde, aproximadamente 80% dos pacientes com COVID-19 podem não apresentar sintomas ou apresentar poucos sintomas e cerca 20% dos casos diagnosticados necessitam de atendimento hospitalar por conta do quadro respiratório (falta de ar ou dificuldade para respirar), dentre esses casos aproximadamente 5% tornam-se graves e podem necessitar de suporte ventilatório (SAÚDE, 2021). Para evitar a rápida disseminação do vírus e consequentemente casos agravados e óbitos, é necessário que a pessoa contaminada fique isolada, isso requer testes diagnósticos em larga escala para que o máximo de pessoas possam evitar a contaminação de outras. O diagnóstico é feito por meios dos testes de RT-PCR (reação em cadeia da polimerase com transcrição reversa) e a Sorologia (IgA, IgM e IgG) para identificação de anticorpos (LIMA et al., 2020a). O problema surge quando o número de pessoas para serem testadas é maior que o número de testes disponíveis, necessitando que haja uma forma de priorizar indivíduos que serão testados primeiro e não alcançando o objetivo de diagnosticar para tratar mais o cedo possível. Além disso, existe também o fator de espera do resultado (podendo levar até dias para o recebimento) e o próprio desempenho dos testes, sendo sujeito a erros.

Uma forma de contornar esses problemas relacionados à testagem é utilizar de outros mecanismos que podem ser mais rápidos e mais específicos, como por exemplo a utilização de imagens do pulmão obtidas por meio de radiografias ou tomografia computadorizada que podem apresentar maior sensibilidade nos resultados em alguns casos (AI et al., 2020). Em contra partida, é necessário que haja certa expertise na análise dessas imagens, o que pode ser dificultado por alguns motivos como por exemplo a falta de experiência com o diagnóstico, considerando que é uma doença relativamente nova, e a grande quantidade de imagens para serem analisadas em pouco tempo. Diante disso, muitos trabalhos tem

desenvolvido metodologias utilizando *deep learning* para detecção automática de Covid-19 em imagens de radiologia e tomografia computadorizada.

1.1 Trabalhos Relacionados

No trabalho de [Wang et al. \(2020\)](#) foi apresentada a COVID-Net, uma arquitetura de rede neural convolucional profunda adaptada para fazer detecção de casos de COVID-19 utilizando imagens de Raio-x de tórax e também imagens de tomografia computadorizada. Ela é capaz de fazer três tipos de predição: a) sem infecção (normal), b) infecção não COVID (ex. viral, bacterial, etc.), e c) infecção COVID-19. Também é apresentado neste trabalho o COVIDx, que é um conjunto de dados composto por 13.975 imagens em 13.870 casos de pacientes, com o maior número de casos positivos para a COVID-19. A COVID-Net é um dos primeiros projetos de rede de código aberto e tanto ela como o COVIDx estão disponíveis para o público geral.

No estudo de [Apostolopoulos e Mpesiana \(2020\)](#) o objetivo era avaliar o desempenho de arquiteturas de redes neurais convolucionais de última geração (VGG19, MobileNet v2, Inception, Xception e Inception ResNet v2) propostas nos últimos anos para classificação de imagens médicas. Foi adotado o procedimento denominado *Transfer Learning* que fez possível a detecção de várias anormalidades em pequenos conjuntos de dados de imagens médicas e consequentemente produzindo resultados, muitas vezes, notáveis. O conjunto de dados utilizado para a detecção de COVID-19 é composto por imagens de raio-x de pacientes com pneumonia bacteriana comum, COVID-19 e sem doença (normal).

Em [Attar \(2020\)](#) foi desenvolvido um modelo para detecção de COVID-19 que combina a Xception e a ResNet50V2 com o objetivo de obter uma melhor acurácia. As redes neurais trabalham em paralelo para extrair características, após a extração essas características são concatenadas para no final classificarem as imagens entre normal, COVID-19 ou pneumonia.

[Zhang et al. \(2020\)](#) realiza a classificação de COVID-19 por meio da análise de amostras saudáveis (sem doença) e a partir da detecção de anormalidades as classifica como COVID-19 utilizando a arquitetura proposta. O modelo é composto por 3 estruturas, chamadas de "backbone network", "classification head", e "anomaly detection head", quando uma imagem de raio-x é recebida ela passa pela "backbone network" onde são extraídas as características de alto nível que logo depois são repassadas para a "classification head" e "anomaly detection head" que por sua vez retornam scores utilizados na classificação final (normal ou COVID-19).

[Narin et al. \(2020\)](#) e [Sethy e Behera \(2020\)](#) apresentam propostas similares, a primeira utilizou os modelos ResNet50, ResNet101, ResNet152, InceptionV3 e Inception-ResNetV2 (pré treinados) para detectar a COVID-19 em imagens de raio-x, utilizando

Transfer Learning e um conjunto de dados dividido em 3 outros sub conjuntos (COVID-19 e normal (saudável), COVID-19 e pneumonia viral, COVID-19 e pneumonia bacteriana). A segunda utilizou 11 modelos para extração de características e com a classificação feita por SVM (Support Vector Machine).

Junior et al. (2021) utilizou VGG19, Inception-v3, e ResNet50 para extração de características e o XGBoost aprimorado para classificar pacientes com COVID-19 através de imagens de raio-x alcançando um resultado de 98,71% de acurácia, 98.89% de precisão, 99.63% de sensibilidade, e 99.25% de F1-score.

1.2 Objetivos

1.2.1 Objetivo geral

Propor uma metodologia para reconhecimento de COVID-19 e pneumonia viral em imagens de raio-x e contribuir com resultados satisfatórios na área de aprendizado profundo.

1.2.2 Objetivos específicos

- Obter um conjunto de dados satisfatório para o desenvolvimento da metodologia proposta;
- Pesquisar, fazer um levantamento, aplicar e desenvolver técnicas de aprendizado profundo;
- Avaliar os resultados obtidos levando em consideração as diferentes abordagens utilizadas em outros trabalhos.

1.3 Organização do trabalho

Além deste capítulo introdutório, esta monografia contém outros quatro capítulos.

No Capítulo 2, será apresentada a fundamentação teórica necessária para compreensão do trabalho. Apresentação sobre os conceitos de Aprendizagem profunda, do inglês *deep learning*, o panorama sobre a COVID e também as ferramentas utilizadas no trabalho.

No Capítulo 3, a metodologia proposta no trabalho será demonstrada por meio de um experimento utilizando diversas arquiteturas de redes neurais.

No Capítulo 4, serão mostrados os resultados do estudo de caso de acordo com as métricas escolhidas para validação.

Por último, no Capítulo 5, serão feitas conclusões acerca desta monografia, assim como sugestões para trabalhos futuros.

2 Fundamentação teórica

Este capítulo apresenta a fundamentação teórica com os principais métodos e tecnologias utilizados bem como a contextualização do cenário da COVID-19. Conceitos de infecções SARS, deep learning, transfer learning e as arquiteturas utilizadas também serão fundamentados.

2.1 Infecções por coronavirus

Os coronavirus (CoVs) são um conjunto de vírus que pertencem à família *Coronaviridae* e que são considerados responsáveis por causar diversas doenças respiratórias, geralmente, resfriados comuns (LIMA et al., 2020a). Esse grupo de vírus possui várias espécies que afetam animais, até 2019 eram conhecidas apenas seis espécies de coronavirus causadores de doenças em humanos, que na maioria dos casos, não são letais (LIMA et al., 2020b).

Dentre as seis espécies de coronavirus que acometem humanos 3 são mais sérias: *severe acute respiratory syndrome coronavirus* (SARS-CoV), a *Middle East respiratory syndrome coronavirus* (MERS-CoV) e a última descoberta intitulada de SARS-CoV-2 pela sua grande similaridade com a SARS-CoV. Essas três espécies estão associadas à quadros respiratórios graves que podem levar à óbito, esses casos de infecções grave são causados por patógenos zoonóticos, ou seja, são transmitidos para os seres humanos através de animais (LIMA et al., 2020b).

2.1.1 Surto de CoVs

O encontro entre coronavirus e humanos foi marcado por episódios de surtos ao redor do mundo. O primeiro foi causado pelo SARS-CoV (síndrome respiratória aguda grave) em 2003 na China. Caracterizado por causar sintomas comuns de outras infecções virais, como febre, dor de cabeça e muscular, a doença é transmitida de pessoa para pessoa através de contato próximo. Foram 8.096 casos espalhados por 29 países e com 774 óbitos, tendo uma letalidade de 9,5% (LIMA et al., 2020b).

O outro surto teve origem no Oriente Médio, especificamente na Arábia Saudita, no ano de 2012, o agente responsável foi o MERSCoV (síndrome respiratória do oriente médio). Foram 2.494 casos em 27 países (incluindo França, Alemanha, Itália, Tunísia e Reino Unido) e 858 óbitos, tendo uma letalidade de 34% . Houve também um pequeno surto de MERSCoV na Coreia do Sul, em que um sul-coreano fora infectado no Oriente

Médio e ao retornar à Coreia do Sul contaminou outras pessoas. Na ocasião foram mais de 180 casos e 36 óbitos ([LIMA et al., 2020b](#)).

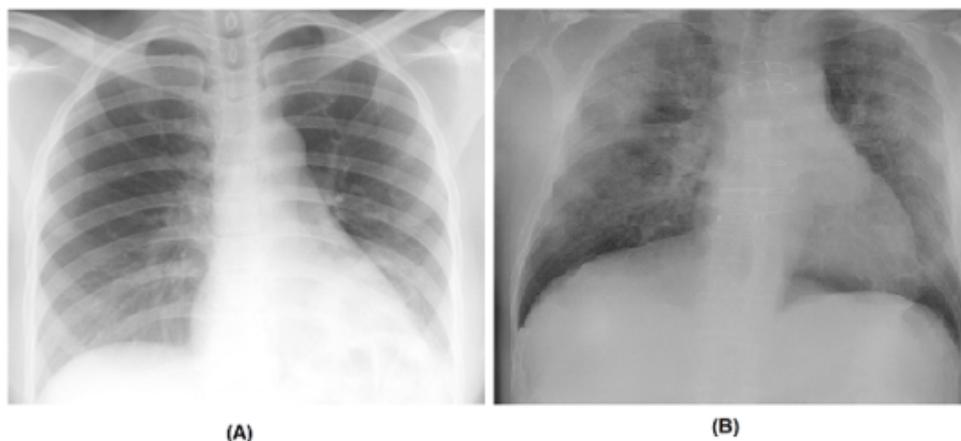
Em dezembro de 2019 surgiram casos de pneumonia de causa desconhecida na cidade de Wuhan, China. Os casos se multiplicaram rapidamente para cidades vizinhas e outros países, descobriu-se que se tratava de um novo surto de coronavírus causado pelo então intitulado pela Organização Mundial da Saúde (OMS) SARS-CoV-2 e a doença associada à ele foi denominada de COVID-19. Em março de 2020 foi declarado que o mundo estava passando por uma pandemia do COVID-19, que atualmente ainda continua ([LIMA et al., 2020b](#)). Até setembro de 2021, no mundo todo, foram 120.745.792 casos e 2.671.764 óbitos tendo uma letalidade bem variada de país para país ([MSDMANUALS, 2021](#)).

2.2 Imagens de Raio-X

A radiografia, também chamada de Raio-X é um exame de imagem não invasivo muito utilizado para visualizar partes internas do organismo como ossos, tecidos moles e pulmão como pode ser visto na Figura 1. A partir dessas imagens é possível analisar a situação do órgão, fazer diagnósticos e seguir com o tratamento adequado ([VARELA, 2021](#)).

A COVID-19 é uma doença que afeta o trato respiratório, logo, não é incomum utilizar de radiografias para acompanhar a situação e o impacto da doença no paciente a partir da análise da imagens de pulmão. Além desta finalidade, foi descoberto em estudos que os pacientes infectados pela COVID-19 apresentam anormalidades em exames de radiografia, sugerindo então, que esses exames possam ser utilizados como forma de triagem e também como uma ferramenta primária para o rastreamento de COVID-19 em áreas epidêmicas ([AI et al., 2020](#)).

Figura 1 – Radiografias (A) Normal (B) COVID-19



Fonte: (WANG et al., 2020)

Embora grande parte da discussão recente tenha girado em torno de imagens de tomografia computadorizada (devido aos maiores detalhes de imagem), há várias vantagens em utilizar as imagens de raio-X para a triagem de COVID-19 no contexto da pandemia de COVID-19, principalmente em áreas com recursos limitados e áreas afetadas. As vantagens são:

- **Disponibilidade e acessibilidade:** por ser considerado um equipamento clínico padrão na maioria dos sistemas de saúde os exames de radiografia estão altamente disponíveis e acessíveis nos locais clínicos e centros de imagem. Em comparação com os equipamentos para realização de tomografia computadorizada, o raio-x também sai em vantagem por conta dos custos mais baixos nos equipamentos e na manutenção.
- **Portabilidade:** devido a existência de equipamentos de raio-x portáteis, é possível que um exame de imagem possa ser realizado dentro das dependências de isolamento de um paciente por isolado por exemplo, reduzindo significativamente os riscos de contaminação da COVID-19.
- **Triagem rápida:** os exames de raio-x podem ser feitos em paralelo aos testes virais, que levam mais tempo, ajudando assim, a aliviar o grande volume de pacientes onde os sistemas de saúde se encontram sem capacidade ou com baixa capacidade. Essas imagens permitem uma triagem rápida em pacientes com suspeita de COVID-19 e até mesmo ser uma opção para substituir o teste viral quando esse não se encontra disponível (seja por baixos suprimentos ou outros motivos). Ainda neste mesmo raciocínio, também é uma opção eficaz para fazer triagem de pacientes em áreas que começam a atender pacientes suspeitos de COVID-19 apenas quando estes apresentam sintomas mais graves, como desconforto respiratório, uma vez que, nesses

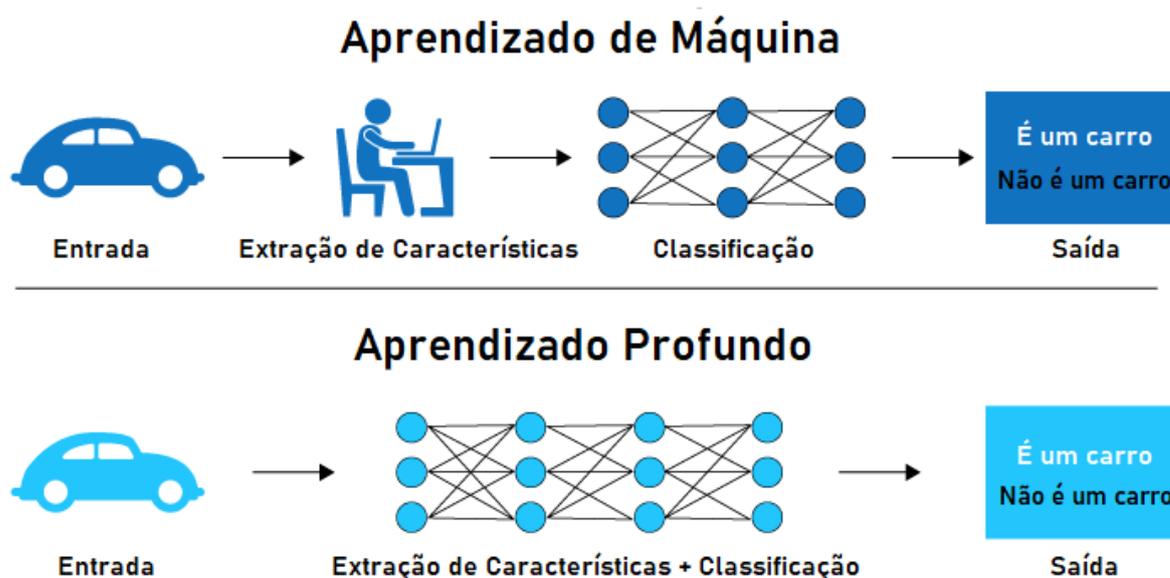
casos, é mais provável observar anormalidades nos exames de imagem (WANG et al., 2020).

Apesar das vantagens apresentadas mostrarem a facilidade e a viabilidade da utilização de exames de imagem para diagnóstico da COVID-19, existe um grande gargalo a ser enfrentado, que é a necessidade de radiologistas especialistas para interpretar corretamente os sinais de COVID-19 nas radiografias, uma vez que os indicadores podem ser sutis. Diante disso, surgem propostas de sistemas de computador auxiliares de diagnósticos, que podem ajudar na interpretação das imagens em termos de velocidade e precisão.

2.3 Aprendizado Profundo

O Aprendizado Profundo é um subcampo da área de machine learning, ou aprendizado de máquina, que faz uso de processamentos em camadas para tentar representar modelos matemáticos complexos (exemplificado na Figura 2). O aprendizado profundo é caracterizado por uma combinação de métodos de aprendizado de máquina focados principalmente na extração automática de características e classificação de imagens, aplicados amplamente em tarefas de detecção de objetos ou de classificação de imagens médicas (APOSTOLOPOULOS; MPESIANA, 2020).

Figura 2 – Aprendizado de Máquina x Aprendizado Profundo



Fonte: Adaptado de Learning (2017)

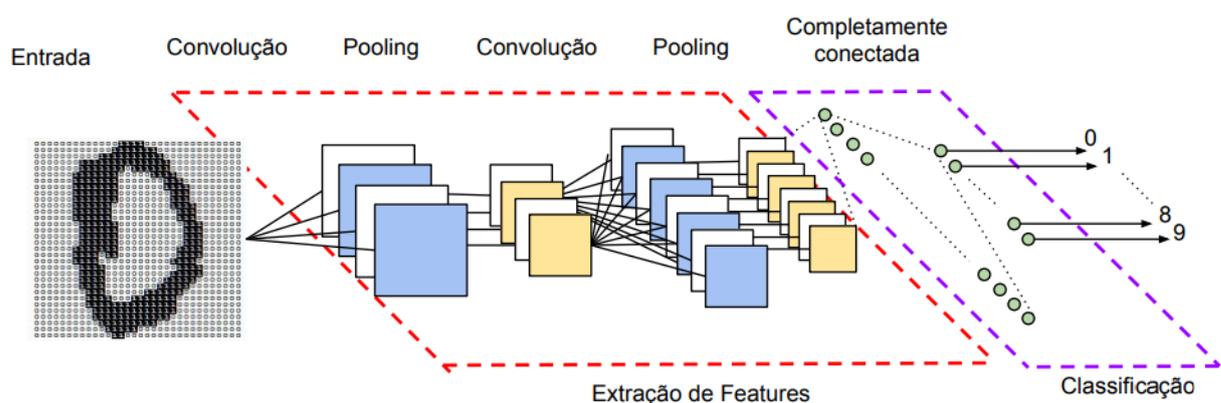
As camadas processam informações não lineares, cada camada envolve uma transformação dos dados em um nível superior e mais abstrato, quanto mais nos aprofundamos na rede, mais informações complexas são aprendidas. Em linhas gerais, pode-se dizer que deep learning é a área de estudo de Redes Neurais Artificiais Convolucionais, que remetem à estrutura e o funcionamento real do cérebro no processamento de dados visuais.

2.4 Redes Neurais Convolucionais

Segundo [Goodfellow, Bengio e Courville \(2016\)](#), Redes Neurais Convolucionais (do inglês *Convolutional Neural Networks*) ou CNN são um tipo especializado de rede neural utilizado para processamento de dados que tem uma topologia conhecida como grade. Como exemplo se tem dados de série temporal, que podem ser considerados como uma grade 1D que coleta amostras em intervalos de tempo regulares, e dados de imagem, podendo ser considerados como uma grade 2D de pixels.

As redes convolucionais tem se mostrado extremamente bem sucedidas em aplicações práticas. As redes tem o nome de convolucional pelo motivo de que elas utilizam de uma operação matemática chamada convolução. A convolução é um tipo especializado de operação linear. As redes convolucionais são, em linhas gerais, redes neurais que usam em pelo menos uma de suas camadas a chamada convolução no lugar da multiplicação geral da matriz (exemplificado na Figura 3).

Figura 3 – Rede Neural Convolucional



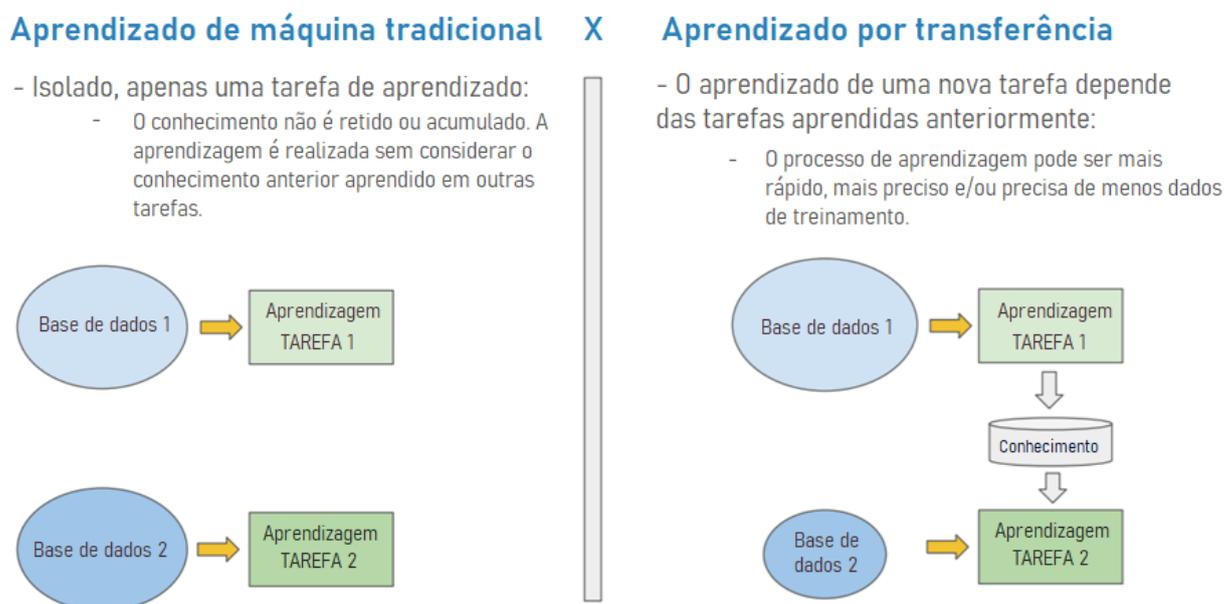
Fonte: (VARGAS et al., 2016)

2.4.1 Aprendizado por transferência

Aprendizado por transferência, em inglês *Transfer learning* é um método de aprendizado de máquina que consiste em aproveitar um modelo treinado desenvolvido

para uma tarefa específica realocando-o, geralmente de forma adaptada, para outra tarefa (representado na Figura 4). Um dos principais casos em que a aprendizagem por transferência é utilizada é para atividades ou tarefas em que não há amostras de treinamento suficientes disponíveis para que se treine um modelo do zero, como por exemplo, a classificação de imagens médicas para doenças raras ou emergentes (APOSTOLOPOULOS; MPESIANA, 2020).

Figura 4 – Aprendizado por Transferência



Fonte: Adaptado de (SARKAR, 2018)

Esta situação é especialmente aplicada nos casos de modelos baseados nas rede neurais profundas, pois tem um grande número de parâmetros para treinar. Ao utilizar a aprendizagem por transferência os parâmetros já começam com valores iniciais bem ajustados, visto que, foram herdados de uma outra tarefa na qual a rede foi treinada. Assim, quando realocados para uma nova tarefa, precisam apenas de pequenos ajustes para adaptar-se completamente.

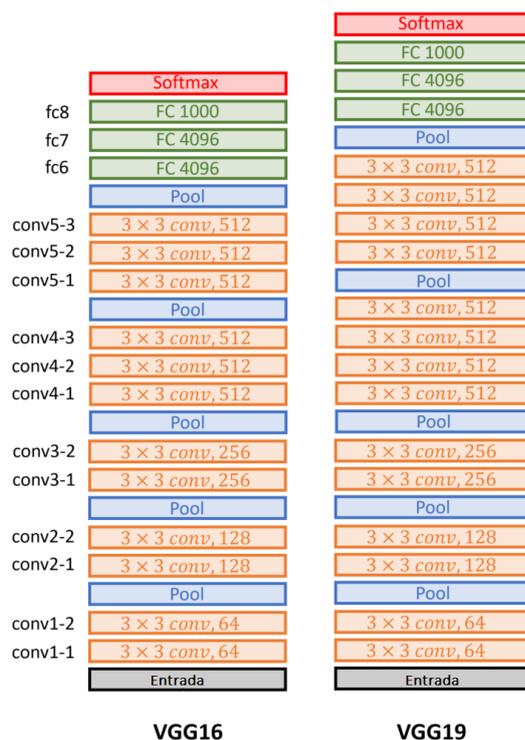
Técnicas de Aprendizado profundo tem se mostrado bastante promissoras na realização de tarefas de análise de imagens radiológicas (CHEN et al., 2019), as redes profundas são arquiteturas poderosas nessa área e estão sendo amplamente utilizadas em aplicações práticas como reconhecimento de padrões e classificação de imagens por exemplo. Nesta seção são descritas as arquiteturas utilizadas para classificar as imagens de COVID-19 deste trabalho.

2.4.2 VGG

As redes neurais de arquitetura VGGNet (SIMONYAN; ZISSERMAN, 2015) são um conjunto de redes da mesma família, que tem como diferenças a sua quantidade de camadas existentes. Duas dessas arquiteturas são as mais conhecidas e utilizadas com maior frequência, elas são a VGG-16 e VGG-19.

O diferencial das redes VGG e a grande contribuição foi o aumento de profundidade das redes possibilitado pelo uso de filtros pequenos (geralmente 3x3) nas camadas de convolução, assim, com camadas mais profundas e maior quantidade de convoluções, as redes VGG apresentam um desempenho muito satisfatório. Esse formato de arquitetura exemplificado na Figura 5 foi inicialmente projetado para o concurso da Imagenet LSVRC-2014 que conquistou o primeiro lugar na tarefa de localização e segundo lugar na tarefa de classificação. A partir disso, essas arquiteturas vem sendo utilizada nas mais diversas aplicações.

Figura 5 – Arquitetura da VGG16 e VGG19



Fonte: Adaptado de (DATAHACKER, 2018)

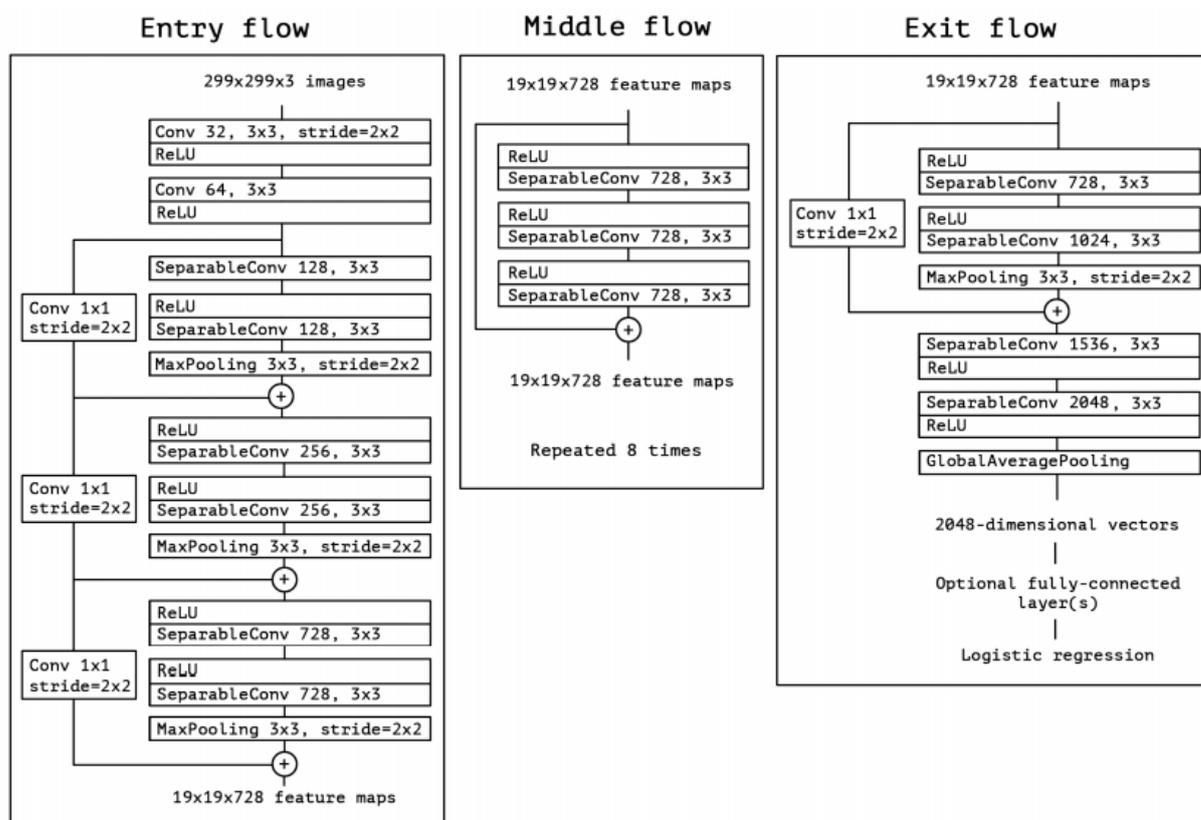
2.4.3 Xception

A Xception é uma arquitetura de rede neural convolucional baseada inteiramente em camadas de convolução separáveis (do inglês *depthwise separable convolution*) que consistem em uma convolução espacial realizada de forma independente sobre cada canal

de uma determinada entrada, que em seguida é realizada uma por convolução 1x1, tendo uma saída resultante em um novo espaço de canal.

A arquitetura da Xception, apresentada na Figura 6, possui 36 camadas convolucionais estruturadas em 14 módulos, todos com conexões residuais lineares ao seu redor, exceto o primeiro e o último módulos e que formam a base de extração de características da rede (CHOLLE, 2017).

Figura 6 – Arquitetura da Xception



Fonte: (CHOLLE, 2017)

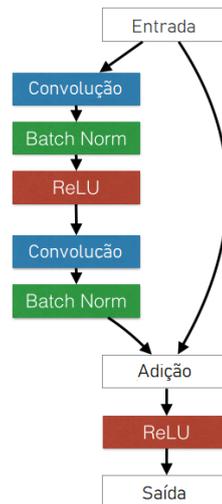
2.4.4 Resnet

As Redes Neurais Convolucionais Residuais, chamadas de ResNet surgiram com a ideia de possibilitar o desenvolvimento de redes neurais com profundidade maior do que CNNs tradicionais. Essas redes foram utilizadas nas competições Imagenet LSVRC-2015 e COCO 2015 (HE et al., 2015).

O aprendizado residual ilustrado na Figura 7, no qual as camadas de uma determinada rede tem de aprender resíduos adicionais em relação ao conteúdo de entrada da rede, é a contribuição da Rede ResNet, ela é dada como uma solução para o problema de degradação na acurácia do treino (HE et al., 2015) causada pelo aumento de camadas,

que até então era o recurso utilizado para aumentar a capacidade de generalização e aprendizagem de uma rede neural convolucional.

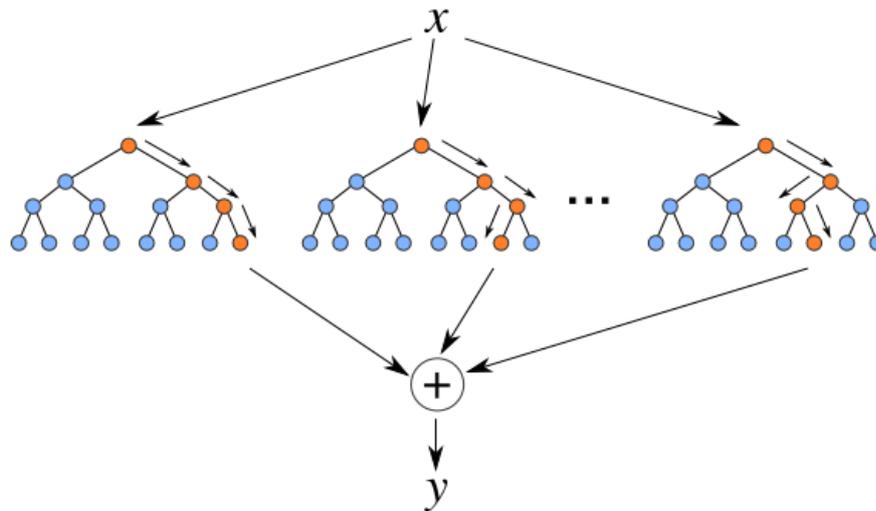
Figura 7 – Convolução Residual



Fonte: Adaptado de (GROSS; WILBER, 2016)

2.5 *Random Forest*

O algoritmo *Random Forest* é um tipo de *ensemble learning* que é um método que gera muitos classificadores e os combina junto com certa quantidade de aleatoriedade para obter o seu resultado. Este algoritmo funciona fazendo uma construção com um conjunto de árvores de decisão na etapa de treinamento e na etapa de predição, e retorna como resultado final a média do resultado de múltiplas árvores, como pode ser observado na Figura 8 tendo como objetivo apresentar resultados mais precisos do que uma árvore de decisão comum (JúNIOR, 2018).

Figura 8 – *Random Forest*

Fonte: (BAIA, 2016)

O Random Forest possui aplicações em problemas de regressão e classificação. No caso da regressão, o algoritmo utiliza como predição a média entre os valores preditos em cada árvore, e na classificação, o algoritmo realiza um sistema de votação entre as árvores, ou seja, a classe que recebe o maior número de votos se torna o valor predito pelo modelo.

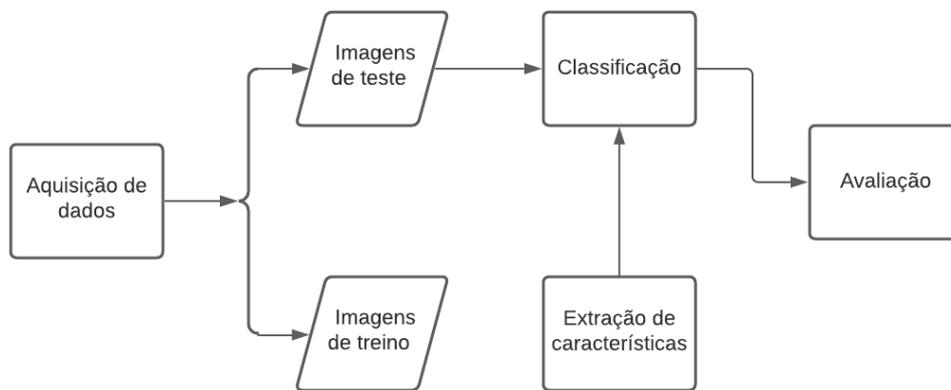
O algoritmo aprende utilizando a metodologia CART (*Classification And Regression Trees*), que é um método em que divisões binárias particionam recursivamente a árvore em nós terminais homogêneos ou quase homogêneos. Uma boa divisão binária empurra os dados de um nó da árvore pai para seus dois nós filhos, de forma que a homogeneidade resultante nos nós filhos seja melhorada a partir do nó pai. Esse algoritmo é geralmente uma coleção de centenas a milhares de árvores, na qual cada árvore é cultivada utilizando uma amostra *bootstrap* dos dados originais (NGUYEN et al., 2013).

As árvores aleatórias se diferenciam das do CART pois são cultivadas de forma não determinística, usando um procedimento de randomização de dois estágios. Além da randomização introduzida pelo crescimento da árvore com uma amostra de *bootstrap* dos dados originais, uma segunda camada de randomização é introduzida no nível do nó durante o crescimento da árvore. Em vez de dividir um nó de árvore utilizando todas as variáveis, o algoritmo seleciona em cada nó de cada árvore, um subconjunto aleatório de variáveis, e apenas essas variáveis são utilizadas como candidatas para encontrar a melhor divisão para o nó. O objetivo dessa randomização em duas etapas é decorrelacionar as árvores para que o conjunto da floresta tenha baixa variância (NGUYEN et al., 2013).

3 Metodologia Proposta

A metodologia proposta para este trabalho é composta por 3 etapas: aquisição de imagens, extração de características, classificação e avaliação dos resultados. Um resumo deste processo pode ser observado na Figura 9. As etapas citadas serão descritas nas seções a seguir.

Figura 9 – Metodologia Proposta



Fonte: Elaborada pela autora

3.1 Aquisição das Imagens

Para este trabalho foi utilizada a base chamada COVIDX (WANG et al., 2020), que foi construída a partir de um compilado de várias outras bases resultando em um total de 13.975 imagens de raio-x oriunda de 13.870 pacientes. Essa base de dados está disponível para o público em geral e é considerada uma das maiores bases de COVID-19.

Na construção da base de dados foram coletadas e modificadas 5 outras base de dados escolhidas pelo fato de que todos os cinco conjuntos de dados são de código aberto e totalmente acessíveis à comunidade de pesquisa e ao público em geral. A base contém 358 imagens (raio-x) de 266 pacientes com COVID-19, um número significativamente maior de imagens classificadas como normal (sem COVID-19 ou pneumonia) de 8.066 imagens e 5.538 amostras de pacientes com pneumonia não oriunda de COVID-19.

3.2 Extração de Características

Para este trabalho foram escolhidas redes neurais profundas VGG, Xception e Resnet. As redes escolhidas são carregadas já pré treinada e com apenas os pesos ou seja,

sem o classificador. A rede é configurada da seguinte maneira: o parâmetro "pooling" de todas as redes foi configurado como "max" e os pesos pré-carregados utilizados foram da imagenet.

As imagens são carregadas, pré-processadas com o método próprio de cada arquitetura, os pesos pré treinados são carregados sem o topo da rede neural e quando chamada a função "predict" é obtido como retorno um vetor de características da última camada (anterior ao classificador) dessa rede. Por fim, esse vetor de características passa pela função de pooling escolhida.

3.3 Classificação

Para a etapa de classificação foi utilizado o algoritmo *Random Forest*, explicado anteriormente na seção 2.5. Foi utilizada uma técnica para selecionar os melhores parâmetros possíveis, que é o GridSearchCV.

A seguinte configuração de parâmetros foi utilizada:

Tabela 1 – Configuração GridSearchCV

Parâmetro	Configuração
max_depth	3 e none
max_features	1 e 3
min_samples_split	2, 3 e 10
criterion	gini e entropy
total arvores	100

Fonte: Elaborada pela autora

3.4 Avaliação

Existem diferentes métricas na literatura que podem ser usadas para avaliar o desempenho de modelos de classificação, como Acurácia, Sensibilidade, Especificidade, Precisão e F1-score.

As métricas são baseadas nas variáveis da matriz de confusão, sendo elas: Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN). Considera-se VP um valor que é classificado como doente e que de fato está doente. Já os VN são aqueles valores não foram classificados como doentes mas o seu valor real é considerado como doente. Os FP são todos aqueles não fazem parte da classe na qual foram classificados ou seja, saudáveis classificados como doentes, e FN aqueles que tem valor como doente mas que foram classificados como saudáveis.

Ao total foram utilizadas 4 métricas, Precisão, Sensibilidade, Acurácia e F1-score. Pode-se considerar a Sensibilidade como a proporção de VP, ou seja, a capacidade do sistema em prever corretamente a condição para casos que realmente a têm. A Sensibilidade é calculada pela seguinte fórmula:

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (3.1)$$

Uma precisão alta significa que foi obtido uma grande quantidade de valores da classe desejada, esta métrica é definida pela razão entre a quantidade de exemplos classificados corretamente como positivos e o total de exemplos classificados como positivos, como pode ser visto na fórmula abaixo:

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3.2)$$

A métrica Acurácia está relacionada à quantos de amostras foram de fato classificadas corretamente, independente da classe, ela é dada pela fórmula abaixo:

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.3)$$

E por último a F1-Score que leva em consideração tanto a precisão quanto a sensibilidade. Esta métrica é definida pela média harmônica entre as duas como podemos observar na seguinte fórmula:

$$F1 = \frac{2 * \text{precisão} * \text{sensibilidade}}{\text{precisão} + \text{sensibilidade}} \quad (3.4)$$

Essas foram as métricas utilizadas para avaliar os resultados das arquiteturas de redes neurais escolhidas e no capítulo seguinte são mostrados os resultados utilizando-as aplicadas à base de dados escolhida também citada anteriormente.

4 Resultados

Neste capítulo são apresentados os resultados obtidos de acordo com a metodologia que foi proposta anteriormente. O principal objetivo é relacionar as arquiteturas escolhidas com o desempenho mostrado na classificação do COVID-19 e doenças respiratórias nas imagens de radiografia. A avaliação das redes neurais, como foi mostrado no capítulo anterior, foi feita através das métricas Acurácia, Sensibilidade, Especificidade, Precisão e F1-score.

A base foi dividida em dois conjuntos aleatórios de dados: o conjunto de treinamento, que consiste em 80% do total de imagens e o conjunto de teste que é formado pelos 20% das imagens restantes. Esses dois conjuntos passam por um processamento prévio. Em cada Keras application é esperado um tipo específico de pré-processamento de entrada, desta forma, foram utilizados os métodos de pré-processamento da própria arquitetura escolhida. As Tabelas 2, 3 e 4 abaixo mostram o apanhado dos resultados das redes seguindo a metodologia proposta.

Tabela 2 – Resultados das Redes Neurais para Classificação de COVID-19

Arquitetura	Precisão	Sensibilidade	F1-score	Acurácia
Xception	97.0%	96.0%	96.0%	93.0%
VGG16	100%	97.0%	98.0%	95.0%
VGG19	98.0%	99.0%	98.0%	95.0%
ResNet50	98.0%	100%	99.0%	95.0%
ResNet101	97.0%	100%	98.0%	95.0%

Fonte: Elaborada pela autora

Tabela 3 – Resultados das Redes Neurais para Classificação de Pneumonia Viral

Arquitetura	Precisão	Sensibilidade	F1-score	Acurácia
Xception	92.0%	89.0%	91.0%	93.0%
VGG16	93.0%	93.0%	93.0%	95.0%
VGG19	94.0%	92.0%	93.0%	95.0%
ResNet50	95.0%	92.0%	93.0%	95.0%
ResNet101	96.0%	92.0%	94.0%	95.0%

Fonte: Elaborada pela autora

Tabela 4 – Resultados das Redes Neurais para Classificação de pacientes saudáveis

Arquitetura	Precisão	Sensibilidade	F1-score	Acurácia
Xception	91.0%	94.0%	93.0%	93.0%
VGG16	93.0%	95.0%	94.0%	95.0%
VGG19	93.0%	94.0%	93.0%	95.0%
ResNet50	92.0%	94.0%	93.0%	95.0%
ResNet101	92.0%	94.0%	93.0%	95.0%

Fonte: Elaborada pela autora

Como pode ser observado nas Tabelas 2 e 3 os valores de Precisão e Sensibilidade, tanto na classificação de imagens de COVID-19 quanto na classificação de imagens de pneumonia viral, mostram-se consideravelmente elevados, o que pode-se concluir que o método proposto foi bastante satisfatório para classificação de COVID-19 e Pneumonia viral.

As arquiteturas que apresentaram melhor desempenho em termos de Sensibilidade foram a ResNet50 e a ResNet101, que alcançaram a sensibilidade de 100%, ou seja, todos os casos de COVID-19 foram classificados corretamente. Este ponto é muito importante, pois, quanto mais casos detectados maior a capacidade de conter a disseminação do vírus. Em segundo lugar a VGG19 também mostra um desempenho satisfatório ainda que menor que as redes residuais.

A rede neural que obteve o pior resultado em relação às outras tanto na detecção de COVID-19, como de pneumonia viral foi a Xception, alcançando a Precisão de 0.93% e Sensibilidade de 0.96% para COVID-19 e 0.91% para pneumonia viral.

Apesar dos bons resultados de classificação de COVID-19 em todas as arquiteturas é importante ressaltar que deve-se considerar a quantidade de amostras de COVID-19 contidas na base de dados, que embora seja uma das maiores da atualidade ainda contém poucas amostras em relação às imagens de pacientes saudáveis e com pneumonia viral não COVID-19, o que pode ocasionar de alguma forma diferenças nos resultados obtidos.

Abaixo são exemplificados alguns casos de erro e acerto na classificação. As imagens são categorizadas em três classes: amostras de pacientes com COVID-19, pneumonia viral de saudáveis (normal). Na Figura 10 estão exemplificados os casos em que a classificação foi feita corretamente, ou seja, a imagem foi classificada de acordo com a classe a qual pertence. Isso pode ser atribuído ao fato de que as imagens apresentam casos claros de características que definem a COVID-19 na imagem de raio-x (como manchas na região dos pulmões) e também a clareza e qualidade das imagens analisadas.

Já na figura 11 há alguns casos de erros, ou seja, as imagens foram classificadas em classes diferentes das quais pertencem. Assim como em casos de acerto há também alguns

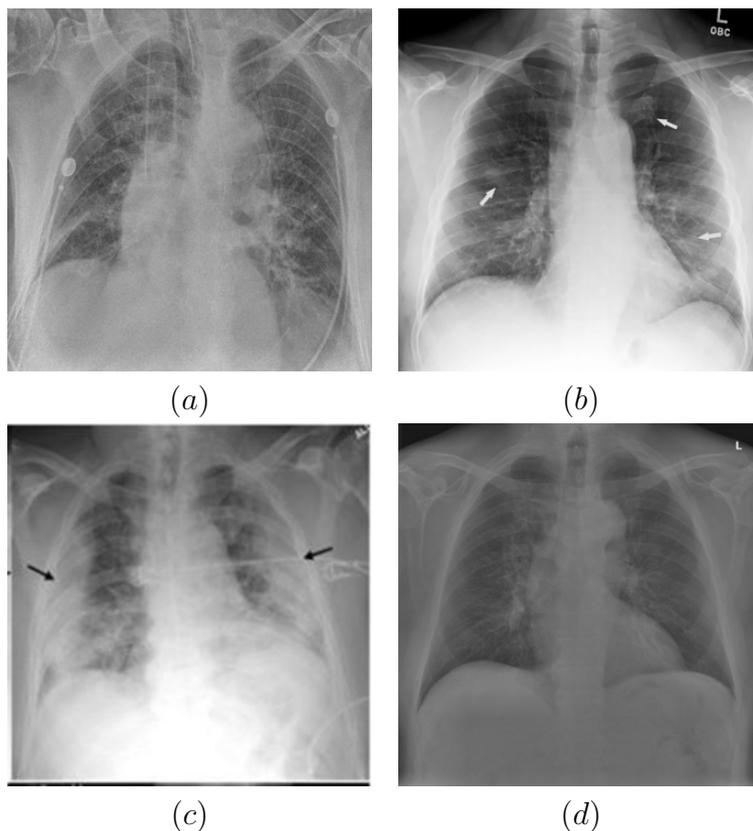


Figura 10 – Amostras de COVID-19 (a), (b), (c) e (d) classificadas corretamente pelas arquiteturas.

fatores que podem contribuir para que a classificação ocorra de maneira errada, como pacientes que de fato estavam com COVID-19 mas não apresentaram sinais claramente visíveis em seus exames de raio-x, que pode ser o caso em a), amostra que foi classificada em três arquiteturas como normal quando na verdade é COVID-19. Outro fator que pode ser atribuído é a qualidade das imagens, formatos e posições em que o exame de raio-x foi feito, pois não há um padrão nas amostras de raio-x no conjunto de dados utilizado, tendo em vista que a base foi construída com a junção de 5 bases (citado anteriormente). Por fim, há a semelhança das lesões entre a COVID-19 e a pneumonia viral, que tiveram a classificação trocada em b) e c) respectivamente.

O COVID-19 afetou países de todo mundo, o que contribuiu para que uma gama de pesquisas e trabalhos fossem desenvolvidos pelos mais diversos especialistas. Na área do aprendizado profundo não foi diferente, na Tabela 5 pode-se observar a comparação de alguns desses trabalhos que utilizam de imagens de raio-x para detecção de COVID-19 juntamente com o trabalho proposto.

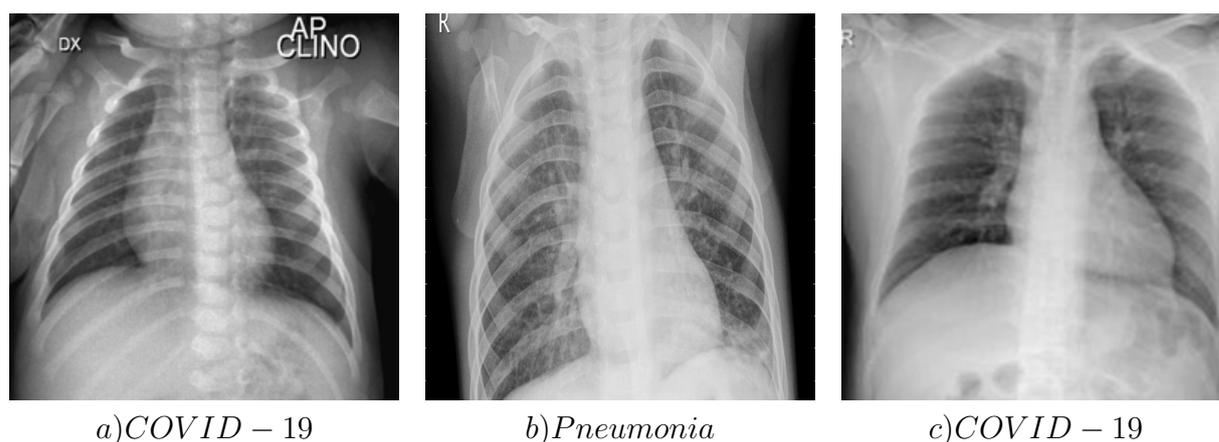


Figura 11 – Amostras classificadas incorretamente.

Tabela 5 – Comparação com trabalhos relacionados

Trabalho	Arquitetura	Precisão	Sensibilidade	F1-score	Acurácia
(APOSTOLOPOULOS; MPESIANA, 2020)	VGG19	-	92.85%	-	98.75%
(ATTAR, 2020)	Xception e ResNet50V2	35.27%	80.53%	-	99.50%
(ZHANG et al., 2020)	ResNet	-	-	-	96.0%
(WANG et al., 2020)	VGG19	-	98.00%	-	-
	ResNet-50				
	COVID-Net		91.0%		93.3%
(NARIN et al., 2020)	ResNet50	-	-	-	98.0%
(SETHY; BEHERA, 2020)	ResNet50 e SVM	-	-	91.41%	95.38%
(JUNIOR et al., 2021)	Vgg19	98.89%	99.63%	99.25%	98.71%
	Inception-v3	98.29%	98.81%	98.54%	97.48
	ResNet50	98.80%	99.48%	99.14%	98.51%
Este trabalho	Xception	97.0%	96.0%	96.0%	93.0%
	VGG16	100%	97.0%	98.0%	95.0%
	VGG19	98.0%	99.0%	98.0%	95.0%
	ResNet50	98.0%	100%	99.0%	95.0%
	ResNet101	97.0%	100%	98.0%	95.0%

Fonte: Elaborada pela autora

[Apostolopoulos e Mpesiana \(2020\)](#) utilizaram um conjunto de dados com 224 imagens de COVID-19 e 1024 imagens de pneumonia e de pacientes saudáveis. Foi obtido um resultado de 98,75% em acurácia e 92,85% em sensibilidade através de arquiteturas profundas e aprendizado por transferência para detectar COVID-19. O método de [Attar \(2020\)](#) tinha como objetivo selecionar as classes normal e com pneumonia, com isso foi obtido o resultado de precisão de 99,50%. Para a classe de COVID-19 foram 35,27% de precisão e 80,53% de sensibilidade. Em [Zhang et al. \(2020\)](#) o resultado alcançado

foi de 96% de precisão utilizando um conjunto de dados composto por 100 imagens de COVID-19 e 1341 de casos saudáveis. Wang et al. (2020) conseguiu um resultado de 93,3% de acurácia e 91,0% de sensibilidade com a COVID-Net e um conjunto de dados bem maior em comparação aos outros composto por 358 de imagens de pacientes com COVID-19, 5.538 de pneumonia e 8.066 de pacientes normais. Narin et al. (2020) utilizou um conjunto de dados pequeno, com apenas 50 imagens de COVID-19 e 50 imagens de pacientes de classe normal, atingindo 98% de precisão como resultado. Com a utilização da ResNet50 com o SVM como classificador Sethy e Behera (2020) obteve F1-score de 91.41% e uma precisão de 91,41% e, por fim, Junior et al. (2021) com a extração de características e o classificador XGBoost conseguiu atingir os resultados de 98.71% de acurácia, a precisão de 98.89%, 99.63%, de sensibilidade e F1-score de 99.25%.

Em comparação com todos os trabalhos citados anteriormente, este trabalho teve um resultado satisfatório e dentro das médias de resultados, contudo, ainda é possível melhorá-lo e obter métricas ainda maiores e específicas com a utilização de outras técnicas de aprendizado profundo ou com o desenvolvimento de uma arquitetura, haja vista que o proposto neste trabalho é apenas a utilização de extração de características para a classificação de imagens.

5 Conclusão

A pandemia causada pelo COVID-19 ainda está sem perspectiva de acabar, com o surgimento de variantes mais perigosas e severas urge a necessidade de métodos de diagnóstico que cumpram com as mais diversas necessidades, dentre elas, o baixo custo e a facilidade de acesso.

Este trabalho apresentou o uso de Redes Neurais Convolucionais para a detecção de COVID-19 e pneumonia em imagens de raio-x, sendo elas VGG16 e VGG19, ResNet50 e ResNet101 e a Xception. Foi utilizado a técnica de transferência de aprendizado, extração de características e o *Random Forest* como classificador com uma base de dados de 19.975 imagens, 358 amostras de pacientes com COVID-19, 5.538 amostras com pneumonia e 8.066 imagens de pacientes saudáveis.

Os resultados obtidos indicam sucesso no experimento, visto que, em resumo, obteve-se Precisão, Sensitividade, Acurácia e F1-Score em todas as redes superiores a 90% na classificação de COVID-19. Estes resultados podem ser considerados satisfatórios quando comparados com resultados de outros trabalhos já apresentados na literatura.

A arquitetura que obteve o pior resultado em relação às outras foi a Xception, atingindo a Precisão de 93% e Sensibilidade de 96% para COVID-19 e 0.91% para pneumonia viral. Já a VGG16, e as redes ResNet atingiram os melhores resultados, chegando a 100% de Precisão e 100% de Sensibilidade respectivamente. Como dito anteriormente, é importante destacar a quantidade significativa inferior de imagens de pacientes de COVID-19 disponíveis para estudo, pois um número pequeno de amostras afeta no resultado das redes, mas, não o inviabiliza, principalmente quando o objetivo é detectar para impedir o contato de indivíduos contaminados com indivíduos saudáveis e, conseqüentemente, diminuir a contaminação.

Com esses resultados positivos é possível expandir essa pesquisa para obter resultados ainda melhores com alguns aprimoramentos, por exemplo, a utilização de uma base de dados com maior número de amostras de COVID-19 para melhorar o treinamento das arquiteturas atrelado a novas técnicas de aprendizado profundo presentes na literatura e até mesmo o desenvolvimento de uma arquitetura própria.

Referências

- AI, T. et al. Correlation of chest ct and rt-pcr testing for coronavirus disease 2019 (covid-19) in china. *RSNA Journals*, v. 296, n. 2, ago, 2020. Acesso em: 28 mar. 2021. Citado 2 vezes nas páginas 9 e 14.
- APOSTOLOPOULOS, I. D.; MPESIANA, T. A. Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, v. 43, 2020. Acesso em: 01 abr. 2021. Citado 4 vezes nas páginas 10, 16, 18 e 29.
- ATTAR, M. R. A. *A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2*. [S.l.]: Elsevier, 2020. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352914820302537?via%3Dihub>>. "Acesso em: 18 ago. 2021". Citado 2 vezes nas páginas 10 e 29.
- BAIA, C. *Decision Tree e Random Forest*. 2016. Disponível em: <<http://carlosbaia.com/2016/12/24/decision-tree-e-random-forest/>>. Acesso em: 20 abr. 2021. Citado na página 22.
- CHEN, L. et al. *Self-supervised learning for medical image analysis using image context restoration*. 2019. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1361841518304699>>. "Acesso em: 20 ago. 2021". Citado na página 18.
- CHOLLE, F. *Xception: Deep Learning with Depthwise Separable Convolutions*. [S.l.]: CVPR, 2017. Disponível em: <<https://arxiv.org/pdf/1610.02357.pdf>>. "Acesso em: 15 abr. 2021". Citado na página 20.
- DATAHACKER. *VGG Neural Network*. 2018. Disponível em: <<http://datahacker.rs/deep-learning-vgg-16-vs-vgg-19/>>. Acesso em: 19 ago. 2021. Citado na página 19.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. [S.l.]: MIT Press, 2016. Citado na página 17.
- GROSS, S.; WILBER, M. *Training and investigating Residual Nets*. 2016. Disponível em: <<http://torch.ch/blog/2016/02/04/resnets.html>>. Acesso em: 20 ago. 2021. Citado na página 21.
- HE, K. et al. *Deep Residual Learning for Image Recognition*. [S.l.]: CVPR, 2015. Disponível em: <<https://arxiv.org/pdf/1512.03385.pdf>>. "Acesso em: 15 abr. 2021". Citado na página 20.
- JUNIOR, D. A. et al. *Automatic method for classifying COVID-19 patients based on chest X-ray images, using deep features and PSO-optimized XGBoost*. 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417421008654>>. "Acesso em: 20 ago. 2021". Citado 3 vezes nas páginas 11, 29 e 30.
- JÚNIOR, D. M. *Classificação de Editais Licitação em Areas de Atuação Baseado em Aprendizado Supervisionado*. 2018. Monografia (Bacharel em Ciência da Computação),

UFSC (Universidade Federal de Santa Catarina), Florianópolis, Brazil. Citado na página 21.

LEARNING, X. . M. L. vs D. *Deep Learning*. 2017.

Disponível em: <<https://medium.com/@Say2neeraj/what-is-the-difference-between-machine-learning-and-deep-learning-5795e4415be9>>.

Acesso em: 01 abr. 2021. Citado na página 16.

LIMA, F. L. O. et al. Diagnóstico da covid-19: importância dos testes laboratoriais e dos exames de imagem. *Research, Society and Development*, v. 9, n. 9, ago, 2020. Acesso em: 28 mar. 2021. Citado 2 vezes nas páginas 9 e 13.

LIMA, L. N. G. C. et al. As descobertas genômicas do sars-cov-2 e suas implicações na pandemia de covid-19. *Journal of Health and Biological Sciences*, v. 8, n. 1, 2020. Acesso em: 06 abr. 2021. Citado 2 vezes nas páginas 13 e 14.

MSDMANUALS. *Coronavírus e Síndromes respiratórias agudas (COVID-19, MERS e SARS)*. 2021. Disponível em: <<https://www.msmanuals.com/pt-br/casa/infecç~oes/virus-respiratórios/coronavírus-e-síndromes-respiratórias-agudas-covid-19-mers-e-sars>>. Acesso em: 24 mar. 2021. Citado na página 14.

NARIN, A. et al. *Automatic Detection of Coronavirus Disease (COVID-19) Using X-ray Images and Deep Convolutional Neural Networks*. 2020. Disponível em: <<https://arxiv.org/abs/2003.10849>>. "Acesso em: 19 ago. 2021". Citado 3 vezes nas páginas 10, 29 e 30.

NGUYEN, C. et al. *Random forest classifier combined with feature selection for breast cancer diagnosis and prognostic*. [S.l.]: SciRes, 2013. Disponível em: <https://www.scirp.org/pdf/JBiSE_2013052520594928.pdf>. "Acesso em: 20 abr. 2021". Citado na página 22.

SARKAR, D. D. *Traditional Learning vs Transfer Learning*. 2018. Acesso em: 12 abr. 2021. Citado na página 18.

SAÚDE, M. da. *Sobre a doença*. 2021. Disponível em: <<https://coronavirus.saude.gov.br/sobre-a-doenca>>. Acesso em: 17 mar. 2021. Citado na página 9.

SETHY, P. K.; BEHERA, S. K. *Detection of coronavirus Disease (COVID-19) based on Deep Features*. 2020. Disponível em: <<https://www.preprints.org/manuscript/202003.0300/v1>>. "Acesso em: 19 ago. 2021". Citado 3 vezes nas páginas 10, 29 e 30.

SIMONYAN, K.; ZISSERMAN, A. *Very deep convolutional networks for large-scale image recognition*. [S.l.]: ICLR, 2015. Disponível em: <<https://arxiv.org/abs/1409.1556>>. "Acesso em: 10 abr. 2021". Citado na página 19.

TRADINGVIEW. *Coronavírus (COVID-19) gráficos e estatísticas*. 2021. Disponível em: <<https://br.tradingview.com/covid19/>>. Acesso em: 18 mar. 2021. Citado na página 9.

VARELA. *Raios X (radiografia)*. 2021. Disponível em: <<https://drauziovarella.uol.com.br/ambulatorio/exames/raios-x-radiografia/>>. Acesso em: 25 mar. 2021. Citado na página 14.

VARGAS, A. C. G. et al. *Exemplo de uma rede neural convolucional e suas diferentes camadas*. 2016. Disponível em: <<http://gibis.unifesp.br/sibgrapi16/e proceedings/wuw/7.pdf>>. Acesso em: 10 abr. 2021. Citado na página 17.

WANG, L. et al. *COVID-Net: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images*. 2020. Disponível em: <<https://arxiv.org/abs/2003.09871>>. Acesso em: 05 abr. 2021. Citado 6 vezes nas páginas 10, 15, 16, 23, 29 e 30.

ZHANG, J. et al. *COVID-19 Screening on Chest X-ray Images Using Deep Learning based Anomaly Detection*. 2020. Disponível em: <https://www.researchgate.net/publication/340271344_COVID-19_Screening_on_Chest_X-ray_Images_Using_Deep_Learning_based_Anomaly_Detection>. "Acesso em: 17 ago. 2021". Citado 2 vezes nas páginas 10 e 29.