



•NOVA•
UCSAL

Universidade Católica do Salvador
Bacharelado em Engenharia de Software

Saulo de Andrade Santana

Detecção de Covid-19 em imagens radiológicas torácicas através
da rede neural convolucional (RNC)

Salvador

2020

Saulo de Andrade Santana

**Detecção de Covid-19 em imagens radiológicas
torácicas através da rede neural convolucional (RNC)**

Trabalho de Conclusão de Curso apresentado à Universidade Católica do Salvador como parte dos requisitos necessários para a obtenção do Título de Engenheiro de Software.

Orientador: Prof. Me. André Brasil Vieira Wyzykowski

Universidade Católica do Salvador

Salvador
2020

Saulo de Andrade Santana

Detecção de Covid-19 em imagens radiológicas torácicas através da rede neural convolucional (RNC)

Trabalho de Conclusão de Curso apresentado à Universidade Católica do Salvador como requisito parcial para a obtenção do título de Engenheiro de Software.

Comissão Examinadora

Prof. Me. André Brasil Vieira Wyzykowski
Universidade Católica do Salvador
Orientador

Prof. Me. Arnaldo Bispo de Jesus
Universidade Católica do Salvador

Prof. Me. Fernando Cezar Reis Borges
Universidade Católica do Salvador

Salvador, 28 de janeiro de 2021

Dedico este trabalho a todos aqueles que contribuíram para minha trajetória acadêmica, principalmente aos meus pais, pelos seus esforços e por sempre me incentivarem e apoiarem em todas as minhas decisões.

Agradecimentos

Agradeço primeiramente aos meus pais, por tudo que fizeram para me proporcionar uma educação de qualidade e sempre estarem me apoiando, eles são os meus maiores exemplos de conquista.

Agradeço também a todos os meus professores por me ajudarem a trilhar esse novo caminho, em especial ao coordenador Osvaldo Requião por não me fazer desistir nessa última etapa, e ao professor e meu orientador André Brasil que me encaminhou para as direções certas e por sua dedicação e persistência em me auxiliar nesta jornada que foi o TCC.

Agradeço também a todos os meus colegas e amigos que fiz durante esta formação, pelos trabalhos e estudos em grupos, amizades que levarei para sempre, como Ícaro, Sérgio e principalmente a Rafael Rembrandt, que esteve presente comigo em todas as etapas desta formação e também fora dela. Um agradecimento em especial também para os Obtusos Fardados, meus amigos que considero irmãos sempre presentes em todas as minhas conquistas.

"A verdadeira motivação vem de realização, desenvolvimento pessoal, satisfação no trabalho e reconhecimento."
(Frederick Herzberg)

Resumo

A nova pandemia do Covid-19, o novo coronavírus (SARS-CoV-2), tem causado muitos problemas em diversas áreas da sociedade. Entre esses problemas, destaca-se o alto número de exames feitos, e a falta de exames, principalmente nas pequenas cidades, de forma eficiente. Considerando esta insuficiência de recursos na identificação da Covid-19, o objetivo desse trabalho foi propor uma solução, em um estudo experimental, para viabilizar a detecção do novo vírus utilizando as imagens de exames médicos radiológicas torácicas, que possuem facilitadores em sua realização, como custo e disponibilidade, com ajuda de uma Inteligência Artificial, mais especificamente a Rede Neural Convolucional (RNC), que habitualmente são usados para analisar imagens. O trabalho constou com uma arquitetura própria e um conjunto de 16.500 imagens separadas em 3 classes (Normal, Covid-19 e Pneumonia), e os resultados da RNC foram analisados e se deram sobre a acurácia dos algoritmos da rede em disfunções do reconhecimento de imagem, sendo esta superior a 80%. A técnica mostrou-se promissora no atendimento desta demanda, em um contexto experimental. Portanto, pode ser indicado como instrumento complementar no diagnóstico médico no sistema de saúde pela sua eficácia e efetividade, além dos benefícios e facilidade para a sua implementação, contudo que sejam feitos mais testes, com um conjunto de amplas variáveis.

Palavras-Chave: 1. Covid-19. 2. Imagens Médicas Torácicas. 3. Raio-X Torácico. 4. Rede Neural Convolucional. 5. RNC. 6. Inteligência Artificial.

Abstract

The new Covid-19 pandemic, the new coronavirus (SARS-CoV-2), has caused many problems in several areas of society. Among these problems, the high number of tests carried out, and the lack of tests, especially in small cities, stands out efficiently. Considering this insufficient resource in the identification of Covid-19, the objective of this work was to propose a solution, in an experimental study, to enable the detection of the new virus using the images of chest radiological medical examinations, which have facilitators in their realization, such as cost and availability, with the help of an Artificial Intelligence, more specifically the Convolutional Neural Network (RNC), which they are usually used to analyze images. The work consisted of its own architecture and a set of 16,500 images separated into 3 classes (Normal, Covid-19 and Pneumonia), and the results of the RNC were analyzed and took place on the accuracy of the network algorithms in image recognition disorders, which is higher than 80 %. The technique proved to be promising in meeting this demand, in an experimental context. Therefore, it can be indicated as a complementary instrument in medical diagnosis in the health system for its efficacy and effectiveness, in addition to the benefits and ease for its implementation, however more tests are carried out, with a set of wide variables.

Keywords: 1. Covid-19. 2. Chest Medical images. 3. Chest Ray-X. 4. Convolutional Neural Network. 5. CNN. 6. Artificial Intelligence.

Lista de figuras

Figura 1	– Representação de uma arquitetura MLP. À esquerda estão presentes as entradas, ao centro as duas camadas intermediárias, e nessa rede específica, à direita, 2 saídas.	20
Figura 2	– Representação de uma arquitetura RNC. À esquerda a entrada, seguida de convoluções e <i>max pollings</i> intercalados, por fim ao final da figura, as <i>Dense Layers</i>	21
Figura 3	– Figura explicativa de uma convolução, à esquerda a matriz que será sofrerá a convolução, ao meio o filtro, e à direita o resultado.	22
Figura 4	– Fluxo explicativo do funcionamento dos filtros, à esquerda a imagem de entrada, o caminho superior o filtro que detecta as linhas (bordas) verticais, seguida pelo seu resultado. E o caminho inferior demonstra o filtro para detecção de linha (bordas) horizontais, e o resultado obtido.	23
Figura 5	– Fluxo explicativo do funcionamento dos <i>stride</i> , à esquerda a imagem de entrada, o caminho superior o filtro deslocando-se um passo, com <i>strides = 1</i> . E o caminho inferior demonstra o filtro deslocando-se dois passos com o uso do <i>strides = 2</i>	24
Figura 6	– Representação da convolução <i>Same</i> , no qual a saída sempre será igual a entrada.	25
Figura 7	– Representação da convolução <i>Valid</i> , no qual a saída sempre será menor que sua entrada, à esquerda.	25
Figura 8	– Representação do processo de um <i>Max Polling 2 x 2</i> com <i>2 destrides</i> , assim, dividindo a matriz pela metade.	25
Figura 9	– Representação gráfica da função ReLU	26
Figura 10	– Representação gráfica da função Sigmoid	27
Figura 11	– Comparação entre raio X torácico	36
Figura 12	– Arquitetura da Rede Neural Convolutiva utilizada neste trabalho	37
Figura 13	– Gráfico representativo do <i>loss</i> de treinamento e validação da RNC.	38
Figura 14	– Comparação entre raio X torácico normal	41
Figura 15	– Comparação entre raio X torácico com Covid-19	41
Figura 16	– Comparação entre raio X torácico com Pneumonia	42

Lista de tabelas

Tabela 1 – Tabela com representação das imagens contidas em cada uma das bases de dados utilizadas, separadas por um exemplo de cada classe presente na mesma.	35
Tabela 2 – Acurácia da Rede Neural Convolutacional por classe	40
Tabela 3 – Acurácia da Rede Neural Convolutacional total	42

Lista de Siglas e Abreviaturas

COVID-19	<i>Coronavirus disease 2019</i>
MS	Ministério da Saúde
OMS	Organização Mundial da Saúde
SARS-COV-2	<i>Severe acute respiratory syndrome Coronavirus 2</i>
IA	Inteligência Artificial
RNC	Rede Neural Convolucional
TC	Tomografia Computadorizada

Sumário

1	INTRODUÇÃO	16
1.1	Aplicabilidade e Motivação	17
1.2	Objetivos	17
1.3	Objetivos Específicos	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	COVID-19	18
2.1.1	Sintomas e transmissão	18
2.1.2	Diagnósticos e testes	18
2.1.3	Formas de prevenção e controle de infecções	19
2.2	Perceptron Multicamadas	19
2.3	Rede Neural Convolutacional	20
2.3.1	Convoluções	21
2.3.2	Filtros	22
2.4	Stride	23
2.4.1	Padding	24
2.4.2	Max Polling	25
2.4.3	Funções de ativação	25
2.4.3.1	ReLu	26
2.4.3.2	Sigmoide	26
3	TRABALHOS RELACIONADOS	28
3.1	Analysis Of Deep Machine Learning Algorithms In Covid-19 Disease Diagnosis	28
3.2	Improving Performance Of Cnn To Predict Likelihood Of Covid- 19 Using Chest X-ray Images With Preprocessing Algorithms	29
3.3	A Light Cnn For Detecting Covid-19 From Ct Scans Of The Chest	30
3.4	Síntese De Imagens De Raios-x De Problemas Respiratórios Utilizando Redes Neurais Adversariais Generativas	31
4	METODOLOGIA	33
4.1	Ambiente de Treinamento	33
4.2	Formação da base de dados	33
4.3	Arquitetura e Treinamento	36

5	EXPERIMENTO E COLETA DE DADOS	39
5.1	Descrição do experimento	39
5.2	Coleta de Dados	40
5.2.1	Precisão por classe	40
5.2.1.1	Normal	40
5.2.1.2	Covid-19	41
5.2.1.3	Pneumonia	41
5.2.2	Precisão geral	42
5.2.3	Discussão	42
6	CONCLUSÕES	45
6.1	Trabalhos futuros	45
	REFERÊNCIAS	46

1 Introdução

A pandemia do novo coronavírus, teve início em dezembro de 2019 na província de chinesa de Wuhan (ZHENG et al., 2020), e tem causado transtornos em todo mundo e em diversas áreas, desde fechamento de comércios, escolas e restaurantes, a sobrecarga do sistema hospitalar. Segundo os dados da OMS (2020b)¹ o número de mortes globais pelo Covid-19 passa de 1 milhão e mais de 37,4 milhões de casos já foram confirmados.

Governo de todos os países têm adotado sistemas de isolamento social para tentar impedir o avanço do contágio, e alguns destes já enfrentam a segunda onda da doença. A realização de teste para detecção da Covid-19 é um desafio para todos, pelo fato dos dispositivos e *kits* de exames serem limitados e, em muitos casos, não acessíveis em toda contingência dos países. Hospitais tiveram que se reorganizar rapidamente para atender as necessidades dos pacientes positivos e a quantidade massiva de exames médicos realizados.

A heterogeneidade dos cenários nas regiões do Brasil reforça a necessidade de diferentes organizações e oferta de serviços de saúde, envolvendo a logística para distribuição de insumos, a organização do processo de trabalho e o sistema de financiamento diferenciado (FLOSS et al., 2020). Porém, no Brasil, números de exames realizados da Covid-19 RT-PCR, que detectam o genoma do vírus, caíram consideravelmente nos últimos meses, segundo os dados apresentados por Garcia (2020)², além do fato de que 6,86 milhões deste mesmo teste perderão a validade em dezembro de 2020 e janeiro de 2021, provocado pelo desequilíbrio na distribuição entre os estados de acordo com UOL (2020)³, e isto pode vir a provocar novas ondas da doença, e gerar novas sobrecargas nos sistemas de saúde, públicas e privadas.

O uso de tecnologias para auxiliar as áreas médicas, já se tornou algo recorrente, por conta da necessidade de extensos processamentos de informação gerada neste campo. As tecnologias de máquina de aprendizados podem ser utilizadas para automatizar os processos de classificação de imagens médicas, capazes de aprender os detalhes de uma doença para um prévio diagnóstico. Pensando nisto, este trabalho teve o objetivo de criar e treinar uma Rede Neural Convolucional, redes baseadas em multicamadas convolucionais, usadas em classificações de imagens e vídeos. Com isto diminuir a sobrecarga nos serviços de radiologia, tornar mais eficaz a triagem, as avaliações médicas e rapidez no diagnóstico e, conseqüentemente, tratamento mais adequado aos pacientes.

É possível classificar diversas imagens médicas, como ultrassom, tomografia computadorizada e ressonância magnética, mas nesta RNC será analisado imagens radiológicas

¹ <<https://covid19.who.int/table>>

² <<https://g1.globo.com/bemestar/coronavirus/noticia/2020/11/19/testes-de-covid-voltam-a-cair-em-outubro-espe.html>>

³ <<https://noticias.uol.com.br/saude/ultimas-noticias/redacao/2020/11/22/jornal-por-prazo-de-validade-governo-pode-jogar-fora-milhoes-de-testes.htm>>

torácicas, por serem mais acessíveis e mais usualmente encontrados em hospitais. Há um grande desafio na identificação correta entre as imagens com Covid-19 e Pneumonia, pelos detalhes semelhantes nos pulmões em que podem influenciar no resultado.

Portanto a relevância deste trabalho está em sua abrangência social, na busca de técnicas que possam favorecer e auxiliar as demandas existentes gerado pela desordem causada pela pandemia em diversos setores da sociedade.

1.1 Aplicabilidade e Motivação

Os desafios no combate ao novo coronavírus ainda são muitos, com diversas consequências já implicadas na sociedade. As segundas ondas da doença, e as possibilidades delas serem ainda piores, com o aumento nos casos e novas sobrecargas hospitalares, agravam mais as dificuldades já existentes.

O uso de uma RNC pode viabilizar e facilitar a triagem e resultados da Covid-19 em hospitais que não se tem muitos recursos, como os *kits* de detecções, ou então que só há as máquinas de raio-x, e também diminuir e ajudar o trabalhos dos profissionais de saúde.

1.2 Objetivos

Montar uma Rede Neural Convolutacional com a finalidade de viabilizar a identificação com um grau aceitável de acurácia os efeitos do Covid-19 no pulmão humano utilizando imagens radiológicas torácicas.

1.3 Objetivos Específicos

- Realizar pesquisas dentro da área, afim de reconhecer e investigar assuntos análogos.
- Criação da base de dados, contendo imagens pulmões saudáveis, Covid-19 e Pneumonia.
- Construção da arquitetura da RNC própria afim de validar a melhor arquitetura.
- Validar resultados com a base de dados criada.

2 Fundamentação Teórica

Esta seção visa tratar sobre a Covid-19 na Seção 2.1, e esclarecer os conceitos de redes neurais nas Seções 2.2, que será dissertado sobre a Perceptron Multicamadas, e na 2.3 será detalhado e exemplificado a concepção das Redes Neurais Convolucionais e suas características.

2.1 COVID-19

A COVID-19 é a doença causada pelo Sars-Cov-2, pertencente a família dos coronavírus, estes que comumente infectam diversas espécies de mamíferos, dificilmente consegue infectar os humanos. Os morcegos abrigam coronavírus semelhantes à síndrome respiratória aguda (SARS) (SL-CoVs), dos quais se acredita que o agente causador da pandemia de SARS de 2002 – 2003 tenha se originado (ZENG et al., 2016). A Organização Mundial da Saúde (OMS) declarou o surto de SARS contido em 2003 teve um total de 8.096 casos de SARS e 774 mortes em 29 países foram relatados para uma taxa de letalidade geral de 9,6% (WU; MCGOOGAN, 2020). Este vírus possui tal nome por suas as partículas, que variam de 60 – 140 nm de diâmetro, apresentarem espigões em sua forma, aparentado assim uma coroa solar (WEI et al., 2020).

2.1.1 Sintomas e transmissão

Os sintomas mais comuns é febre, tosse seca e cansaço, porém os infectados podem apresentar também diarreia, perda de sabor ou cheiro, conjuntivite e dores, e em casos mais graves perda de fala ou movimento, dor ou pressão no peito e dificuldade em respirar ou falta de ar (OMS, 2020a)¹.

O vírus da COVID-19 se transmite, principalmente, por gotículas de saliva ou secreção nasal, mas podem ser propagados também pelo contato próximo, como superfícies ou objetos infectados. A doença apresenta elevada transmissibilidade, o grande contingente de indivíduos infectados e adoecidos ao mesmo tempo representa risco de sobrecarga para o atendimento dos sintomáticos e dos graves, podendo gerar estrangulamento do sistema de saúde e elevar significativamente a letalidade da doença (CAETANO et al., 2020).

2.1.2 Diagnósticos e testes

O seu diagnóstico pode ser de diferentes maneiras, sendo elas o diagnóstico clínico, o clínico-epidemiológico, laboratorial, laboratorial em indivíduo assintomático e o clínico-

¹ <<https://www.who.int/health-topics/coronavirus>>

imagem de acordo com o MS (2020)², sendo o este último o foco para da automatização neste artigo. Há também o diagnóstico pelos testes de RT-PCR, rápidos e os sorológicos.

O RT-PCR é o mais preciso entre os eles, e detecta o material genético do vírus, é recomendado realizar do primeiro ao oitavo dia após os sintomas, porém possui uma realização complexa e equipamento específicos, além de demorar entre 6 a 24, ou até mais, horas para o resultado, e um único teste PCR negativo não é conclusivo.

Os testes rápidos identificam as substâncias de defesa, os anticorpos IgM e IgG, geradas pelo sistema imunológicos, estes são fáceis e rápidos de serem realizados, cerca de 15 minutos a partir da coleta, contudo apresenta um elevado número de falsos negativos e só deve ser feito depois de sete dias, caso contrário a sua sensibilidade é de 30%. Já os teste sorológicos buscam os anticorpos no plasma, também levam em média 24 horas para o seu resultado, mas exigem laboratórios automatizados, e possui uma sensibilidade superior a 80%, dados obtidos por (AZEVEDO, 2020)³.

2.1.3 Formas de prevenção e controle de infecções

As formas de prevenção existente segundo ao (MS, 2020)⁴ são: Lavar as mãos constantemente com água e sabão, ou álcool em gel 70%; Manter uma distância de pelo menos 1 metro entre as pessoas; Manter os ambientes lipos e ventilados; Utilizar máscaras em todos lugares, as de tecidos caseiras não são Equipamentos de Proteção Individual (EPI), mas funcionam como barreira física, contra gotículas contaminadas.

Os governo, em sua maioria, tomaram como medida de controle o isolamento e confinamento social, no qual restringiam a circulação de pessoas, e fechamento de faculdade e escolas, e do comércio não essencial.

2.2 Perceptron Multicamadas

Perceptron Multicamadas é uma rede neural com uma ou mais camadas ocultas, ou intermediárias, com um número indeterminado de neurônios, imitando os neurônios humanos. A maioria dos resultados é declarada para uma saída unidimensional, mas pode ser estendida para redes de várias saídas (HORNIK et al., 1989), representado na Figura 1.

As Redes Neurais de Múltiplas Camadas são profundamente precisas. Os neurônios entradas são ativados por uma função de ativação, gerando uma saída que será a entrada para a camada intermediária. De forma geral, os nós de cada camada têm como entradas os valores de saída da camada anterior. A falta de sucesso é devido à aprendizagem ina-

² <<https://coronavirus.saude.gov.br/sobre-a-doenca>>

³ <<https://oglobo.globo.com/sociedade/coronavirus-servico/conheca-as-vantagens-desvantagens-dos-diferentes-tipos>>

⁴ <<https://coronavirus.saude.gov.br/sobre-a-doenca>>

dequada, número insuficiente de unidades ocultas ou a falta de um relação determinística entre entrada e destino (HORNİK et al., 1989).

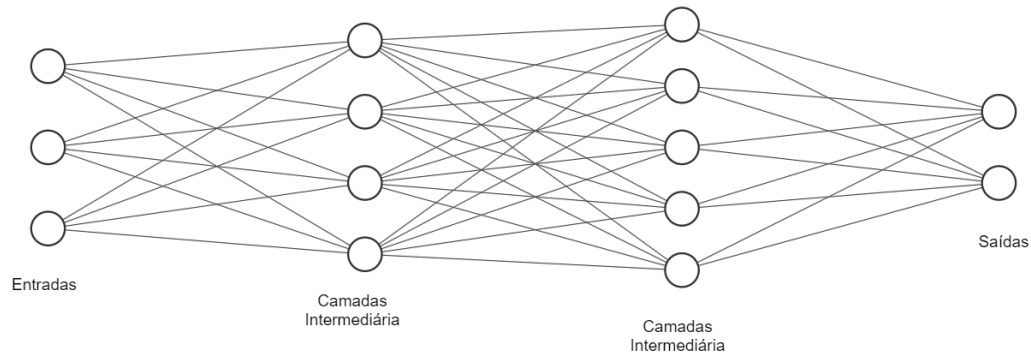


Figura 1 – Representação de uma arquitetura MLP. À esquerda estão presentes as entradas, ao centro as duas camadas intermediárias, e nessa rede específica, à direita, 2 saídas.

2.3 Rede Neural Convolutacional

Rede Neural Convolutacional (RNC) é uma classe de redes neurais artificiais de *feed-forward* profundo que é comumente usada em problemas de visão de computador, como classificação de imagem (AGARAP, 2017). A Rede Neural Convolutacional (RNC) se tornou o novo padrão na visão computacional pela facilidade de treinamento quando se há um grande acervo de imagens classificadas em diferentes classes-alvo. O processo consiste em extrair características de uma imagem, e utiliza-se das técnicas convolucionais para estruturar sua rede Neural.

Uma das principais diferenças é que os neurônios que formam as camadas da RNC são compostos de neurônios organizados em três dimensões, a dimensionalidade espacial da entrada (altura e largura) e a profundidade (O'SHEA; NASH, 2015), esta última dimensão corresponde ou número de canais de cor da imagem, ou seja, se a mesma for colorida RGB (*Red*, *Green* e *Blue*) ela irá possuir o valor de profundidade 3, caso cinza o valor será 1.

As camadas são processadas por filtros aleatórios, isto faz com o computador aprenda por si só quais os melhores valores dos filtros, em outras palavras quais características são mais significativos para o seu objetivo estabelecido. Esses filtros são geralmente pequenos em dimensionalidade espacial, mas se espalham ao longo de toda a profundidade da entrada (O'SHEA; NASH, 2015).

As vantagens de uma RNC estão em, como, por exemplo, o compartilhamento de parâmetros, isso significa que, ao usar um filtro detector, é possível replicá-lo à próxima

posição, e assim por diante. Deste modo, cada um desses detectores, pode usar os mesmos parâmetros em lotes de posições diferentes em sua imagem de entrada, conseguindo extrair características específicas e importantes através do aprendizado.

Outra vantagem desse método é que cada neurônio está totalmente conectado a todos os neurônios da camada anterior e, os mesmos em uma única camada trabalham de forma completamente independente e não compartilham nenhuma conexão. Além também de possuírem menos parâmetros, o que permite que sejam treinados com células de treinamento menores. Essa tecnologia vem sendo amplamente aplicada em imagens médicas para a detecção de diferentes doenças, como demonstra Wang et al. (2019). A arquitetura exemplificada na Figura 2.




Figura 2 – Representação de uma arquitetura RNC. À esquerda a entrada, seguida de convoluções e *max pollings* intercalados, por fim ao final da figura, as *Dense Layers*.

2.3.1 Convoluções

Convolução é uma operação matemática formal, assim como multiplicação, adição e integração, retratado na Figura 3. A adição leva dois números e produz um terceiro número, enquanto a convolução recebe dois sinais e produz um terceiro sinal (SMITH et al., 1997).

A convolução é representada pela estrela, “*”, o que pode ser confundido pela operação de multiplicações nas maiorias das linguagens de programação. Convoluções são usadas na matemática em muitos campos, como probabilidade e estatística. Em sistemas lineares, a convolução é usada para descrever a relação entre três sinais de interesse: o sinal de entrada, a resposta ao impulso e o sinal de saída (SMITH et al., 1997).

- Expressão Matemática: n representa o tamanho matriz de entrada, f simboliza o tamanho do filtro, s equivale ao número de *strides*, e p é o número do *padding*.

$$((n + 2p - f)/s) + 1$$




Figura 3 – Figura explicativa de uma convolução, à esquerda a matriz que será sofrerá a convolução, ao meio o filtro, e à direita o resultado.

2.3.2 Filtros

Um filtro, ou *kernel*, é uma matriz com valores que dependem do objetivo da identificação, como identificar linhas de verticais ou horizontais, demonstrado na Figura 4. Isto produzirá um mapa de ativação bidimensional que consiste nas respostas do filtro em determinadas regiões (AGARAP, 2017).

Os filtros são aplicados de uma maneira que respeita a geometria subjacente da entrada (YOSINSKI et al., 2015). Esses filtros realizam operações ao longo da imagem percorrendo-a, cada elemento do filtro é multiplicado pelo elemento da imagem de mesma posição, região onde o mesmo está sendo aplicado. No fim, soma-se os resultados destas multiplicações para obter o valor da saída. Este valor será o pixel correspondente na imagem filtrada.

Os resultados das operações de todos os filtros da camada são diversas imagens filtradas, organizadas em uma nova camada, com profundidade igual ao número de filtros aplicados. Agora esta camada será a entrada da próxima.

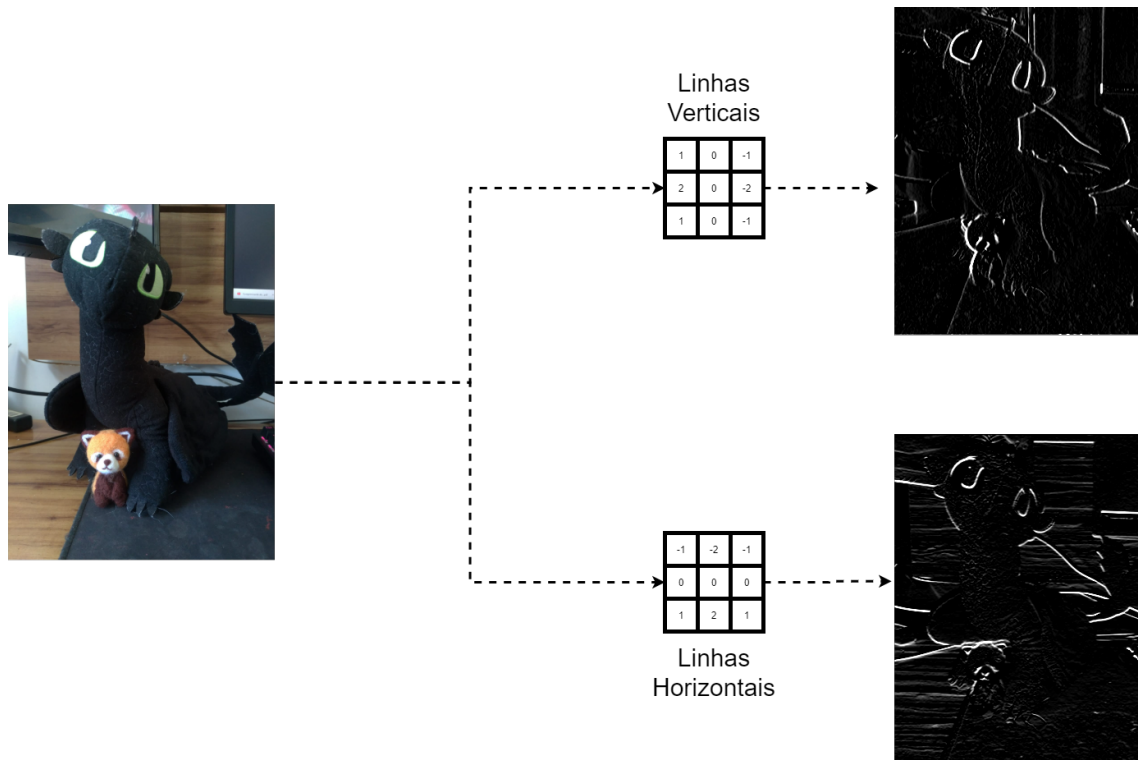


Figura 4 – Fluxo explicativo do funcionamento dos filtros, à esquerda a imagem de entrada, o caminho superior o filtro que detecta as linhas (bordas) verticais, seguida pelo seu resultado. E o caminho inferior demonstra o filtro para detecção de linha (bordas) horizontais, e o resultado obtido.

2.4 Stride

O *stride* determina o número de passos que o filtro percorrerá em cima da matriz de entrada para que possa realizar a convolução, ilustrado na Figura 5. Este processo de *stride* define o quanto de detalhamento e velocidade uma convolução terá.




Figura 5 – Fluxo explicativo do funcionamento dos *stride*, à esquerda a imagem de entrada, o caminho superior o filtro deslocando-se um passo, com *strides* = 1. E o caminho inferior demonstra o filtro deslocando-se dois passos com o uso do *strides* = 2.

2.4.1 Padding

Na convolução, a cada operação sua imagem encolhe, com isso, talvez, tende a ficar pequena, a ponto de não ser possível definir mais recursos sobre a mesma, vindo a tornar-se uma desvantagem. Outro problema que pode vir a existir numa operação convolução é a perda de informações em suas bordas, isso acontece pelo fato de que os pixels dos cantos são menos processados do que os demais, como os dos meios, então muita informação é desperdiçada nas extremidades. O deslocamento de localização se acumula ao empilhar várias convoluções, prejudicando gravemente as informações espaciais (WU et al., 2019).

Para solucionar essas desvantagens do processo convolucional é usado o *padding*, preenchimento, criando uma borda adicional e permitindo que os pixels das bordas originais sejam processados mais vezes e também mantendo o tamanho inicial da entrada. O preenchimento da borda da entrada é um método eficaz para fornecer controle adicional quanto à dimensionalidade dos volumes de saída (O'SHEA; NASH, 2015). Essa convolução com preenchimento é chamada de Mesma Convolução (*Same Convolution*), e quando não há o preenchimento é chamada de Válida (*Valid*), representados, respectivamente, nas Figuras 6 e 7.




Figura 6 – Representação da convolução *Same*, no qual a saída sempre será igual a entrada.




Figura 7 – Representação da convolução *Valid*, no qual a saída sempre será menor que sua entrada, à esquerda.

2.4.2 Max Polling

A camada de *pooling* (denotada por *POOL*) reduz o tamanho das imagens de entrada de acordo com os resultados de um filtro (AGARAP, 2017), exemplo na Figura 8. As camadas de *pooling* são muitas vezes realizadas após uma convolução, com o objetivo também de manter sua profundidade, e acelerar, consideravelmente, a computação.

O *Max Polling* consiste em gerar uma saída com apenas o máximo de cada região. Diminui o tamanho da representação pela metade, assim, absorve rapidamente as diferenças de comprimento ou representação (HU et al., 2014). Uma propriedade interessante é que ele tem um conjunto de hiper parâmetros, porém não possui parâmetros de aprendizagem.




Figura 8 – Representação do processo de um *Max Polling* 2 x 2 com 2 *destrides*, assim, dividindo a matriz pela metade.

2.4.3 Funções de ativação

As funções de ativação são essenciais para ensinar ao neurônio se informação recebida é relevante ou não para prosseguir, introduzindo um componente de não linearidade. Porém a implementação torna a otimização um pouco mais complicado. Se uma função de ativação não for usada em uma rede neural então o sinal de saída seria simplesmente

um simples linear, quais não têm a capacidade de aprender e reconhecer mapeamentos complexos de dados (SHARMA, 2017).

2.4.3.1 ReLu

A função linear rectificada (*ReLU*) produz zero em metade do seu domínio, e são fáceis de otimizar, como consequência, as derivadas se mantêm grandes enquanto a unidade estiver ativa. A vantagem de usar a função ReLU é que todos os neurônios não são ativados ao mesmo tempo (SHARMA, 2017). Uma desvantagem da ReLU é que unidades tendem a cair, passando a produzir apenas zeros, durante o treinamento. Isso acontece quando a soma ponderada antes da aplicação se torna negativa. Representação gráfica na Figura 9




Figura 9 – Representação gráfica da função ReLU

2.4.3.2 Sigmoides

Até pouco tempo atrás, a função sigmoide era a mais utilizada em RNAs, a função logística praticamente desapareceu dos modelos modernos de redes neurais mais convencionais.

A função sigmoide assume valores apenas entre 0 e 1, respectivamente, não ativação e ativação. No entanto, sua derivada satura para valores acima de 5 e abaixo de -5. Com essas derivadas tendendo a zero, a propagação do gradiente desvanece nessas regiões, causando dificuldades no treinamento. Esta função não é simétrica em relação a zero o que significa que os sinais de todos os valores de saída de neurônios serão os mesmos (SHARMA, 2017).

Ela ainda pode ser utilizada na saída da RNA, para modelar variáveis binárias. Alguns modelos probabilísticos, redes neurais recorrentes e alguns modelos não supervisionados tem restrições que tornam a torne necessária. Representação gráfica na Figura 10.




Figura 10 – Representação gráfica da função Sigmoide

3 Trabalhos Relacionados

Neste capítulo iremos dissertar sobre os trabalhos relacionados ao tema em destaque. Na Seção 3.1 é abordado uma comparação de arquiteturas de RNC para a detecção da Covid-19. As Seções 3.2 e 3.3 também discutem sobre a detecção do coronavírus, sendo o primeiro utilizando imagens radiológicas e a arquitetura VGG-16, e a segunda trabalhando com imagens de tomografia computadorizadas e uma arquitetura própria. Já na Seção 3.4 é elucidado sobre a síntese de imagens de raios-x utilizando as redes neurais adversariais generativas.

3.1 Analysis Of Deep Machine Learning Algorithms In Covid-19 Disease Diagnosis

Este artigo, Yadav et al. (2020) relata os desafios em realizar os testes e diagnosticar a Covid-19, como a dificuldade no acesso aos limitados *kits* de testes, e os sinais de triagem não confiáveis. Então apresenta como solução as tecnologias digitais de automação e sistemas robóticos, mais precisamente a visão computacional para encontrar, localizar, classificar e analisar objetos a partir de uma imagem. Tecnologias parecidas já são usadas para atividades complexas como:

- ROC (Reconhecimento Óptico de Caracteres), convertendo texto de uma imagem em texto editável;
- RA (Realidade Aumentada), permitindo que objetos virtuais sejam projetados em uma imagem e/ou ambiente real;
- Diagnósticos médicos, usados na detecção precoce de células cancerosa, aumentando a qualidade das imagens de ressonância magnéticas.

O trabalho usa os algoritmos de aprendizados de máquina profunda para resolver problemas de reconhecimento de imagens e também redes neurais para diagnosticar a Covid-19 a partir de radiografias de tórax. Ao usar a rede neural convolucional, redes que usam camadas convolucionais, que por sua vez são caracterizados pelo uso de matrizes de peso, chamados filtros ou *kernel*, menores que a imagem original, esse *kernel* em uma certa etapa percorre o conjunto de dados de entrada e calcula as somas dos produtos dos valores das células correspondentes. Ele descreve as seguintes arquiteturas:

- VGG (SIMONYAN; ZISSERMAN, 2014), proposta em 2014, tem como principal característica o uso de camadas convolucionais consecutivas com filtros 3 x 3, utili-

zando função de ativação ReLU em sua completude, em vez das camadas convolucionais utilizadas anteriormente com grandes filtros. Isto tornou possível reduzir o número de parâmetros, e ainda assim manter a eficiência. Existe várias configurações de VGG, sendo as conhecidas a VGG-16 e VGG-19.

- Inception (SZEGEDY et al., 2016), utiliza módulos aninhados como camadas, que são um conjunto de diferentes dimensões e, posteriormente, a junção dos resultados. Abandonando as camadas totalmente conectadas, usando então um pool de média global, convertendo cada mapa de recurso em um número formando um vetor de valores médios. Diminuindo o número de parâmetros de complexidade computacional;
- ResNet(HE et al., 2016), a maior característica da rede são suas conexões que transmitem informações inalteradas para as partes mais profundas, que serão somadas com o valor calculado nas camadas ausentes e transmitidos posteriormente;
- DenseNet (HUANG et al., 2017), semelhante a ResNet, porém sua diferença está em que todos seus blocos da rede são conectados por conexões diretas, assim cada bloco recebe informações de todos anteriores.

Demonstrando melhores resultados no Inception.

3.2 Improving Performance Of Cnn To Predict Likelihood Of Covid-19 Using Chest X-ray Images With Preprocessing Algorithms

No artigo, (HEIDARI et al., 2020) apresentam a problemática do pandemia do Covid-19 e seus diagnósticos. Explica a facilidade e vantagens encontradas na realização de imagens de raio-x, fala sobre o diagnóstico auxiliado por computador e sistemas baseados em processamentos de imagens médicas, e como elas podem ser ferramentas valiosas de apoio aos radiologistas. Aponta também que o uso de redes neurais convolucionais têm uma precisão superior em comparação com outras técnicas de processamento e identificação de imagens.

O estudo utiliza-se de um rede neural VGG16, por possuir vantagens para esta aplicação como uma superioridade e um desempenho estável em diversos conjuntos de imagens, e também ficou em primeiro lugar numa competição, em 2014, envolvendo 14 milhões de imagens. O *dataset* deste trabalho foi composto somente por 8,474 imagens de raio-x torácicas pósterio anteriores, separadas em 415 com Covid-19 confirmada, 2,880 normais e 5,179 com pneumonia. Imagens quais foram submetidas a um pré-processamento para remover o diafragma das imagens, com o objetivo de evitar um diagnóstico equivocado.

Posteriormente a imagem é filtrada bilateralmente usando o filtro *Gaussian low-pass*, etapa que gera uma imagem com redução de ruído, e normalizada usando a equalização do histograma alimentada em três canais RGB de entrada do modelo RNC baseado em VGG16, respectivamente. As imagens em todos os 3 canais são redimensionadas para 224 x 224 pixels para caber no modelo pré-treinado.

No treinamento inicial da RNC no conjunto de dados em grande escala, ela aprendeu a distinguir os recursos de imagem mais comuns e notáveis, como forma, borda, etc. Em seguida, é adequada para a próxima fase, que é a aprendizagem por transferência. o modelo VGG16 tem 16 convoluções e camadas totalmente conectadas em 6 blocos, que incluem mais de 138 milhões de parâmetros treináveis.

No aprendizado de transferência, os pesos entre os nós conectados na frente ou nas camadas baixas da rede foram mantidos. As camadas superiores do modelo VGG16 foram cortadas e removidas. Em seguida, para preparar o RNC para esse propósito de aplicação, foi adicionado uma camada plana, duas camadas totalmente conectadas com 256 e 128 nós, respectivamente. A Unidade Linear Retificada (ReLU) é usada como sua função de ativação. Em seguida, a última camada de classificação, que usa Softmax como a função de ativação para construir o modelo de aprendizado profundo completo para cumprir uma tarefa de classificação de três classes (normal, pneumonia e Covid-19).

Entre 848 casos de teste, 796 são corretamente detectados e classificados em três classes. Assim, a precisão geral é de 93,9% (796/848) com intervalo de confiança de 95% de [0,92,0,96]. Para avaliar futuramente o desempenho do esquema CAD desenvolvido com o modelo RNC baseado em VGG16 na detecção de infecção por COVID19 usando imagens de raios-X de tórax, colocamos imagens de pneumonia adquiridas pela comunidade na classe negativa e os casos de pneumonia infectados com COVID-19 na classe positiva. Combinando os dados na matriz de confusão, o esquema CAD produz 100% de sensibilidade (42/42) e 98,5% de especificidade (794/806). A precisão geral é de 98,6% (836/848).

3.3 A Light Cnn For Detecting Covid-19 From Ct Scans Of The Chest

O artigo, (POL SINELLI; CINQUE; PLACIDI, 2020) disserta sobre a provável importância do TC para o diagnóstico e tratamento da pneumonia por COVID-19, considerando os incrementos contínuos em casos globais. Mas salienta os problemas que os radiologistas vivenciam na análise de imagens radiológicas no escaneamento visual de pequenos detalhes. Além disto, um grande número de imagens de TC deve ser avaliado em um tempo muito curto, aumentando assim a probabilidade de erros de classificação. Isso justifica o uso de abordagens inteligentes que podem classificar automaticamente as imagens de TC

do tórax.

(POL SINELLI; CINQUE; PLACIDI, 2020) relatam os problemas dos conjuntos de dados limitados para COVID-19. Por esse motivo, durante a fase de treinamento é necessário evitar / reduzir o sobreajuste (isso significa que o RNC não está aprendendo as características discriminantes das tomografias COVID-19, mas apenas as memorizando). Mais ainda, esse tipo de máquina não poderia estar disponível em hospitais, principalmente em situações de emergência e / ou em países em desenvolvimento.

Neste trabalho, pretendeu-se obter desempenhos aceitáveis para um método automático no reconhecimento de imagens COVID-19 CT de pulmões e, em simultâneo, lidar com conjuntos de dados reduzidos para treinamento e validação e reduzir a sobrecarga computacional imposta por sistemas automáticos mais complexos. Por esta razão, foi utilizado o modelo do SqueezeNet CNN, pois ele é capaz de atingir a mesma precisão das RNCs modernas, mas com menos parâmetros. O conjunto de dados é composto por 360 tomografias de indivíduos COVID-19 e 397 tomografias de outros tipos de doenças e / ou indivíduos saudáveis. O conjunto de dados italiano é composto por 100 tomografias do COVID19

O SqueezeNet pode atingir o mesmo nível de precisão de outros designs de RNCs, mais complexos, que possuem um grande número de camadas e parâmetros. Composto por blocos denominados "Módulo de Incêndio". Cada bloco é composto por uma camada de convolução de compressão (que tem filtros 1x1) alimentando uma seção de expansão de duas camadas de convolução com filtros 1x1 e 3x3, respectivamente. Cada camada de convolução é seguida por uma camada ReLu. A saída das camadas ReLu da seção de expansão é concatenada com uma camada de Concatenação. Para melhorar a convergência de treinamento e reduzir o sobreajuste, adicionamos uma camada de normalização em lote entre a camada de convolução de compressão e a camada ReLu.

3.4 Síntese De Imagens De Raios-x De Problemas Respiratórios Utilizando Redes Neurais Adversárias Generativas

Nesta monografia (SANTANA; BARBOSA, 2020) menciona os problemas enfrentados pelas áreas de estudos computacionais de diagnóstico com escassez de dados de doenças "raras". Pensando nisto eles propuseram gerar imagens sintéticas de raio-x pulmonares que sejam visualmente realísticas a partir de poucas amostras de imagens reais.

Para conceber imagens sintéticas, dividiram a abordagem do trabalho proposto em 4 etapas, preparar o *dataset*, tratamento das imagens utilizando *data augmentation* com o objetivo de expandir o *dataset* escolhido, treinamento da rede neural utilizando dois modelos geradores: WGAN e DCGAN, e realizar a comparação entre estes modelos.

Os modelos DCGAN e WGAN utilizados, possuindo estruturas de padrões generativos, possibilitam a execução dos módulos para efetuar o treinamento das redes com pesos de inicialização aleatórios, com o otimizador Adam. Sendo ajustado experimentalmente entre valores iniciais e sendo fixados em 100, este foi um valor suficiente de épocas para atingir um resultado considerável em ambas dos GANs. As imagens geradas foram utilizadas para montar o *dataset* utilizado, onde cada modelo gerou uma pasta com uma quantidade de figuras equivalentes às quantias das pastas das amostras originais para que pudessem corresponder ao teste.

Os modelos generativos treinados produziram imagens realísticas e variadas, conseguiram reproduzir características de raio-x pulmonares. Apesar de aprender bem as partes importantes das estruturas torácicas vistas em um raio-x, O DCGAN não foi capaz de gerar imagens com nitidez. Com isto foi possível notar que o WGAN por possuir uma camada extra de convolução acaba possuindo uma melhor resolução em relação ao DCGAN, sendo assim mais assertivo no experimento com pessoas reais.

4 Metodologia

Trata-se de um estudo experimental e neste capítulo será dissertado sobre os desenvolvimentos de forma detalhada, passando pelo ambiente de treinamento na Seção 4.1, formação da base de dados na Seção 4.2, e processos de arquiteturas na Seção 4.3. Foram utilizados 26 artigos para realização desta pesquisa extraídos dos repositórios arXiv¹ e Google Acadêmico², no período de agosto a novembro de 2020 para construção do mesmo e análise dos resultados.

4.1 Ambiente de Treinamento

O ambiente de trabalho usado foi o Google Colaboratory³, mais conhecido como "Colab", um serviço gratuito fornecido e hospedado pelo Google, concebido como um projeto de pesquisa para prototificar e disseminar a educação em modelos de aprendizado de máquina em opções de *hardware* robustos Carneiro et al. (2018). Foi utilizado a linguagem Python de programação, que combina o poder das linguagens de programação de propósito geral com a facilidade de uso de linguagens de *script* específicas do domínio, como MATLAB ou R Müller, Guido et al. (2016). Além de tornar disponíveis diversas bibliotecas úteis como *Tensor Flow*, *PyTorch* e *Keras*.

O Colab oferece dois tipos de serviços, o gratuito, fornecendo recursos mais básicos, ainda assim eficientes, e o pago, chamado de Pro, viabilizando melhores recursos de *hardware*, e o qual é utilizado neste trabalho pela necessidade de um melhor desempenho, alocando 25,51 GB de RAM e 107,77 GB de Disco e uma GPU Nvidia Tesla V100 de 16 GB.

4.2 Formação da base de dados

A quantidade de bases de dados de Covid-19 ainda é escassa, e muitas delas são privadas, o que dificulta bastante a formação de banco de imagens conciso. Também não foi encontrado nenhum repositório que possuísse, em grande quantidades, todos os tipos de raio-x torácico, incluindo Covid-19.

Por conta disto, o conjunto de dados utilizado neste trabalho foi construído a partir de um conjunto de outras bases⁴ de imagens de raio-x torácico posto-anteriores e antero-posteriores, dispostos na Tabela 1, separado em dois grupos, treinamento e teste, ambos divididos em 3 classes: normais, Covid-19 e Pneumonia, como pode ser visto na Figura

¹ <<https://arxiv.org/>>

² <<https://scholar.google.com.br/>>

³ <<https://colab.research.google.com/notebooks/intro.ipynb>>

11. A parte de treinamento consiste em 15.000 imagens, e o teste formado por 1.500 imagens, 10% do treinamento.


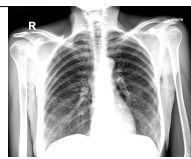


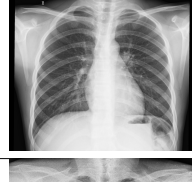



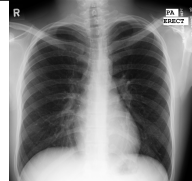
Base de Dados	Normal	Covid-19	Pneumonia
Brixia-score-COVID-19			
Xrays Chest 299px			
COVID19_Pneumonia_Normal_Chest_Xray(PA)_Dataset			
COVID-19 Radiography Database			
Chest X-Ray Images (Pneumonia)			
Actualmed COVID-19 Chest X-ray Dataset Initiative			
Shenzhen			
Figure 1 COVID-19 Chest X-ray Dataset Initiative			
Montgomery			

Tabela 1 – Tabela com representação das imagens contidas em cada uma das bases de dados utilizadas, separadas por um exemplo de cada classe presente na mesma.

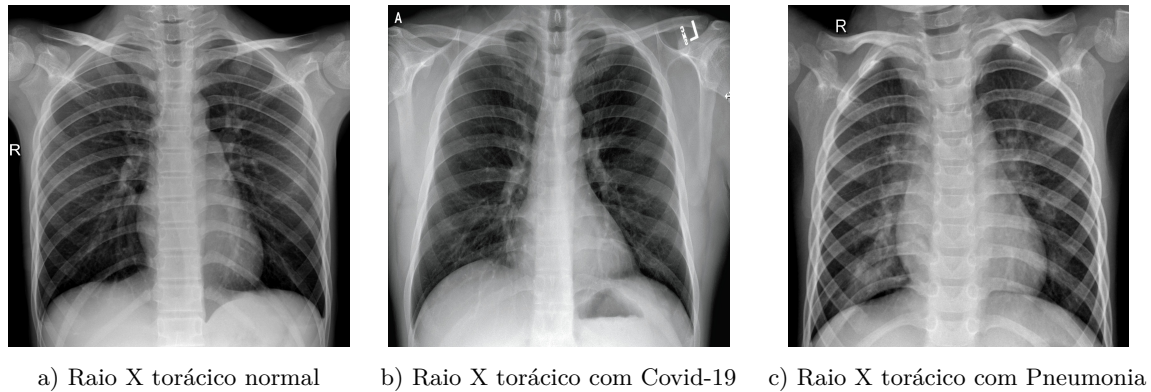


Figura 11 – Comparação entre raio X torácico

4.3 Arquitetura e Treinamento

Já existem diversas arquiteturas estabelecidas de Rede Neurais Convolucionais, como as VGG's, ResNet e Inception, porém neste trabalho não será usado nenhum delas, e sim uma rede construída do zero, por motivo de aprendizagem e para demonstrar que é relativamente fácil criar uma RNC, logo, as configurações da rede foram modificadas de acordo com os cálculos convolucionais. Até chegar na configuração final, diversas estruturas foram testadas realizando os mesmo experimentos, com a finalidade de se conseguir a melhor acurácia possível.

A estrutura da RNC estabelecido neste trabalho foi composto por entradas de 128 x 128, tratando-se das imagens da base de dados em escala de cinza. Contendo também quatro camadas convolucionais, sendo elas com filtros de 7 x 7, 5 x 5, 3 x 3 todos os 3 primeiros filtros com 2 de *strides* e o último de 3 x 3 com 1 de *strides*, e todas as convoluções utilizando como função de ativação o *ReLU* e com preenchimento válido. Além disso, estão presente duas camadas de *Max Pooling*, a primeira de 3 x 3 e 1 de *strides*, e a segunda de 2 x 2 com 2 de *strides*, cada uma após as duas primeiras convoluções, e por final duas camadas de *Dense Layer*, de 512 e 256 respectivamente, e utilizando a função sigmoide como ativação, como pode ser visto na Figura 12. No Algoritmo abaixo é possível visualizar de forma codificada os parâmetros da arquitetura da rede.

⁴ Referência das bases de dados:

```
<https://github.com/BrixIA/Brixia-score-COVID-19#license-and-attribution>
<https://www.kaggle.com/jbeltranleon/xrays-chest-299px>
<https://www.kaggle.com/amanullahasraf/covid19-pneumonia-normal-chest-xraypa-dataset?
select=COVID19_Pneumonia_Normal_Chest_Xray_PA_Dataset>
<https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>
<https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>
<https://github.com/agchung/Actualmed-COVID-chestxray-dataset>
<http://openi.nlm.nih.gov/imgs/collections/ChinaSet_AllFiles.zip>
<https://github.com/agchung/Figure1-COVID-chestxray-dataset>
<http://openi.nlm.nih.gov/imgs/collections/NLM-MontgomeryCXRSet.zip>
```

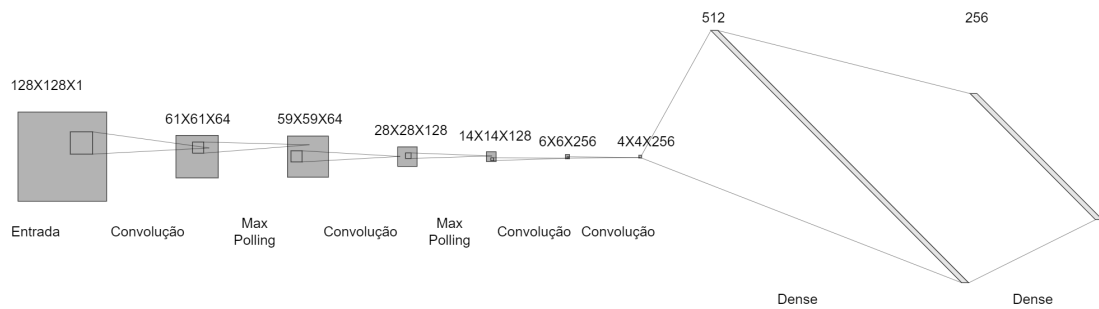


Figura 12 – Arquitetura da Rede Neural Convencional utilizada neste trabalho

```

1 out = tf.layers.conv2d(X, 64, (7, 7), (2, 2), padding='valid', activation=
  tf.nn.relu)
2 print(out.shape)
3 out = tf.layers.batch_normalization(out, training=is_training)
4 out = tf.layers.max_pooling2d(out, (3, 3), (1, 1), padding='valid')
5 print(out.shape)
6
7 out = tf.layers.conv2d(out, 128, (5, 5), (2,2), padding='valid',
  activation=tf.nn.relu)
8 print(out.shape)
9 out = tf.layers.batch_normalization(out, training=is_training)
10 out = tf.layers.max_pooling2d(out, (2, 2), (2, 2), padding='valid')
11 print(out.shape)
12 out = tf.nn.dropout(out, prob)
13
14 out = tf.layers.conv2d(out, 256, (3, 3), (2,2), padding='valid',
  activation=tf.nn.relu)
15 print(out.shape)
16 out = tf.layers.batch_normalization(out, training=is_training)
17 out = tf.nn.dropout(out, prob)
18
19 out = tf.layers.conv2d(out, 512, (3, 3), (1,1), padding='valid',
  activation=tf.nn.relu)
20 print(out.shape)
21 out = tf.layers.batch_normalization(out, training=is_training)
22 out = tf.nn.dropout(out, prob)
23 out = tf.reshape(out, [-1, out.shape[1]*out.shape[2]*out.shape[3]])
24
25 out = tf.layers.dense(out, 512, activation=tf.nn.sigmoid)
26 out = tf.nn.dropout(out, prob)
27 out = tf.layers.dense(out, len(classes_train), activation=None)
28
29 out = tf.layers.dense(out, 256, activation=tf.nn.sigmoid)
30 out = tf.nn.dropout(out, prob)
31 out = tf.layers.dense(out, len(classes_train), activation=None)
32

```

```
33 out = tf.layers.dense(out, 128, activation=tf.nn.sigmoid)
34 out = tf.nn.dropout(out, prob)
35 out = tf.layers.dense(out, len(classes_train), activation=None)
```

Todas as imagens foram redimensionadas para o tamanho de 128 x 128 antes de serem submetidas à convolução. O treinamento da rede foi realizado com 100 épocas com objetivo de torná-la robusta para que a mesma generalize futuras imagens independentes, mas que também não sofresse um sobreajuste, quando IA passa a memorizar as características ao invés de aprendê-las. Foi estabelecido um *Learning Rate* de 0.001 e o *Split Rate* de 0.8 para a divisão das imagens em treinamento e validação, e um *Batch Size* de 64. A Figura 13 demonstra graficamente o valores de *loss* do treinamento e validação, como pode visto houve muita variação no *loss* de validação, o que pode ter sido causado pela escolha do *batch normalization*. Por conta disto foi decidido parar a rede quando atingisse um ponto mais após um determinado número de épocas.




Figura 13 – Gráfico representativo do *loss* de treinamento e validação da RNC.

5 Experimento e Coleta de Dados

Esta seção será descrito o experimento na Seção 5.1 e demonstrado os dados resultantes e apurados pelo experimento na Seção 5.2.

5.1 Descrição do experimento

1. Definição do estudo Experimental

- a) Objeto de estudo: Análise e detecção da Covid-19 através de raio-x torácico usando uma RNC.
- b) Objetivo global: Avaliar a efetividade de um rede neural convolucional.
- c) Focos Específicos
 - i. Analisar: A efetividade de uma rede neural convolucional.
 - ii. A proposta é: Obter uma acurácia nas classificações da RNC superior a 80%.
 - iii. Com respeito a: Qualidade na detecção da Covid-19 em imagens de pulmão.
 - iv. Com o ponto de vista de: Estudante de graduação.
 - v. No contexto de: Doenças pulmonares.
- d) Foco na qualidade: Qualidade na experimentação.
- e) Contexto: Será carregado uma bateria de imagens radiológicas torácicas para serem analisadas e classificadas.
- f) Questões e métricas
 - i) Questões:
 - A. Q1) A rede neural terá uma boa acurácia na detecção da Covid-19?
 - B. Q2) Esse experimento trouxe uma melhoria significativa comparando as outras análises que já existem?
 - ii) Métricas:
 - A. Análise do experimento: será feita uma acurácia entre as classificações das imagens.
- g) Formulação de hipóteses
 - i. Objetivo: Comprovar a hipótese, como parâmetro dos resultados o desvio padrão, através dos resultados obtidos da base de dados.

- ii. H0 - Hipótese Nula:
H0: $h1 < 80\%$
- iii. H1 - Hipótese Alternativa:
H1: $h1 > 80\%$
 $h1$: Acurácia geral de todas as classes.
- h) Seleção das variáveis
 - i. Variáveis independentes:
 - A. Estrutura da Rede Neural Convolutacional.
 - B. Base de dados.
 - ii. Variáveis dependentes:
 - A. Resultado da acurácia.

5.2 Coleta de Dados

O experimento realizado neste trabalho consistiu em coletar 1.500 imagens de raios torácicas reais em suas respectivas classes e desconhecidas pela inteligência Artificial, organizadas de forma aleatória, e posteriormente, submetidas ao teste. Todos os acertos e erros foram considerados e contados para obter-se o resultado final da acurácia da rede em cada classe.

5.2.1 Precisão por classe


Nesta seção iremos exemplificar a precisão da IA como as imagens de acertos e erros de cada classe. Demonstrado na Tabela 2.

	Normal	Covid-19	Pneumonia
Normal	66,6%	33,4%	0,0%
Covid-19	11,0%	88,4%	0,6%
Pneumonia	0,2%	6,0%	93,8%

Tabela 2 – Acurácia da Rede Neural Convolutacional por classe

5.2.1.1 Normal

A RNC obteve 66,6% de sensibilidade nesta classificação, possuindo imprecisões na classe de Covid-19, o que pode vir a causar falsos positivos. Exemplos imagens classificadas pela rede demonstrada na Figura 14.



a) Imagem classificada como normal b) Imagem classificada com Covid-19

Figura 14 – Comparação entre raio X torácico normal

5.2.1.2 Covid-19

A RNC alcançou 88,4% de sensibilidade nesta classificação, mostrando que as características da Covid-19 foi aprendida pela rede, e resultado é importante, pois é possível afirmar que a detecção da Covid-19 é eficiente. Deste modo, é confirmado a hipótese alternativa, e atende a finalidade do trabalho. Exemplos imagens classificadas pela rede demonstrada na Figura 15.



a) Imagem classificada com Covid-19 b) Imagem classificada como normal c) Imagem classificada com Pneumonia

Figura 15 – Comparação entre raio X torácico com Covid-19

5.2.1.3 Pneumonia

A RNC teve 93,8% de sensibilidade nesta classificação, apresentando resultados excelentes de detecção e aprendizado. Exemplos imagens classificadas pela rede demonstrada na Figura 15.



a) Imagem classificada com Pneumonia b) Imagem classificada como normal c) Imagem classificada com Covid-19

Figura 16 – Comparação entre raio X torácico com Pneumonia

5.2.2 Precisão geral

Após o resultado da precisão da RNC por classe foi necessário saber a acurácia total da mesma, para ter-se a ciência de o quão promissor este trabalho pode ser. A Tabela 3 demonstra estes valores.

Normal	Covid-19	Pneumonia	Total
66,6%	88,4%	93,8%	82,9%

Tabela 3 – Acurácia da Rede Neural Convolutacional total

5.2.3 Discussão

Este estudo avaliou a eficácia da detecção da Covid-19 em imagens radiológicas torácicas através da Rede Neural Convolutacional. Os dados analisados evidenciaram a promissora possibilidade da utilização desta técnica, com a sensibilidade satisfatória para detectar a Covid-19 como também na acurácia da rede, confirmando a hipótese alternativa proposta. Esta solução apresenta ser viável para atender as necessidades presentes nos diagnósticos rápidos e abre possibilidades para a realização do exame de Covid-19 mesmo em hospitais que não possuam os exames a disposição.

Yadav et al. (2020) em seu trabalho obteve um melhor resultado em identificar imagens com Covid-19 com a utilização da arquitetura Inception V3 e algoritmo de otimização Estocástico Gradiente Descendente (EGD). Sua amostra foi composto com 14,197 imagens de raio-x, sendo 8,066 normais, 8,558 com pneumonia e 573 com covid, e todos os modelos foram treinados para 10 épocas.

Diferentemente, em nosso estudo, utilizamos 15 mil imagens, pareadas em 5 mil para cada diagnóstico radiológico, além do aprendizado de rede de 100 épocas, considerado um parâmetro mais confiável e que o torna uma rede mais robusta. Seu trabalho mostrou-se promissor, no entanto, um número pequeno de épocas pode ter sido uma limitação para a rede evidenciar melhor os resultados, pelo fato de que as arquiteturas comparadas possam ter diferenças na aprendizagem em suas estruturas de análise.

Em outro estudo, Heidari et al. (2020) comparou as imagens torácicas com e sem remoção das regiões do diafragma, o desempenho de classificação do modelo RNC mudou de 93,9% para 87,6% para a precisão da classificação geral, o que indica um aumento na acurácia ao remover a maioria das regiões do diafragma. Concluíram que a aplicação de aumento de dados, no treinamento é essencial, pois, influencia significativamente na precisão geral da classificação do modelo RNC, com a redução para cerca de 78%. No presente estudo não foi realizado a remoção das regiões do diafragma, o que pode ter implicado no resultado do nossa pesquisa. Trabalhar com segmentação e processamentos de imagens para retirar áreas e regiões desnecessárias ou que causem ruídos nas zonas pulmonares pode ser um importante modelo a ser seguido para futuras pesquisas.

Polsinelli, Cinque e Placidi (2020), diferentemente dos demais trabalhos apresentados, utilizaram de imagens de tomografias computadorizadas para a detecção das doenças. A RNC proposta pelo trabalho atingiu 83,00% de precisão. Mostrou-se mais eficiente em relação a outros *designs* de RNCs mais complexos. O tempo médio de classificação é baixo em um computador de última geração (1,25 segundos para uma única imagem de TC) e em um *laptop* de extremidade média (7,81 segundos para uma única imagem de TC). Isso demonstra que a RNC é capaz de analisar milhares de imagens por dia mesmo com recursos de *hardware* limitados.

A tomografia computadorizada (TC) demonstra ser uma alternativa válida para detectar COVID-19 com maior sensibilidade (FANG et al., 2020). Porém o presente trabalho utilizou de imagens torácicas pelo fato de serem mais acessível e usualmente encontrado em hospitais. Contudo a acurácia encontrada foi semelhante ao estudo com TC, o que pode evidenciar a importância da arquitetura presente na RNC em comparação com o tipo de imagem a ser utilizada.

A RNC proposta neste trabalho apresentou ótimos níveis para detecção da Covid-19 e Pneumonia, com sensibilidades superiores a 80% ,o que podem torná-los grandes auxiliares em pré diagnóstico com resultados mais rápidos, com acurácias semelhantes a outros testes para identificação do coronavírus, oferecendo uma alternativa para ajudar no combate contra a pandemia. É importante também analisar sobre as detecções da Covid-19 e Pneumonia, pois este é um desafio para algoritmos de visão computacional, visto que ele também provoca regiões brancas (líquidos, acúmulos de secreções) no pulmão, o que pode vir a causar falsas inferências na rede, além do fato de que a própria Covid-19 provoca também uma pneumonia.

Como limitação deste estudo foi identificado que houveram classificações errôneas, isto pode ter se dado pela qualidade técnica das imagens, como, por exemplo, a nitidez, saturação e posicionamento do paciente, assim como também a classificação incorretas das imagens por parte dos criadores das bases de dados. A falta de uma base de dados mais sólida, maior e com qualidade de padronização, ainda é um desafio para o desenvolvimento, a escolha do *batch normalization* também pode ter sido um problema para um melhor

resultado.

Contudo é importante salientar que o uso da tecnologia já se tornou essencial para o desenvolvimento dos diagnósticos em saúde. O uso de Inteligência Artificiais com RNC para detecção de doenças em imagens radiológicas já é estudado por diversas áreas. Essa aplicabilidade permite uma nova metodologia de diagnóstico com um aprofundamento na velocidade do resultado para o paciente, assim como a IA também permite que radiologistas priorizem os casos específicos, e que a triagem dos pacientes seja feita de forma mais eficiente, deste modo diminuindo a sobrecargas no trabalho dos profissionais de saúde, e consequentemente dando um melhor atendimento na assistência.

6 Conclusões

Pode-se concluir que este estudo atingiu os objetivos propostos a através da construção de uma rede neural convolucional para identificação da Covid-19 em imagens de raio-x torácicos, juntamente com criação de uma base de dados mais adequada metodologicamente, o que evidenciou ser eficiente e com acurácias esperadas.

A técnica mostrou-se promissora no atendimento dessa demanda, da insuficiência de testes em locais com poucos recursos. Portanto, pode ser indicado como instrumento complementar no diagnóstico médico no sistema de saúde pela sua eficácia e efetividade, além dos benefícios e facilidade para a sua implementação.

O resultado encontrado neste trabalho não apresenta melhoria significativa a outros trabalhos, porém afirma que está tecnologia tem muito a oferecer e ajudar no combate contra a Covid-19. Contudo, mais pesquisas são necessárias para superar as lacunas nos estudos existentes, com finalidade de atender de forma precisa as frequentes demandas na área da saúde.

6.1 Trabalhos futuros

Com o objetivo de melhorar a acurácia sugere-se trabalhar com seguintes técnicas:

- Síntese de imagens de Raios-X de problemas respiratórios utilizando redes neurais adversariais generativas, proposto por Santana e Barbosa (2020), para atender a demandas da escassez de base de dados reais.
- Viabilizar a detecção de diversas doenças pulmonares.
- Uso não somente de raio-x, mas também como tomografia e ultrassons.
- Trabalhar com arquiteturas já estabelecidas de RNC's, como VGG16, ResNet ou Inception
- Fazer sistema mobile para utilização medica nos hospitais.

Referências

AGARAP, A. F. An architecture combining convolutional neural network (cnn) and support vector machine (svm) for image classification. *arXiv preprint arXiv:1712.03541*, 2017. 20, 22, 25

AZEVEDO, A. L. *Conheça as vantagens e desvantagens dos diferentes tipos de teste para diagnosticar coronavírus*. 2020. Disponível em: <<https://oglobo.globo.com/sociedade/coronavirus-servico/conheca-as-vantagens-desvantagens-dos-diferentes-tipos-de-teste-para-diagnosticar-coronavirus-243419>>

CAETANO, R. et al. Desafios e oportunidades para telessaúde em tempos da pandemia pela covid-19: uma reflexão sobre os espaços e iniciativas no contexto brasileiro. *Cadernos de Saúde Pública*, SciELO Public Health, v. 36, p. e00088920, 2020. 18

CARNEIRO, T. et al. Performance analysis of google colab as a tool for accelerating deep learning applications. *IEEE Access*, IEEE, v. 6, p. 61677–61685, 2018. 33

FANG, Y. et al. Sensitivity of chest ct for covid-19: comparison to rt-pcr. *Radiology*, p. 200432, 2020. 43

FLOSS, M. et al. A pandemia de covid-19 em territórios rurais e remotos: perspectiva de médicas e médicos de família e comunidade sobre a atenção primária à saúde. *Cadernos de Saúde Pública*, SciELO Public Health, v. 36, p. e00108920, 2020. 16

GARCIA, M. *Testes de Covid voltam a cair em outubro; especialistas alertam que exames são essenciais para rastrear e frear avanço da pandemia*. 2020. Disponível em: <<https://g1.globo.com/bemestar/coronavirus/noticia/2020/11/19/testes-de-covid-voltam-a-cair-em-outubro-especialistas-alertam-que-exames-sao-essenciais-para-rastrear.html>>. 16

HE, K. et al. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 770–778. 29

HEIDARI, M. et al. Improving performance of cnn to predict likelihood of covid-19 using chest x-ray images with preprocessing algorithms. *arXiv preprint arXiv:2006.12229*, 2020. 29, 43

HORNIK, K. et al. Multilayer feedforward networks are universal approximators. *Neural networks*, v. 2, n. 5, p. 359–366, 1989. 19, 20

HU, B. et al. Convolutional neural network architectures for matching natural language sentences. In: *Advances in neural information processing systems*. [S.l.: s.n.], 2014. p. 2042–2050. 25

HUANG, G. et al. Densely connected convolutional networks. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 4700–4708. 29

- MS. *Sobre a doença*. 2020. Disponível em: <<https://coronavirus.saude.gov.br/sobre-a-doenca>>. 19
- MÜLLER, A. C.; GUIDO, S. et al. *Introduction to machine learning with Python: a guide for data scientists*. [S.l.]: "O'Reilly Media, Inc.", 2016. 33
- OMS. *Coronavírus*. 2020. Disponível em: <<https://www.who.int/health-topics/coronavirus>>. 18
- OMS. *WHO coronavirus disease (COVID-19) dashboard*. 2020. Disponível em: <<https://covid19.who.int/table>>. 16
- O'SHEA, K.; NASH, R. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*, 2015. 20, 24
- POLSINELLI, M.; CINQUE, L.; PLACIDI, G. A light cnn for detecting covid-19 from ct scans of the chest. *arXiv preprint arXiv:2004.12837*, 2020. 30, 31, 43
- SANTANA Ícaro; BARBOSA, S. M. Síntese de imagens de raios-x de problemas respiratórios utilizando redes neurais adversariais generativas. *Pró-Reitoria de Graduação (PROGRAD)*, Universidade Católica do Salvador, p. 60, 2020. 31, 45
- SHARMA, S. Activation functions in neural networks. *Towards Data Science*, v. 6, 2017. 26
- SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014. 28
- SMITH, S. W. et al. The scientist and engineer's guide to digital signal processing. California Technical Pub. San Diego, 1997. 21
- SZEGEDY, C. et al. Rethinking the inception architecture for computer vision. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 2818–2826. 29
- UOL. *Por prazo de validade, governo pode jogar fora milhões de testes*. 2020. Disponível em: <<https://noticias.uol.com.br/saude/ultimas-noticias/redacao/2020/11/22/jornal-por-prazo-de-validade-governo-pode-jogar-fora-milhoes-de-testes.htm>>. 16
- WANG, S. et al. Pathology image analysis using segmentation deep learning algorithms. *The American journal of pathology*, Elsevier, v. 189, n. 9, p. 1686–1698, 2019. 21
- WEI, Q. et al. Description of the first strain of 2019-ncov, c-tan-ncov wuhan strain—national pathogen resource center, china, 2020. *China CDC Weekly*, China CDC Weekly, v. 2, n. 6, p. 81–82, 2020. 18
- WU, S. et al. Convolution with even-sized kernels and symmetric padding. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2019. p. 1194–1205. 24
- WU, Z.; MCGOOGAN, J. M. Characteristics of and important lessons from the coronavirus disease 2019 (covid-19) outbreak in china: summary of a report of 72 314 cases from the chinese center for disease control and prevention. *Jama*, American Medical Association, v. 323, n. 13, p. 1239–1242, 2020. 18

- YADAV, S. S. et al. Analysis of deep machine learning algorithms in covid-19 disease diagnosis. *arXiv preprint arXiv:2008.11639*, 2020. 28, 42
- YOSINSKI, J. et al. Understanding neural networks through deep visualization. *arXiv preprint arXiv:1506.06579*, 2015. 22
- ZENG, L.-P. et al. Bat severe acute respiratory syndrome-like coronavirus wiv1 encodes an extra accessory protein, orfx, involved in modulation of the host immune response. *Journal of virology*, Am Soc Microbiol, v. 90, n. 14, p. 6573–6582, 2016. 18
- ZHENG, Y.-Y. et al. Covid-19 and the cardiovascular system. *Nature Reviews Cardiology*, Nature Publishing Group, v. 17, n. 5, p. 259–260, 2020. 16