

USO DE REDES NEURAS PARA CLASSIFICAÇÃO DA COVID 19 VIA IMAGEM DE TOMOGRAFIA COMPUTADORIZADA

**Fernando Cardoso Jardim (fernando.cardoso@souunit.com.br); Hugo Henrique
Correia da Silva (hugohenrique1998@gmail.com); Prof Msc. Roberto Felipe
Andrade Menezes (rmenezeseng@gmail.com)**

Com os acontecimentos advindos da pandemia ocasionada pelo COVID-19, popularmente conhecido como coronavírus, surgiu a necessidade de métodos de identificação da doença. Dentre os sintomas da doença está a debilitação do sistema respiratório, proveniente de uma pneumonia causada pela mesma. Exames de imagens, como raio-X do peito e tomografia computadorizada, vêm se revelando muito úteis para identificação dessa trágica doença. Diante disso, o intuito deste artigo é criar uma Rede Neural Convolutacional, também conhecida como CNN, para diagnosticar imagens de tomografia computadorizadas a partir de um dataset composto por exames de pacientes com pneumonias causadas por COVID-19, de outros tipos de pneumonias existentes e também pacientes saudáveis. A partir dos testes e das configurações adotadas para a rede, foram obtidos no melhor modelo os resultados de uma acurácia de 93% nos dados de validação, com a utilização de um filtro de imagem idêntico a Resnet 50. Conclui-se que a rede obteve bons resultados em diagnosticar o vírus a partir da tomografia computadorizada, podendo assim ser usada para diagnósticos reais em hospitais de todo o mundo, além de servir como base para pesquisas futuras, onde poderá ser possível obter melhores resultados ou diagnosticar mais tipos de pneumonia.

Palavras-chave: Rede Neural Convolutacional; Tomografia computadorizada; COVID-19.

ABSTRACT

With the events arising from the pandemic caused by COVID-19, popularly known as coronavirus, the need for methods of identifying the disease arose. Among the symptoms of the disease is the weakening of the respiratory system from pneumonia caused by the same. Imaging tests, such as chest X-rays and computed tomography, have proved to be very useful in identifying this tragic disease. Therefore, the purpose of this article is to create a Convolutional Neural Network, also known as CNN, to diagnose computed tomography images from a dataset composed of exams of patients with pneumonia caused by COVID-19, by other types of existing pneumonia and also healthy patients. From the tests and configurations adopted for the network, the results of 93% accuracy in the validation data were obtained in our best model, with the use of an image filter identical to Resnet 50. It is concluded that the network obtained good results in diagnosing the virus using computed tomography, so it can be used for real diagnoses in hospitals around the world, in addition to serving as a basis for future research, where it may be possible to obtain better results or diagnose more types of pneumonia.

Keywords: Convolutional Neural Network; computed tomography; COVID-19.

1 INTRODUÇÃO

Após crises de saúde como o ebola e o zika, muitos países do mundo tiveram problemas no controle e na eficiência para responder às emergências provocadas por elas. Em uma entrevista para BBC, no ano de 2016, o famoso bilionário e filantropo Bill Gates, cita como os países ainda estão fragilizados pelas últimas crises de saúde e como é importante que os mesmos possam estudar e desenvolver sistemas de saúde, que estejam preparados e consigam responder a possíveis cenários pandêmicos que venham a surgir no futuro (BBC, 2016).

No ano de 2019, houve a aparição de um novo vírus da gripe, o SARS-CoV-2, causador do Covid-19. Em março de 2020, a Organização Mundial da Saúde (OMS), confirmou que o número de casos da nova doença já havia ultrapassado 214 mil casos em todos os continentes. No entanto, sem a existência de algum plano estratégico, fez-se necessário o uso de medidas semelhantes aos de vírus da gripe do tipo influenza (FREITAS, 2020). Em dezembro do mesmo ano, o número de casos aumentou para mais de 65 milhões de casos confirmados e com mais de um milhão e meio de mortes pelo vírus (WHO, 2020).

Existem variáveis que dificultam o diagnóstico dessa doença, desde a época da coleta de amostra, período de infecção e método de diagnóstico aplicado. Os métodos com os maiores destaques são os de exames de imagens e o PCR em tempo real (RT-qPCR), mesmo este último apresentando casos de falsos negativos (MAGNO, 2020). Embora os exames de imagem como Tomografia Computadorizada (TC) do tórax, no início, não fossem recomendados como primeiro método a ser testado em caso de suspeita, novos estudos apontam que o uso de tecnologia de inteligência artificial, como redes neurais, apresentam avanços na detecção da doença com uma grande sensibilidade e uma grande acurácia (ARAUJO FILHO, 2020).

Este trabalho tem como objetivo criar uma Rede Neural Convolutacional (Convolutional neural network - CNN) capaz de classificar três grupos de imagens de TC, os de pacientes com Covid-19, os que têm algum tipo de pneumonia e os pacientes que não têm nenhuma doença.

2 DESCRIÇÃO DE PROBLEMA

No início do ano de 2019, surgiu na China um novo vírus chamado Coronavírus 2 da Síndrome Respiratória Aguda Grave (SARS-CoV-2), causando a Covid-19. Rapidamente este vírus se disseminou entre os outros países gerando uma pandemia com graves crises nos sistemas de saúde de todo o mundo.

Pela necessidade de métodos para diagnosticar pacientes com a doença, vários médicos e pesquisadores mobilizaram-se por todo o mundo, chegando aos métodos de reação em cadeia da polimerase e transcriptase reversa-PCR, também denominadas de PCR e RT-PCR, respectivamente. Porém, resultados negativos destes testes não excluem o diagnóstico por Covid-19, pois a carga viral e a sensibilidade das amostras para detecção do vírus variam (WANG, 2020).

Estudos posteriores identificaram a presença do Covid-19 em exames de TC e raio-X, porém os pacientes tinham apresentado RT-PCR negativo e a comparação da sensibilidade entre esses exames mostraram uma eficiência de 98% para a

1 tomografia, e 71% para o RT-PCR (XIE, 2020; FANG, 2020). Sendo assim, com o
2 auxílio de redes neurais, um novo método de detecção dessa doença de forma
3 eficiente e rápida vem sendo desenvolvido por pesquisadores no mundo inteiro para
4 se criar um modelo de visão computacional e reconhecimento de padrões capaz de
5 auxiliar na decisão desse diagnóstico.

6 A TC é um procedimento rápido, assistido e manuseado por computador, que
7 tem vantagem sobre o raio-X, por ser um exame mais preciso, oferecendo mais nitidez
8 nas imagens geradas, garantindo uma maior distinção entre os tecidos e as anomalias
9 formadas pela Covid-19, como a anomalia multifocal organizada, distorção
10 arquitetônica em distribuição periférica pulmonar e presença de opacidades
11 conhecidas como vidro fosco (ARAUJO FILHO, 2020). Além disso, o exame é
12 realizado capturando várias imagens separadas podendo ser analisada da mesma
13 maneira que o raio X quanto de forma 3D por alguns programas.

14 3 TRABALHOS RELACIONADOS

15 Nesta seção são apresentados os principais trabalhos tomados como base para
16 a criação do modelo de rede e do tratamento de imagem, onde foi levado em conta os
17 tipos de pré-processamento de imagem e modelos de redes já feitos, e as
18 características de cada um.

19 3.1 Pré-processamento de imagem

20 Alguns artigos foram publicados como resultado das buscas por soluções
21 diferentes para problemas relacionados à classificação de imagem. Nesses
22 problemas, o pré-processamento é uma das etapas mais importante e imprescindível,
23 mas não se tem uma ideia de qual o melhor pré-processamento de imagem, pois varia
24 de caso a caso.

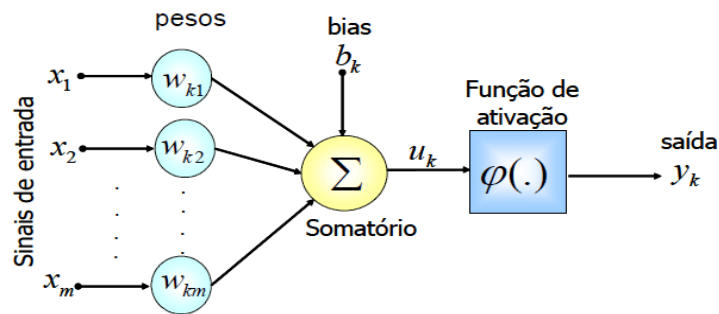
25 Existem alguns pré-processamentos mais utilizados que outros, os quais
26 constantemente são encontrados nos artigos, a exemplo da normalização dos dados,
27 usada principalmente para impulsionar o processamento. Nos artigos de Bai *et al.*
28 (2020) e Silva *et al.* (2020), é utilizada a normalização dos valores de pixels das
29 imagens para alcançar mais velocidade nos seus algoritmos.

30 Além disso, outro pré-processamento de imagem bastante utilizado antes do
31 treinamento é o *re-scale*, onde as dimensões imagens são alteradas, e, regularmente,
32 essas são padronizadas no formato quadrado (mesma altura e mesma largura). Nos
33 trabalhos de Narin *et al.*(2020), Bai *et al.*(2020) e Asif *et al.*(2020) os dados foram
34 readaptados para serem usados com um modelo pré-treinado alterando seu tamanho
35 para 228x228 pixels. Já no trabalho de Silva, Ferreira e Araújo (2020), o intuito deste
36 processamento foi alcançar menos custo computacional, fazendo essa mesma
37 redução para valores de 75x75 pixels.

38 Outro método bastante utilizado é o *Data Augmentation* (DA), sendo uma
39 ferramenta disponibilizada pelo *TensorFlow* em Python. Sua vasta aplicação é devido
40 a sua versatilidade na manipulação de imagens, no qual elas podem ser rotacionadas,
41 ampliadas, recortadas e reformatadas com padrões de modelos famosos. Além disso,
42 é possível, aplicar filtros, alterar o contraste, equalizar, entre outras formas de
43 modificação, mostrado na Figura 1.

1

Figura 2 - Modelo de um neurônio artificial



2

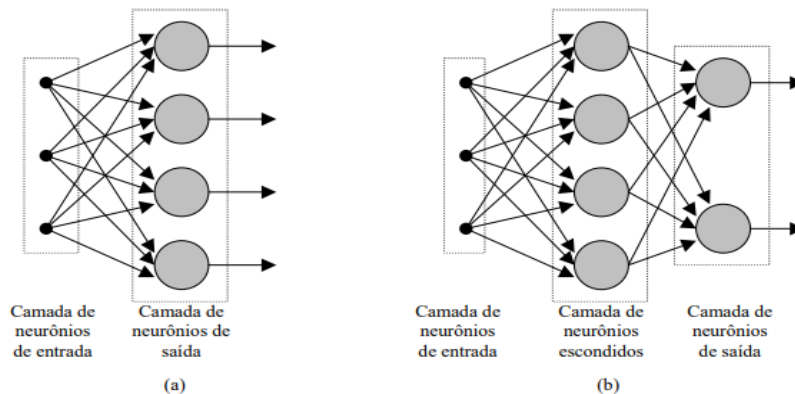
3

Fonte: Soares (2011)

4 transformação não-linear com a entrada, possibilitando a capacidade da rede de
 5 aprender e executar tarefas mais complexas. No entanto, existe uma diversa
 6 quantidade de funções de ativação, dentre elas as mais conhecidas e utilizadas são o
 7 degrau, linear, *sigmoid*, softmax e a *ReLU* (DSA, 2019).

8 Ampliando o conceito dos perceptrons, surgiu as redes neurais multicamadas ou
 9 *Multi Layer Perceptron* (MLP), exemplificado na Figura 3, que representa uma rede
 10 contendo uma ou mais camadas ocultas com vários neurônios, onde os sinais dessas
 11 camadas ocultas não podem ser previstos (MOREIRA, 2018).

12 Figura 3 - Diagramas de redes neurais em camadas: (a) rede com apenas duas camadas de
 13 neurônios, (b) MPL com uma camada de entrada, uma camada oculta e uma camada de
 14 saída.



15

16

Fonte: Masato (2000)

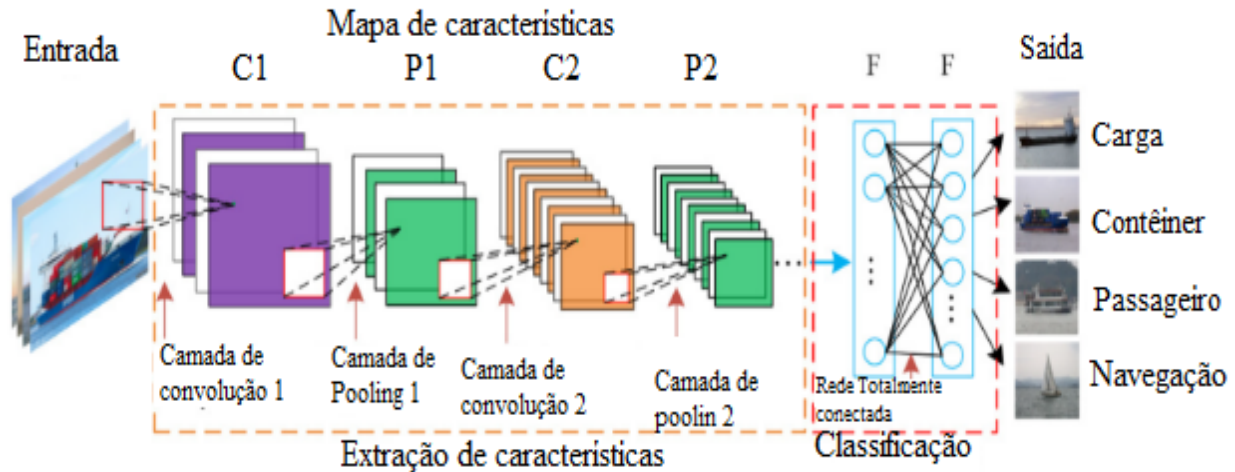
17 O algoritmo de aprendizagem mais utilizado é o *backpropagation*, ele é um
 18 algoritmo que atualiza os pesos dos neurônios da rede a partir do erro presente na
 19 saída da MLP, corrigindo primeiro os valores das últimas camada para depois corrigir
 20 os das camadas iniciais (LEITE, 2018).

21 3.3 Rede Neural Convolutacional

22 Uma Rede Neural Convolutacional ou do inglês *Convolutional Neural Networks*
 23 (CNN), é uma das técnicas mais comumente aplicadas em tarefas de visão
 24 computacional (GIRELI; LUÍS, 2020). Isso se deve ao fato de existirem algumas
 25 camadas especiais nesse modelo que possuem funções de extração de

1 características, a camada convolucional, a camada *pooling* e a camada *flatten*. Na
 2 Figura 4, tem-se um exemplo visual de como os dados se comportam ao passar pelas
 3 camadas da CNN.

4 Figura 4 - Camadas de uma CNN.



5

6

Fonte: Ren (2019)

7 Como visto na Figura acima, a camada de convolução é responsável por
 8 aplicação de filtros que podem ou não extrair características detectáveis pela rede. Já
 9 a camada de *max pooling* fica responsável por amplificar os pontos mais significativos
 10 das imagens pós filtragem, tornando-os mais perceptíveis pela rede. Por último, a
 11 imagem passa pela camada *flatten*, esta que transforma as informações já extraídas
 12 em formato de vetor para aplicação na rede neural, neste caso apenas se tem a
 13 camada de saída, mas é possível ser uma MLP (BRANDIZZI, 2020).

14 3.4 Modelos de rede com tomografia computadorizada e raio-X


15 No treinamento das redes, as camadas iniciais dos sistemas tendem a extrair as
 16 mesmas características pois são mais simples. Com esse conceito surgiram grandes
 17 redes treinadas a partir de gigantescos bancos de dados de imagens, como por
 18 exemplo a Imagenet, onde se utiliza os parâmetros já treinados e existentes dessas
 19 redes nas camadas iniciais, e são criadas camadas mais profundas para
 20 características mais complexas e de ajustes finos, como analisado por Vasani (2019).

21 Essas redes pré-treinadas são comumente utilizadas para facilitar os trabalhos,
 22 sem ter a necessidade de treinar uma rede novamente. Trabalhos envolvendo raio-X
 23 e TC tendem por utilizar modelos de pré-treinos, sendo os mais utilizados a Resnet,
 24 Alexnet e o VGG, modificando ou não o número de camadas existentes e utilizando
 25 funções de classificação como *sigmoid*, *softmax* e suas variáveis, como apresentado
 26 por Afshin *et al.*(2020). Na Figura 5 é possível ver um exemplo do diagrama de uma
 27 rede pré-treinada.

28 Já no trabalho de Ahammed *et al.*(2020), é analisado o fato de que algumas
 29 redes pré-treinadas não são tão compatíveis com imagens de escala cinza para a
 30 detecção de COVID-19.

1

Figura 5 - Diagrama da CNN Alexnet



2

3

Fonte: Ling (2019)

4 METODOLOGIA


Na busca de atingir os objetivos deste trabalho, as etapas tomadas foram, aquisição de um banco de dados de imagens de TC para as classificações em questão, criação de um modelo de rede neural convolucional e definição de métricas de desempenho desejados.

4.1 Banco de dados utilizados

O conjunto de imagens utilizado neste trabalho foi retirado de um *dataset* construído a partir do CC-CCII, ou Consórcio Chinês de Investigação de Imagens de TC de Tórax (CNCB, 2020). Esse *dataset* é constituído de 617.775 imagens de 4.154 pacientes diagnosticados com a Nova Pneumonia por Coronavírus (NCP), Outras Pneumonias (CP) ou Pessoas Saudáveis (Normais). Na Figura 6 é possível observar uma visualização dos exames utilizados neste presente trabalho.

Figura 6 - Frames de TC: (A) de uma pessoa normal, (B) de uma pessoa com outras pneumonias e (C) uma pessoa com Covid.

17



18

19

Fonte: Autoria Própria

Para a criação do modelo utilizado, foram escolhidos, de forma aleatória, 450 pacientes da base original. Além disso, devido ao fato de o exame de TC ser em formato de vídeo, foi necessário a obtenção de imagens de frames de cada exame, resultando em 28.242 imagens da nova base gerada. Para o treinamento, foram selecionados 100 pacientes de cada doença, outras 25 para validação e outras 25 para teste, no Quadro 1 temos uma visualização melhor das quantidades utilizadas.

25

1 Quadro 1 - Quadro do número de amostras usadas para o treinamento e validação das
 2 RNAs.

Classes	Nº de Pacientes	Nº de amostras de treinamento	Nº de amostras de validação	Nº de amostras de testes
Normal	150	100	25	25
Covid	150	100	25	25
CP	150	100	25	25
Total	450	300	75	75

3 Fonte: Autoria Própria

4 As imagens deste *dataset* já vêm no formato 512x512 pixels, e também já
 5 passaram por um filtro de escala cinza e um ajuste no contraste. Contudo, foi realizado
 6 um pré-processamento das imagens (64x64 pixels) e aplicado algumas funções do
 7 DA para prevenir problemas de *overfitting*.

8 Dentre essas funções do DA, foram utilizadas a mudança da posição de largura
 9 e altura até 20% do valor original, ampliação de até 30% da imagem, rotação em até
 10 50°, alteração de brilho de 20% a 100%, normalização dos pixels, inversão da imagem
 11 no eixo horizontal e processamento de imagem para padrões de CNN's famosas em
 12 classificação de imagens (Resnet 50, Densenet e Xception). Alguns desses exemplos
 13 podem ser vistos na Figura 7.

14 Figura 7 - Aplicações do *Data Augmentation*.



15

16

Fonte: Autoria própria

17 Inicialmente todas as funções citadas anteriormente foram adicionadas durante
 18 o treinamento, com exceção da padronização das imagens chamada de pré-
 19 processamento. Esse último veio após alguns treinamentos, por último, o DA foi
 20 modificado para diminuir o número de modificações nas imagens e melhorar o
 21 aprendizado.

22 Os rótulos foram transformados no formato *dummy*, um formato ideal para
 23 rótulos categóricos e primordiais para um problema de classificação com RNA's por
 24 apresentar um formato probabilístico compatível com a saída da rede. Primeiro cada
 25 rótulo recebe um valor entre 0 e 2, um para cada classe existente (NCP, CP e
 26 NORMAL), e logo após eles sofrem uma transformação binária em um vetor de três
 27 posições, e cada uma representa um valor anteriormente recebido. No Quadro 2, é
 28 possível observar um exemplo visual dessa alteração.

1

Quadro 2 - Variáveis *dummy*.

0	(1,0,0)
1	(0,1,0)
2	(0,0,1)

2

Fonte: Autoria Própria

3

4.3 Plataforma de desenvolvimento

4

Com o avanço tecnológico e a grande quantidade de RNAs criadas em diferentes linguagens de programação e métodos, surgiram facilitadores que auxiliam na criação de uma rede sem ter a necessidade de criar todas as etapas de aprendizagem, tornando assim mais simples e prática a utilização dessas redes neurais. Neste projeto, a rede neural foi criada a partir da linguagem de programação *Python*, utilizando os softwares *Anaconda* e *JupyterLab* para a compilação dos códigos, e o *TensorFlow* e *Keras*, como bibliotecas essenciais para criação dos modelos.

11


4.4 Modelos de rede neural utilizado

12

Os modelos aplicados nestes trabalhos foram de diversas configurações de CNNs conhecidas. Desde modelos padrões de CNNs até modelos com pré-treinamento foram aplicados, na busca de um resultado satisfatório. Entretanto, as imagens usadas nas redes foram limitadas a 64x64 pixels, e as sem pré-treinamento mantiveram a condição de três camadas, sendo que todas repetiam a sequência de *convolução*, *dropout*, *max pooling* e *dropout*, finalizando toda essa estrutura com uma camada *flatten* que conectava a rede MLP. O *dropout* foi definido com o valor de 0,3 e a rede neural densa teve sua estrutura interna bastante modificada até chegarmos ao melhor modelo encontrado na Figura 8.

21

Figura 8 - Estrutura do modelo de rede neural desenvolvida.



22

23

Fonte: Autoria própria

24

Como visto, a rede densa criada é composta de uma camada de entrada de 256 neurônios, seguida de duas internas de 128 neurônios, uma última interna de 64 neurônios e a de saída com 3 neurônios indicando as classes determinadas no dataset. Vale ressaltar que entre essas camadas internas também foi aplicado o método de *dropout*, correspondente ao das camadas de convoluções. Além disso, o número de épocas foi de 300, no entanto os melhores resultados das redes foram

1 salvos independentemente do número de épocas, baseado nos melhores valores de
2 acurácia nos dados de validação.

3 Para as redes com pré-treinamento, apenas as camadas de convolução eram
4 invocadas com os pesos já treinados, retirando-se o chamado “topo” da rede e
5 aplicando diversos tipos de MLP’s, incluindo a configuração vista na Figura 8. O
6 *dropout* seguiu a mesma configuração anterior.

7 Em todos os modelos as principais funções de ativação para as camadas de
8 saída foram a *softmax* e *sigmoid*, pelo fato de serem melhores em classificação de
9 multiclases. Já para as outras as camadas em conjunto, utilizou-se as funções ReLu,
10 elu, *hard sigmoid* e *swish*.

11 O otimizador selecionado para essa aplicação foi o *Adam*, uma versão
12 melhorada do *Stochastic Gradient Descent*, por apresentar melhor comportamento e
13 eficiência no aprendizado, facilitando a alteração do *learning rate*.

14 **4.5 Indicadores e Métricas de desempenho**

15 Com o objetivo de obter informações da rede e dos métodos de treinamento
16 aplicados e demonstrados nos tópicos anteriores. Neste tópico será apresentado
17 todos os indicadores e métricas usados no trabalho, com o objetivo de obter
18 informações da rede e dos métodos de treinamento aplicados e demonstrados nos
19 tópicos anteriores. Os indicadores utilizados são a função custo, a *Categorical*
20 *Crossentropy*, a acurácia, a precisão, o Indicador AUC, a sensibilidade e a
21 especificidade.

22 **4.5.1 Função de custo**

23 A função de custo determina a distância entre a resposta da classificação
24 fornecida pela rede do rótulo (resposta verdadeira). Existem algumas funções
25 especiais que conseguem fazer essa avaliação, porém, devido a natureza dos dados,
26 foi escolhida a função *Categorical Crossentropy*. Essa função espera os rótulos no
27 formato *dummy*, pois quando o índice de maior valor da predição é próximo ao maior
28 índice do rótulo, o valor binário 1 e o cálculo de custo é calculado com.

$$29 \quad L = -\sum y_i \ln \hat{y}_i \quad (1)$$

30 Em que L é o valor da função custo, y_i é o valor do rótulo, enquanto \hat{y}_i é o valor
31 atribuído pela classificação i da rede, sendo que quanto mais próximo de 1, mais o
32 custo tende a zero (PELTARION, 2020).

33 **4.5.2 Acurácia**

34 A acurácia, ou exatidão, representa o quão próximos os valores classificados
35 estão dos valores reais. Isso vale para os valores ditos positivos, aqueles que são
36 determinantes da classe (maior valor dentre a classificação), ou dos negativos,
37 determinantes de não classe (menores valores), Se a classificação for feita de forma
38 correta tem-se os verdadeiros positivos. Porém, se a classificação for feita de forma
39 incorreta tem-se os falsos positivos. Além disso, também existem os verdadeiros
40 negativos e falsos negativos, usados para medir o quanto que a RNA classificou os

1 negativos de forma correta ou errada. A acurácia é baseada nessa relação existente
2 entre os dois tipos de métricas e é calculada por (2) (KERAS, 2020).

$$3 \text{ Acurácia} = \frac{TP+TN}{TP+FP+TN+FN} \quad (2)$$

4 Onde TP é o número de Verdadeiros Positivos, FP é o número de falsos
5 negativos, o TN é o número de verdadeiros negativos e FN é o número de falsos
6 negativos.

7 **4.5.3 Precisão**

8 A precisão é o quão próximos estão os valores classificados pela rede em
9 relação aos rótulos, nesse caso apenas são consideradas as métricas positivas. A
10 equação usada para esse cálculo é representada por (3) (KERAS, 2020).

$$11 \text{ Precisão} = \frac{TP}{TP+FP} \quad (3)$$

12 **4.5.4 Indicador AUC**

13 O indicador AUC, do inglês *Area Under the ROC Curve*, ou área sob a curva
14 ROC, é área abaixo da curva da métrica chamada ROC (*Receiver Operating*
15 *Characteristic* ou Características Operacionais do Receptor), que nada mais é que um
16 gráfico que revela o desempenho de um modelo em todos os limites de classificação
17 através da taxa de verdadeiros positivos (TPR) e da taxa de falsos positivos (FPR)
18 disponibilizada através da resposta da rede e calculadas através de (4) e (5).

$$19 \text{ TPR} = \frac{TP}{TP+FN} \quad (4)$$

$$20 \text{ FPR} = \frac{FP}{FP+TN} \quad (5)$$

21 A curva ROC é construída pelo gráfico TPR x FPR em diferentes limiares de
22 classificação. Caso seja reduzido o limite de classificação mais itens serão
23 classificados como positivos (verdadeiros ou falsos) e o gráfico irá evoluindo.
24 Entretanto não se torna viável o cálculo dos pontos da curva ROC, sendo utilizada a
25 métrica AUC.

26 A AUC é um cálculo integral dessa curva, pois assim temos uma medida de
27 desempenho em todos os limites de classificação. Entre outras palavras, a AUC é uma
28 probabilidade de que o modelo classifique um positivo aleatório com valor mais alto
29 do que um negativo aleatório, e quanto mais próximo um classificador tem AUC de
30 um, mais corretas são as previsões deste modelo (MLCC, 2020).

31 **4.5.5 Sensibilidade**

32 A sensibilidade da RNA é uma métrica que retorna à proporção da quantidade
33 de casos positivos que foram identificados de forma correta. Ela é calculada através
34 de (6):

$$35 \text{ Sensibilidade} = \frac{TP}{TP+FN} \quad (6)$$

1 4.5.6 Especificidade

2 Assim como a sensibilidade, a especificidade também é uma métrica de
3 proporção, mas de casos negativos. Ela é calculada usando (7):

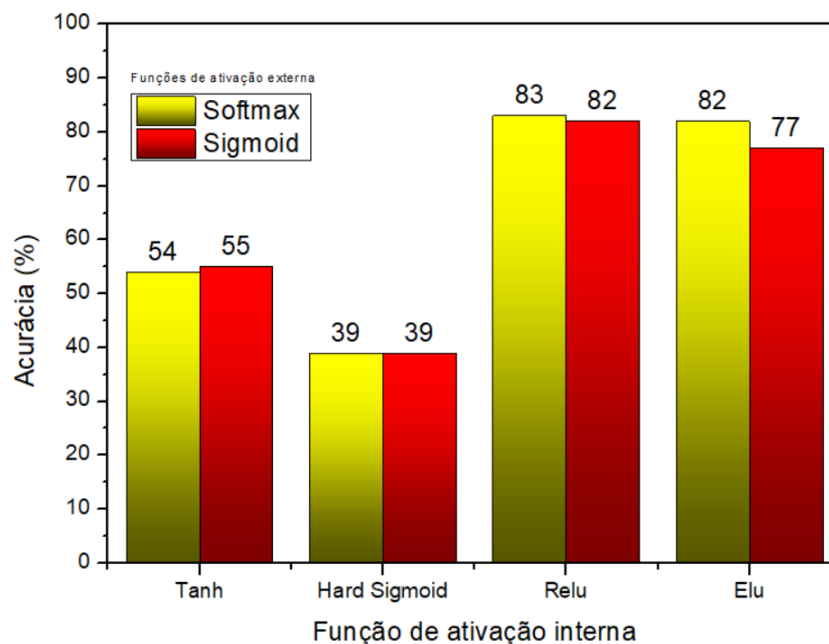
$$4 \text{ Especificidade} = \frac{TN}{TN+FP} \quad (7)$$

5 5 RESULTADOS E DISCUSSÕES

6 5.1 Variando as funções de ativação

7 Após alguns testes iniciais, foi obtido o primeiro modelo treinado com valores
8 satisfatórios, usando as funções de ativação ReLu, nas camadas escondidas, e
9 *softmax* na camada de saída, e alcançou-se 83% de acurácia. Em seguida, foi
10 realizada uma busca por outras funções de ativação que pudessem ter melhores
11 resultados. Na Figura 9 é possível ver os resultados encontrados.

12 Figura 9 - Acurácia máxima dos modelos de CNN comuns, com diferentes combinações de
13 funções de ativação.



14

15

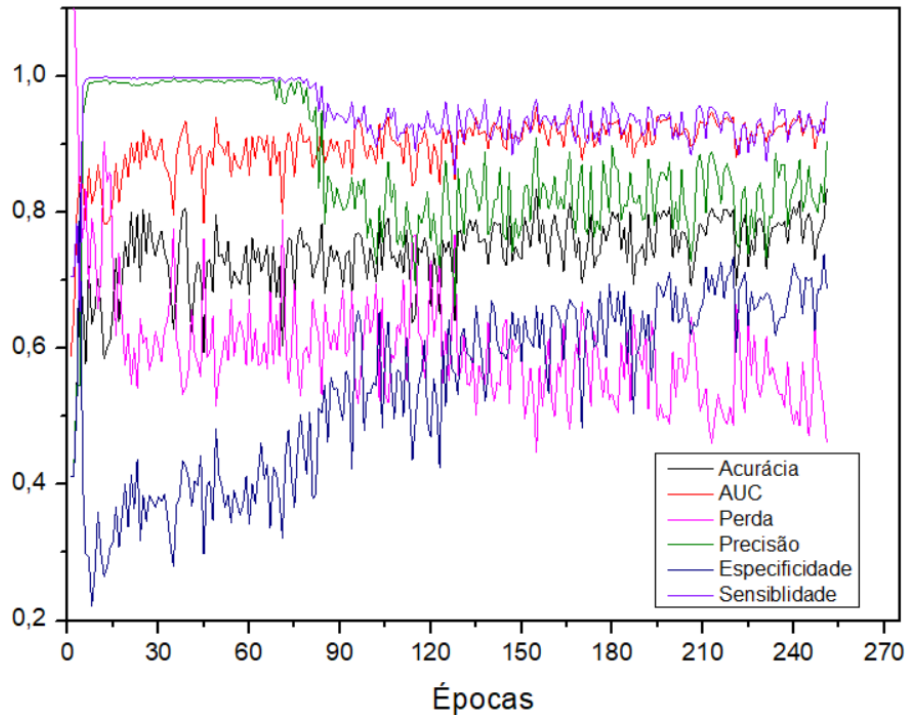
Fonte: Autoria própria

16 Como esperado o melhor arranjo foi o primeiro testado, pois é muito comum o
17 uso da *softmax* na camada de saída em casos de multiclass, devido a mesma
18 apresentar excelentes resultados. Consequentemente a ReLu tem um comportamento
19 parecido com a *softmax*, logo tem uma adaptabilidade parecida com esse tipo de
20 problema.

21 Os parâmetros adicionais para avaliar o desempenho da melhor rede dessa
22 etapa podem ser vistas no Figura 10, em sequência. Nele vemos a evolução do modelo
23 na perspectiva das outras métricas, até a época do melhor resultado.

1 Nota-se que todos os indicadores apresentam um comportamento ruidoso,
 2 sendo isso explicado pelo fato de ter sido usado um valor de taxa de aprendizagem de
 3 0,1. Mesmo que o otimizador reduza esse valor com o passar do tempo, ainda assim
 4 a variação persiste.

5 Figura 10 - Evolução da melhor CNN com as funções de ativação ReLu e *sigmoid*, com
 6 todos as métricas analisadas.



7

8

Fonte: Autoria própria

9 O melhor conjunto de pesos encontrados foi na época 251, e é possível observar
 10 no Quadro 3, todos os valores obtidos.

11

Quadro 3 - Métricas finais da CNN comum.

Acuracia	AUC	Perda	Precisão	Especificidade	Sensibilidade	Épocas
0,836	0,948	0,461	0,905	0,688	0,964	251

12

Fonte: Autoria própria

13 Pode-se analisar que os valores estão bem próximos do ideal (igual a 1,000),
 14 entretanto a especificidade e a perda estão mais longe quando comparados a outras
 15 métricas. Por isso continuou-se a busca por métodos que tivessem melhor
 16 desempenho

17

5.2 Pré-treinamento e pré-processamento

18

19

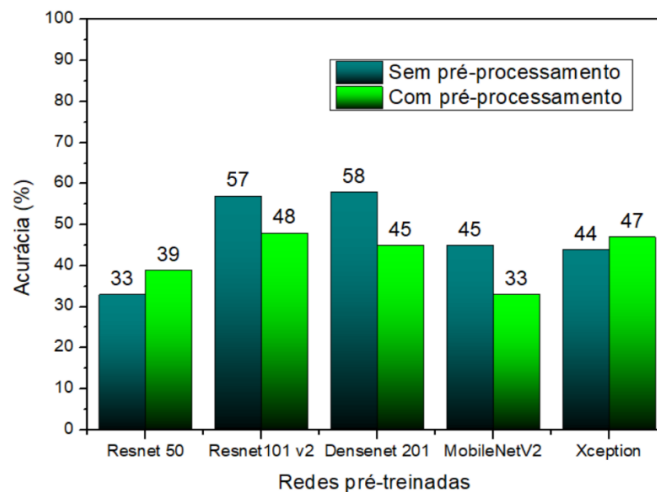
20

Na Figura 11, tem-se os resultados da acurácia dos dados de validação usando a técnica de pré-treinamento, com e sem pré-processamento das imagens, onde, no primeiro caso, cada rede teve seu pré-processamento aplicado. Observa-se que

1 aconteceu um retrocesso no aprendizado do modelo, já que o melhor resultado dessa
 2 etapa foi de 58%, sem o pré-processamento da imagem e usando os pesos da rede
 3 Densenet 201.

4 Esse fato pode ser explicado, por dois motivos, o primeiro é que as redes originais
 5 testadas no trabalho foram treinadas com imagens com diferentes formatos.

6 Figura 11 - Acurácia máxima dos modelos de CNN com pré-treinamento, alguns com pré-
 7 processamento das amostras.



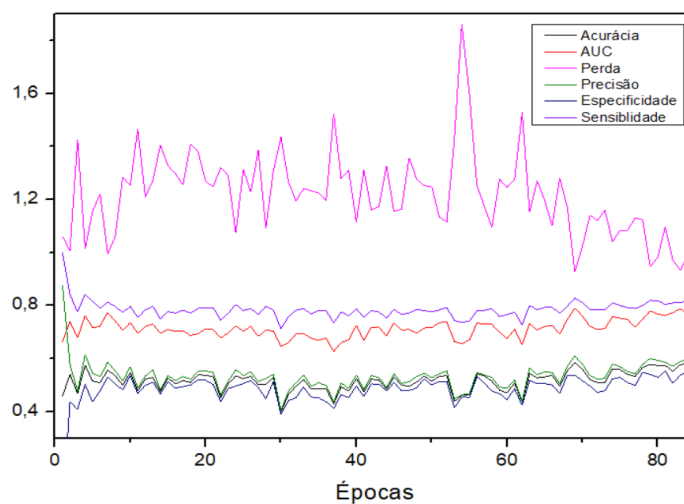
8

9

Fonte: Autoria própria

10 As imagens continuam 228x228 *pixels*, alguns modelos também usavam segmentação
 11 e inicialmente não estavam em escala cinza. O segundo fato é na verdade um
 12 complemento do primeiro, já que foi constatado por (AHAMMED, 2020) que as
 13 imagens em escala cinza não tem boa compatibilidade com as redes CNN pré-
 14 treinadas. Temos no Figura 12, a evolução do melhor modelo desta etapa com seus
 15 devidos parâmetros.

16 Figura 12 - Evolução da CNN com somente o pré-treinamento da Densenet 201, com todas
 17 as métricas analisadas.



18

19

Fonte: Autoria própria

1 Se comparado com o modelo com o pré-processamento, a evolução desse
 2 modelo foi menos ruidosa e teve um amortecimento muito rápido do seu aprendizado,
 3 sendo uma consequência da ineficiência da adaptação dos pesos ao problema de
 4 classificação. Assim, o melhor valor de acurácia foi atingido na época 84, mas valores
 5 próximos dele já foram alcançados nas primeiras 10 épocas e perdurou estável até o
 6 final do treinamento. No Quadro 4, temos os parâmetros finais desta experiência.

7 Quadro 4 - Métricas finais da CNN com somente o pré-treinamento da Densenet 201.

Acuracia	AUC	Perda	Precisão	Especificidade	Sensibilidade	Épocas
0,586	0,770	0,989	0,599	0,549	0,816	84

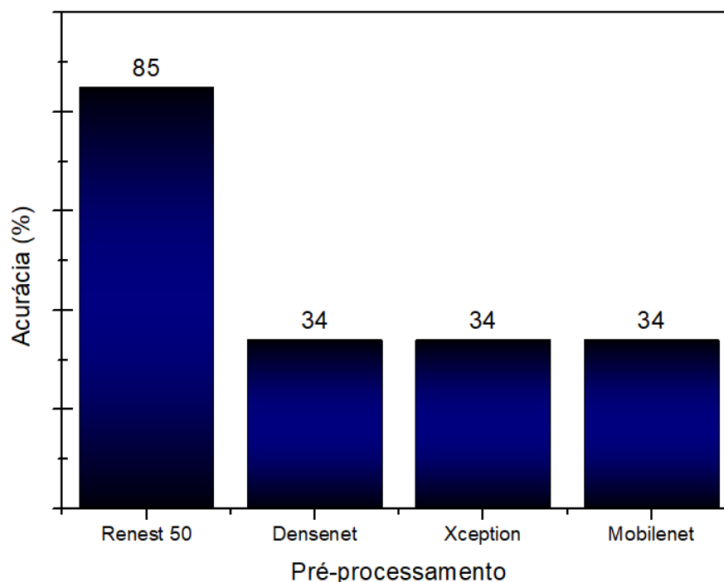
8 Fonte: Autoria própria

9 A sensibilidade foi o parâmetro que chegou mais próximo do ideal. Porém,
 10 observando os outros parâmetros, observa-se que a rede ainda apresenta dificuldade
 11 para a classificação de maneira adequada. Com isso, para promover o
 12 aperfeiçoamento da rede, é preciso adequá-la ainda mais.

13 5.3 Pré-processamento sem o pré-treinamento

14 Nessa etapa foram treinadas as redes só com o pré-processamento e a rede
 15 CNN já indicada. Os resultados dessa etapa podem ser vistos no Figura 13, onde há
 16 um destaque no pré-processamento utilizando o filtro da Resnet 50, onde foi atingido
 17 85% de acurácia.

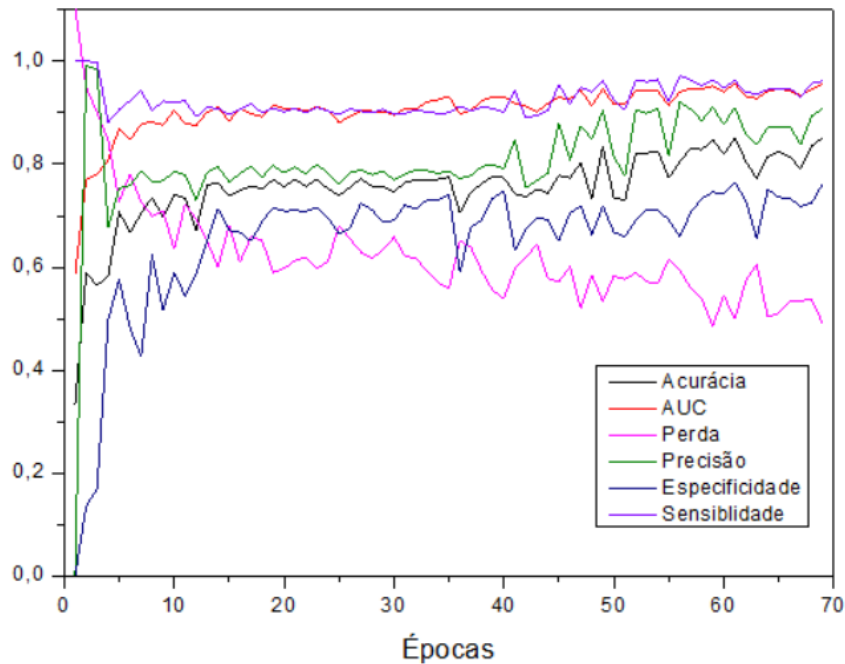
18 Figura 13 - Acurácia máxima dos modelos de CNN com os seus respectivos pré-
 19 processamentos das amostras.



20
 21 Fonte: Autoria própria

22 Percebe-se, na Figura 14, a evolução desse modelo na visão de outros
 23 parâmetros para o filtro Resnet 50.

1 Figura 14 - Evolução da CNN com somente o pré-processamento da Resnet, com todas
 2 as métricas analisadas.



3

4

Fonte: Autoria própria

5 Nota-se que o desenvolvimento dessa rede se assemelha aos das anteriores, de
 6 forma ruidosa, e logo nas épocas iniciais temos uma rápida convergência. Apesar de
 7 alcançar um valor próximo da primeira melhor rede dessa pesquisa, alcançando
 8 apenas 2% a mais na acurácia, precisa-se considerar a velocidade já que o resultado
 9 foi alcançado com 71 épocas, demonstrando uma maior eficiência na extração das
 10 características das amostras. A seguir, no Quadro 5, tem-se os parâmetros finais
 11 dessa rede.

12 Quadro 5 - Métricas finais da CNN com somente o pré-processamento da Resnet.

Acuracia	AUC	Perda	Precisão	Especificidade	Sensibilidade	Épocas
0,851	0,955	0,489	0,908	0,762	0,961	71

13

Fonte: Autoria própria


14 É perceptível que os outros parâmetros têm uma ligeira melhoria, principalmente
 15 no AUC, precisão e especificidade, se comparados ao da primeira rede. Entretanto, a
 16 perda nessa rede foi maior, mas apresentando uma pequena melhoria. Logo, é preciso
 17 fazer um ajuste fino nos parâmetros da rede.

18 5.4 Rede final e redução do DA

19 Nessa última etapa foram feitos alguns ajustes no parâmetro de taxa de
 20 aprendizado da rede e reduziu-se as modificações feitas pelo DA. O primeiro foi
 21 reduzido a 0,04, e o mesmo já apresentou resultados significativos, alcançando 89%
 22 de acurácia, sendo o seu comportamento visto na Figura 15 através da curva na cor

1 preta. Junto a essa modificação, a redução do DA para a alteração das imagens
 2 também foi implementada e é representada também na Figura 15 através da cor
 3 vermelha. Ressalta-se que foi colocado na imagem todo o comportamento de 300
 4 épocas, mas a rede final foi salva com o melhor valor de acurácia nos dados de
 5 validação.

6 Figura 15 - Evolução da acurácia das CNN's finais, ambas com pré-processamento Resnet
 7 mas com modificações nos parâmetros internos.



8

9

Fonte: Autoria própria


10 A melhoria adicionada ao modelo deu um impulso que finalmente alcançou um
 11 resultado satisfatório. Notou-se que o DA demasiado estava impedindo o
 12 desenvolvimento da rede em vez de ajudar na generalização, confundindo a extração
 13 de característica da rede. Com a retirada desse obstáculo, tem-se um pico de 93% de
 14 acurácia na validação. Outro ponto a se notar é que, a partir da época 200, o modelo
 15 comum (sem a redução do DA) apresentou uma queda no aprendizado, revelando
 16 uma barreira de evolução do modelo. Na figura 16 é mostrada a evolução do modelo
 17 modificado e seus parâmetros.

18 É visível que a evolução desse modelo é um pouco mais lenta, pois a estabilidade
 19 é alcançada próxima da época 60, e seu pico surgiu apenas na época 184. Mesmo
 20 com a redução da taxa de aprendizagem, os ruídos da rede permanecem. Mas, nesse
 21 último método, apenas tem-se variações elevadas de picos na função de perda, sendo
 22 que as outras métricas encontram-se mais estabilizadas. No Quadro 6 tem-se os
 23 parâmetros salvo nesta última etapa.

1 Após todas as modificações, é possível observar que os resultados deste modelo
 2 estão mais próximos do ideal. A perda foi reduzida próximo da metade com relação a
 3 segunda melhor rede, o AUC e a sensibilidade estão bem próximos de 1, a precisão
 4 chegou ao máximo de 0,93, junto da especificidade e sensibilidade que
 5 respectivamente tiveram os valores de 0,925 e 0,966.

6

7 Figura 16 - Evolução da CNN final, com todos os parâmetros analisados.



8

9

Fonte: Autoria própria

10

Quadro 6 - Métricas finais da CNN definitiva.

Acuracia	AUC	Perda	Precisão	Especificidade	Sensibilidade	Épocas
0,930	0,982	0,261	0,932	0,925	0,966	184

11

Fonte: Autoria própria

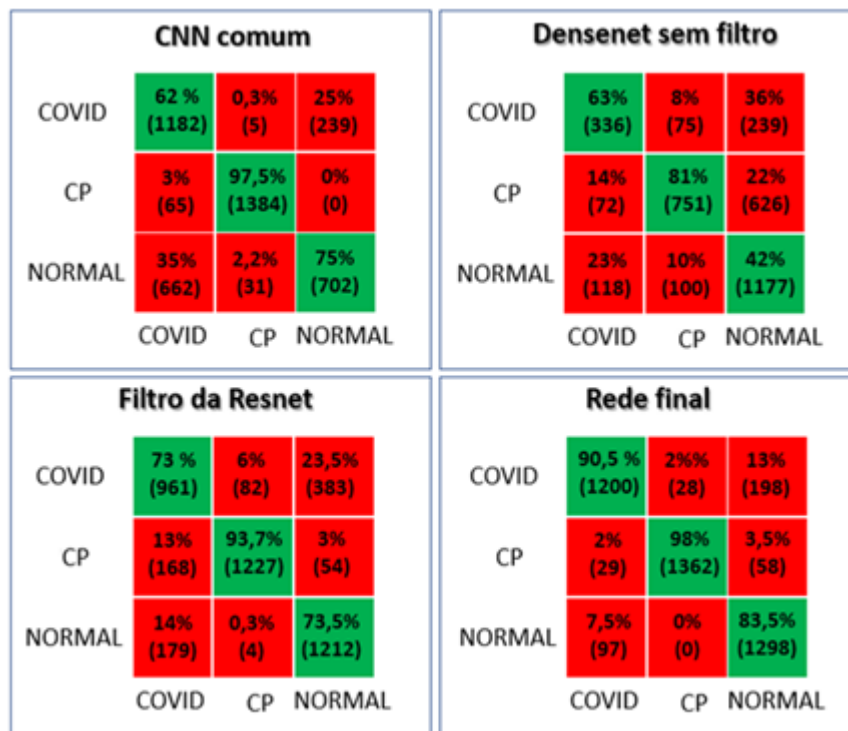
12 5.5 Evolução do modelo via matriz de confusão

13 Para acompanhar a evolução dos resultados nas redes testadas, as matrizes de
 14 confusão, mostradas na Figura 17, foram construídas. Esses valores correspondem
 15 aos dados de teste que inicialmente foram separados.

16 É visível que o modelo final se sai melhor que outros na classificação correta de
 17 todas as classes, e a classe com mais facilidade de ser classificada foi a de pneumonia
 18 comum, enquanto a mais difícil de identificar foi a normal. Curiosamente, havia mais

1 imagens de exames de pessoas normais que as demais classe, possivelmente a
 2 qualidade do exame realizado nessas pessoas deve ter afetado no aprendizado.

3 Figura 17 - Matrizes de confusão.



4
 5 Fonte: Autoria própria

6 6 CONCLUSÕES

7 Diante dos resultados obtidos, pode-se concluir a efetividade de uma rede neural
 8 em classificar padrões de exames de TC do tórax, diferenciando a infecção por Covid-
 9 19 dentre outras doenças e um pulmão saudável. Entretanto, é inegável que o
 10 diagnóstico feito por médicos especializados ainda é prioritário e tem uma maior
 11 precisão de acerto e identificação do vidro fosco presente em exames de pacientes
 12 que tiveram Covid-19.

13 Cada função de ativação tem uma melhor efetividade em certas condições, como
 14 demonstrado a *softmax* e a ReLu foram as melhores empregadas, pois a saída
 15 apresentada era de multicamadas. Além disso, foi reforçado que as redes pré-
 16 treinadas têm dificuldade em encontrar padrões em imagens de escala cinza não
 17 oferecendo resultados desejáveis. Pois elas são treinadas em uma outra formatação
 18 de dados diferente da empregada no trabalho.

19 A utilização dos filtros de pré-processamento é de extrema importância para
 20 analisar a melhora na classificação. Neste caso, a Resnet50 foi a que apresentou
 21 resultados satisfatórios, vale ressaltar que os filtros de pré-processamento da
 22 Resnet50 são os mesmos da Resnet101.

23 A taxa de aprendizado dita o ritmo com que a CNN se desenvolve, não podendo
 24 nem ser alto ou muito baixo, pois em ambos os casos o algoritmo não iria convergir.

1 Sendo então um dos ajustes finos mais difíceis de sintonizar. Já a DA é uma função
 2 que tende a melhorar o reconhecimento das imagens utilizadas, porém foi observado
 3 que o uso excessivo dela faz com que a rede perca sua precisão e tenha dificuldade
 4 para extrair as características presentes nela.

5 Para trabalhos futuros, a ideia é buscar um conhecimento mais aprofundado de
 6 um especialista na área para poder trabalhar com os métodos de segmentação,
 7 facilitando a extração de características e ampliando o uso e os conceitos presentes
 8 neste trabalho.

9 REFERÊNCIAS

- 10 AFSHIN, Shoeibi et al. Automated detection and forecasting of COVID-19 using
 11 deep learning techniques: A review. **arXiv preprint arXiv:2007.10785v3**, 2020.
- 12 AHAMMED, Khair et al. Early Detection of Coronavirus Cases Using Chest X-ray
 13 Images Employing Machine Learning and Deep Learning Approaches. DOI:
 14 10.13140/RG.2.2.13579.11045, 2020.
- 15 ALLRED, Ryan. Image Augmentation for Deep Learning using Keras and Histogram
 16 Equalization. Towards Data Science, 2017. Disponível em
 17 <<https://towardsdatascience.com/image-augmentation-for-deep-learning-using-keras-and-histogram-equalization-9329f6ae5085>>. Acesso em 12/10/2020.
- 19 ARAUJO-FILHO, Jose de Arimateia Batista et al . Pneumonia por COVID-19: qual o
 20 papel da imagem no diagnóstico?. **J. bras. pneumol.**, São Paulo , v. 46, n. 2,
 21 e20200114, 2020 . Epub Mar 27, 2020. [http://dx.doi.org/10.36416/1806-](http://dx.doi.org/10.36416/1806-3756/e20200114)
 22 [3756/e20200114](http://dx.doi.org/10.36416/1806-3756/e20200114).
- 23 ASIF, Sohaib et al. Classification of covid-19 from chest x-ray images using deep
 24 convolutional neural networks. **medRxiv**, 2020.
- 25 BAI, Harrison X. et al. AI augmentation of radiologist performance in distinguishing
 26 COVID-19 from pneumonia of other etiology on chest CT. **Radiology**, p. 201491, 2020.
- 27 BBC. Bill Gates: We are vulnerable to flu epidemic in next decade. 2016. Disponível
 28 em: <<https://www.bbc.com/news/av/health-38330823>>. Acesso em: 05/12/2020.
- 29 BRANDIZZI, Loreane. Visão computacional: O que é? Como funciona?, 2020.
 30 Disponível em <[https://www.serpro.gov.br/menu/noticias/noticias-2020/o-que-eh-](https://www.serpro.gov.br/menu/noticias/noticias-2020/o-que-eh-visao-computacional)
 31 [visao-computacional](https://www.serpro.gov.br/menu/noticias/noticias-2020/o-que-eh-visao-computacional)>. Acesso em : 05/11/2020.
- 32 CNCB CHINA NATIONAL CENTER FOR BIOINFORMATION. 2019 Novel Coronavirus
 33 Resource (2019nCoV), 2020. Disponível em: <[http://ncov-](http://ncov-ai.big.ac.cn/download?lang=en)
 34 [ai.big.ac.cn/download?lang=en](http://ncov-ai.big.ac.cn/download?lang=en)>. Acesso em: 16/09/2020.
- 35 DSA DATA SCIENCE ACADEMY. Deep Learning Book, 2019. Disponível em
 36 <<http://www.deeplearningbook.com.br/>>. Acesso em: 05/11/2020.
- 37 FANG, Yicheng et al. Sensitivity of chest CT for COVID-19: comparison to RT-PCR.
 38 **Radiology**, p. 200432, 2020.

- 1 FREITAS, André Ricardo Ribas; NAPIMOGA, Marcelo; DONALISIO, Maria Rita. Análise
2 da gravidade da pandemia de Covid-19. **Epidemiol. Serv. Saúde**, Brasília , v. 29, n.
3 2, e2020119, 2020 . Epub 06-Abr-2020. [https://doi.org/10.5123/S1679-](https://doi.org/10.5123/S1679-49742020000200008)
4 49742020000200008.
- 5 GIRELLI, Cassio; CORSO, Leandro Luís. Detecção de falhas em contentores plásticos
6 utilizando Redes Neurais Convolucionais. **Scientia cum Industria**, v. 8, n. 2, p. 156-163,
7 2020. HAYKIN, S. **Redes neurais: princípios e prática**. 2.ed. Porto Alegre: Bookman,
8 2001. 908p.
- 9 KANG, Zhang; XIAOHONG, Liu; JUN, Shen; et al. Jianxing He, Tianxin Lin, Weimin Li,
10 Guangyu Wang. (2020). Clinically Applicable AI System for Accurate Diagnosis,
11 Quantitative Measurements and Prognosis of COVID-19 Pneumonia Using Computed
12 Tomography.
- 13 Keras, Probabilistic metrics. Keras. Disponível em
14 <https://keras.io/api/metrics/probabilistic_metrics/#categorical_crossentropy-class>.
15 Acesso em: 05/11/2020.
- 16 Krizhevsky, A., Sutskever, I., Hinton, G.E.: ImageNet classification with deep
17 convolutional neural networks. *Commun. ACM* 60(6), 84–90 (2017).
18 <https://doi.org/10.1145/3065386>.
- 19 LEITE, Tiago. Redes Neurais, Perceptron Multicamadas e o Algoritmo
20 Backpropagation. Medium, 2018. Disponível em: <[https://medium.com/ensina-](https://medium.com/ensina-ai/redes-neurais-perceptron-multicamadas-e-o-algoritmo-backpropagation-eaf89778f5b8)
21 [ai/redes-neurais-perceptron-multicamadas-e-o-algoritmo-backpropagation-](https://medium.com/ensina-ai/redes-neurais-perceptron-multicamadas-e-o-algoritmo-backpropagation-eaf89778f5b8)
22 [eaf89778f5b8](https://medium.com/ensina-ai/redes-neurais-perceptron-multicamadas-e-o-algoritmo-backpropagation-eaf89778f5b8)>. Acesso em: 08/11/2020.
- 23 Ling, A & 袁凌, Yuan & Muttakhirroh, ling. (2019). 华中科技大学硕士学位论文 DNN-
24 based Application on Joint Mobile and Cloud Computing Platform Candidate: ling
25 Muttakhirroh (孙静) Major: Computer Applied Technology.
26 10.13140/RG.2.2.21502.00321.
- 27 MAGNO, Laio et al . Desafios e propostas para ampliação da testagem e
28 diagnóstico para COVID-19 no Brasil. **Ciênc. saúde coletiva**, Rio de Janeiro , v. 25, n.
29 9, p. 3355-3364, 2020 . Epub Aug 28, 2020. [http://dx.doi.org/10.1590/1413-](http://dx.doi.org/10.1590/1413-81232020259.17812020)
30 81232020259.17812020.
- 31 MASATO, Eduardo. Inteligência Computacional no Projeto Automático de Redes
32 Neurais Híbridas e Redes Neurofuzzy Heterogêneas, 2000.
- 33 MLCC MACHINE LEARNING CRASH COURSE. Classification: ROC Curve and AUC.
34 Disponível em <[https://developers.google.com/machine-learning/crash-](https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc)
35 [course/classification/roc-and-auc](https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc)>. Acesso em 07/11/2020.
- 36 MOREIRA, Sandro. Redes Neural Perceptron Multicamadas. Medium, 2018. Disponível
37 em: <[https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-](https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-f9de8471f1a9)
38 [f9de8471f1a9](https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-f9de8471f1a9)>. Acesso em: 08/11/2020.
- 39 NARIN, Ali; KAYA, Ceren; PAMUK, Ziyet. Automatic detection of coronavirus disease
40 (covid-19) using x-ray images and deep convolutional neural networks. **arXiv preprint**
41 **arXiv:2003.10849**, 2020.

- 1 Peltarion. Categorical CrossEntropy. Peltarion. 2020. Disponível em:
2 <<https://peltarion.com/knowledge-center/documentation/modeling-view/build-an-ai-model/loss-functions/categorical-crossentropy>>. Acesso em 05/11/2020.
- 4 Ren, Y.; Yang, J.; Zhang, Q.; Guo, Z. Multi-Feature Fusion with Convolutional Neural
5 Network for Ship Classification in Optical Images. *Appl. Sci.* **2019**, 9, 4209.
- 6 SILVA, Luan; FERREIRA, Victor; ARAÚJO, Leandro; SANTOS, Adam. Aplicação de
7 Deep Learning no pré-diagnóstico da COVID-19 através de imagens de raio-x,
8 UNIFESSPA, 2020.
- 9 SILVA, Pedro et al. COVID-19 Detection in CT Images with Deep Learning: A Voting-
10 based Scheme and Cross-Datasets Analysis. **Informatics in Medicine Unlocked**, p.
11 100427, 2020.
- 12 SOARES, Pablo; SILVA, José da. (2011). Aplicação de Redes Neurais Artificiais em
13 Conjunto com o Método Vetorial da Propagação de Feixes na Análise de um
14 Acoplador Direcional Baseado em Fibra Ótica. *Revista Brasileira de Computação*
15 *Aplicada*. 3. 10.5335/rbca.2013.1803.
- 16 VASANI, Dipam. How do pre-trained models work?. Towards data science 2019.
17 Disponível em <<https://towardsdatascience.com/how-do-pretreined-models-work-11fe2f64eaa2>>. Acesso em 13/10/2020.
- 19 WANG, Wenling; XU, Yanli; GAO, Ruquin; et al. Detection of SARS-CoV-2 in Different
20 Types of Clinical Specimens. *JAMA*. 2020;323(18):1843–1844.
21 doi:10.1001/jama.2020.3786
- 22 WHO WORLD HEALTH ORGANIZATION. WHO Coronavirus Disease (COVID-19)
23 Dashboard. 2020. Disponível em: <covid19.who.int>. Acesso em 05/12/2020
- 24 XIE, Xingzhi et al. Chest CT for typical 2019-nCoV pneumonia: relationship to negative
25 RT-PCR testing. **Radiology**, p. 200343-200343, 2020.