

CT-FastNet: Detecção de COVID-19 a partir de Tomografias Computadorizadas (TC) de Tórax usando Inteligência Artificial**CT-FastNet: Detection of COVID-19 From Chest Computed Tomography (CT) Images Using Artificial Intelligence**

DOI:10.34117/bjdv6n7-619

Recebimento dos originais:03/06/2020

Aceitação para publicação:23/07/2020

Rodrigo Carvalho Barbosa

Mestrando em Ciência da Computação pela Universidade Federal de Lavras

Instituição: Universidade Federal de Lavras

Endereço: Câmpus Universitário, Caixa Postal 3037, CEP:37200-000, Lavras - MG - Brasil

E-mail: rodrigo.barbosa13@gmail.com

Renata Lopes Rosa

Professora Adjunto do DCC na Universidade Federal de Lavras

Instituição: Universidade Federal de Lavras

Endereço: Câmpus Universitário, Caixa Postal 3037, CEP:37200-000, Lavras - MG - Brasil

E-mail: rrosa77@gmail.com

Kátia Cilene Neles da Silva

Professora Adjunto

Instituição: Faculdade Martha Falcão

Endereço: Campus Martha Falcão, Rua Natal, 300 - Bairro Adrianópolis, Manaus - AM - Brasil

E-mail: katia.neles@gmail.com

Demostenes Zegarra Rodriguez

Professor Adjunto do DCC na Universidade Federal de Lavras

Instituição: Universidade Federal de Lavras

Endereço: Câmpus Universitário, Caixa Postal 3037, CEP:37200-000, Lavras - MG - Brasil

E-mail: demostenes.zegarra@ufla.br

RESUMO

Many countries have been affected by the COVID-19, and health departments are facing delays to detect the new coronavirus symptoms. Artificial Intelligence (AI) models are designed for the automatic detection of respiratory diseases patterns using computed tomography (CT) scans of the chest. However, the training time consumed by the algorithms is a key parameter that is not properly attended. In this article, we propose an AI solution using an activation function that helps to obtain a low training time. Experimental results show that our proposal overcome several deep learning architectures, such as the 3D deep Convolutional Neural Network to Detect COVID-19 (DeCoVNet).

Palavras-chave: COVID-19, Redes Neurais Artificiais, Tomografia Computadorizada (TC) de Tórax.

ABSTRACT

Many countries have been affected by the COVID-19, and health departments are facing delays to detect the new coronavirus symptoms. Artificial Intelligence (AI) models are designed for the automatic detection of respiratory diseases patterns using computed tomography (CT) scans of the chest. However, the training time consumed by the algorithms is a key parameter that is not properly attended. In this article, we propose an AI solution using an activation function that helps to obtain a low training time. Experimental results show that our proposal overcome several deep learning architectures, such as the 3D deep Convolutional Neural Network to Detect COVID-19 (DeCoVNet).


Keywords : COVID-19, Artificial Neural Networks, Chest Computed Tomography

1 INTRODUÇÃO

A pandemia do novo coronavírus, o COVID-19, teve início em dezembro de 2019 na China [Wang et al. 2020]. Desde então, a rápida disseminação do vírus tem se tornando um grande problema de saúde mundial em pouco tempo. O novo coronavírus, também denominado de SARS-Cov-2 [Roosa et al. 2020] possui alta taxa de contágio e pode apresentar características da Síndrome Respiratória Aguda Grave, causando doenças subsequentes de diferentes tipos [Rothan and Byrareddy 2020].

Nos casos críticos causados pelo COVID-19 estão incluídas infecções graves que podem levar a pneumonia, falência de órgãos e morte [Rothan and Byrareddy 2020]. A pandemia tem se espalhado muito rapidamente em vários países conforme pode ser visto na Figura 1, que mostra os números de casos no mundo e o número de mortes diárias em alguns países mais afetados [Ourworldindata. 2020].

Figura 1. Números de casos no mundo e o número de mortes diárias em alguns países específicos



Conforme pode ser observado na Figura 1, o número de indivíduos infectados tem aumentado drasticamente e tal fato tem aumentado a demanda por tratamentos intensivos nas

unidades de atendimento de forma paralela. Assim, há escassez de leitos nas Unidade de Terapia Intensiva (UTI) em algumas regiões durante o pico da doença.

O COVID-19 pode ser diagnosticado por sequenciamento de genes através de amostras de sangue, e usando métodos como Transcrição Reversa seguida de Reação em Cadeia da Polimerase em Tempo Real (RT-PCR) [Yong et al. 2020]. Porém, o processo de sequenciamento genético e o uso de RT-PCR não são realizados em todos os centros de saúde, pois eles são escassos em determinadas regiões, além do fato que os procedimentos consomem tempo e incrementas as atividades do pessoal técnico. É importante destacar que as entidades de saúde sinalizam que quanto antes efetuar o diagnóstico e eventual hospitalização do paciente, isso pode evitar que esse indivíduo alcance um estágio crítico da doença, causando danos permanentes nos pulmões ou mesmo levando o indivíduo a morte.

Em muitos casos do COVID-19, o indivíduo adquire pneumonia [Shi et al. 2020]. Para a detecção de indícios de pneumonia ou outras doenças pulmonares, a técnica de tomografia computadorizada (TC) [Song et al. 2020] do tórax vem sendo bastante utilizada é adotada no mundo. A TC do tórax e um componente essencial no procedimento de diagnostico para pacientes com problemas respiratórios, e atualmente usado para descarte de suspeita de COVID-19 [Chung et al. 2020].

O diagnóstico preciso e rápido de COVID-19 desempenha um papel crucial no tratamento médico do indivíduo. Assim como também auxilia no controle da epidemia, é na segurança da saúde publica. A técnica de TC de tórax possibilita observar as alterações e a extensões da gravidade das pneumonias pulmonares. Porém, a análise desses exames médicos pode causar uma elevada carga nas equipes medicas. As técnicas de detecção de doenças com uso de bases de dados e um fator benéfico, ainda mais no início de uma nova doença. Assim, desenvolver um modelo de Inteligência Artificial ou *Artificial Intelligence* (AI) para diagnosticar o COVID-19 ou outras novas doenças que venham a surgir é útil tanto para os pacientes como para os radiologistas ou demais especialistas.

Diferentes técnicas de IA são utilizadas em diferentes aplicações [da Silva et al. 2020, Dantas et al. 2019, Lasmar et al. 2019, Rodríguez and Möller 2019, de Almeida et al. 2018]. A técnica de Aprendizado profundo ou Deep Learning

(DL) tem sido a principal tecnologia de IA utilizada em diversas aplicações nos últimos anos [Affonso et al. 2018, Rosa et al. 2019, Ênio dos Santos Silva et al. 2020, Sombra et al. 2020], e também, no auxílio de diagnósticos de diferentes doenças pulmonares [Ardila et al. 2019, Suzuki 2017].

Técnicas de DL são utilizadas para a análise de milhares de imagens que seria muito demorada caso fossem analisadas por especialistas [He et al. 2015]. Em [He et al. 2015], os autores apresentam uma solução baseada em DL, a qual obteve resultados de treinamento satisfatórios em termos de acurácia. Outros trabalhos relacionados obtêm resultados de acurácia superior a 90% no rastreamento do câncer de pulmão em 2019 [Ardila et al. 2019]. No entanto, a maioria dos métodos baseados em aprendizado profundo para doenças requer uma anotação manual previa de lesões presentes nas imagens, especialmente para doenças com diagnóstico através de um alto volume de dados de TC. Tais anotações de lesões requer uma quantidade razoável de esforços para os radiologistas, e um período longo de análise, o que não é aceitável para detecção de doenças com alta disseminação, como é o caso do COVID-19. Portanto, existe a necessidade de trabalhar métodos que não necessitem de tais anotações e que descubram tais lesões automaticamente por meio das imagens analisadas.

Estudos recentes têm focado na detecção de COVID-19 a partir de TC de tórax [Dong et al. 2020], mostrando que comparado com outra pneumonia, os pacientes com COVID-19 são mais propensos a apresentar anormalidades na TC. Tais anomalias são caracterizadas por opacidade reticular fina, espessamento vascular reverso, e também é provável que tenham níveis significativos de distribuição periférica central, derrame pleural e linfadenopatia [Pinto et al. 2008].

Chen et al. (2020) apresentou estudos usando o método UNet ++ [Zhou et al. 2018] com redes convolucionais em imagens de pulmão. Em seu estudo, fatias de imagem de TC 2D de 106 pacientes (51 com COVID-19 e 55 com outras doenças pulmonares) foram divididos aleatoriamente em conjuntos de treinamento e validação. No conjunto de validação, o modelo diagnosticou os pacientes com uma precisão de 95,24% [Chen et al. 2020].

Fang et al. (2020) utilizou uma análise randômica [Fang et al. 2020] para diagnosticar o COVID-19. Nessa pesquisa, os exames clínicos de 75 pacientes foram estudados (46 pacientes confirmados com COVID-19 e 29 pacientes com outros tipos de pneumonias) e o modelo randômico alcançou um valor de parâmetro *Area Under the Curve* (AUC) de 0,826. Em Jin et al. (2020), uma solução baseada em aprendizagem profunda foi implementada para acelerar o diagnóstico do COVID-19 por meio de imagens TC [Zhou et al. 2020]. Esse modelo de aprendizado profundo foi treinado usando apenas 312 imagens de casos. No entanto, alcançou uma alta correlação com o diagnóstico de radiologistas experientes. Entre 1.255 independentes casos de teste, o modelo proposto de aprendizado profundo alcançou precisão de 94,98%.

A função de ativação é um passo importante em uma rede neural, sendo crucial para um bom desempenho de aprendizado [LeCun et al. 2015]. Nos últimos anos, muitas funções de ativação têm

sido propostas, como Unidade Linear Retificada (ReLU) [Nair and Hinton 2010], Swish [Ramachandran et al. 2017], entre outras [He et al. 2015]. A função de ativação *Soft-Root-Sign* (SRS) [Zhou et al. 2020] pode ajustar adaptativamente a saída através de poucos parâmetros treináveis independentes, com melhor desempenho de generalização e aprendizado mais rápido. Assim, essa função de ativação foi escolhida para ser implementada neste trabalho devido a velocidade de aprendizado. É importante notar que existem trabalhos escassos sobre a implementação e testes da função SRS em modelos de detecção de doenças ou anomalias em processamento de imagens. Além disso, nosso trabalho efetuou o treinamento de modelos com um grande número de camadas, como o *Deep Residual Learning for Image Recognition* (ResNet) [Wu et al. 2019]. Pois, trabalhos como Akiba et al. (2017) alcançaram bons resultados de acurácia com o ResNet-50, utilizando um tempo de treinamento de 15 minutos para imagens.

Diferentemente das demais soluções existentes, nossa solução, denominada de CT-FastNet, que usa o ResNet-50 [Akiba et al. 2017] e a função de ativação *Soft-Root-Sign* (SRS) permitem obter um aumento na acurácia na classificação do COVID-19 nas imagens de tórax por TC, e obter um menor tempo de treinamento. Os resultados experimentais mostram que o CT-FastNet apresentou uma acurácia de 98,9%, o que é muito útil para detecções precisas no diagnóstico do COVID-19, principalmente em situações críticas para auxiliar no combate de tal surto global. A diminuição do tempo de treinamento do CT-FastNet também ocorreu, sendo quase 20% menor que demais métodos como o *3D deep convolutional neural Network to Detect COVID-19* (DeCoVNet) [Wang et al. 2020].

As principais contribuições apresentadas neste artigo estão resumidas em:

1. Efetuar a segmentação de imagens utilizando um método baseado em [Colin 2020], e adaptada para detecção do COVID-19 em pulmões, efetuando uma segmentação em blocos, a partir de TC de Tórax.
2. E proposto um método de detecção do COVID-19 a partir de TC usando ResNet-50 para aumento da acurácia na detecção do COVID-19.
3. Aplicação da função de Ativação *Soft-Root-Sign* (SRS) em conjunto com a ResNet-50 para a diminuição do tempo de treinamento das imagens, obtendo a solução denominada de CT-FastNet.
4. Validação dos testes por meio do uso de 3 diferentes bases de dados de imagens de TC de tórax.

Por meio dos resultados experimentais, demonstramos que a arquitetura de rede proposta, gerando o nosso modelo proposto denominado de CT-FastNet, fornece maior acurácia em comparação com o método DeCoVNet.

2 MÉTODOS E MATERIAIS

Nesta seção são descritos os principais métodos e materiais utilizados neste trabalho, tal como base de dados de TC de tórax, e os algoritmos utilizados para obtenção da solução proposta, o CT-FastNet.

2.1 BASES DE DADOS DE TC DE TÓRAX

Para o desenvolvimento dos testes realizados neste trabalho foram utilizados três bases de dados de imagens TC.

A primeira base de dados, denominada de COVID-CT-Dataset [Yang et al. 2020], foi utilizada neste trabalho por possuir imagens de pulmão tanto de pacientes com COVID-19, que totalizam 288, como de pacientes sem COVID-19 que totalizam 1000 pessoas. Esta base de dados é aberta e pública. O diagnóstico do conjunto de dados é explicado em detalhes em [Yang et al. 2020]. Tais autores também realizaram estudos experimentais para verificar a precisão desse conjunto de dados, onde desenvolveram uma abordagem baseada na aprendizagem multitarefa e na aprendizagem auto-supervisionada contrastante que atingiu valores de medida F1 de 0,90 e uma precisão de 0,89.

A segunda base de dados é disponibilizada pela Sociedade Italiana de Radiologia Médica, com 113 imagens de infecção por COVID-19 [de Radiologia Médica 2020].

A terceira base de dados também é aberta e pública, contendo 1252 imagens de CT com diagnóstico positivos para infecção de SARS-CoV-2 e 1230 varreduras de CT para pacientes não infectados por SARS-CoV-2, contendo no total 2482 tomografias. Esses dados foram coletados de pacientes em hospitais de São Paulo, no Brasil. O objetivo deste conjunto de dados é incentivar a pesquisa e o desenvolvimento de métodos de IA, capazes de identificar se uma pessoa está infectada pelo SARS-CoV-2 através da análise de suas TC. Adicionalmente, como resultado de análise desta base de dados, os autores usaram uma abordagem de Aprendizado Profundo *eXplainable* (xDNN), cujo método alcançou uma pontuação F1 de 97,31%. O conjunto de dados proposto está disponível em [Eduardo 2020].

O conjunto de imagens de cada base de dados foram divididos aleatoriamente em treinamento (80%) e validação (20%).

É importante salientar que todas as bases de dados são cedidas publicamente e possuem a aprovação do comitê de ética CERSES - 20 - 058 - D.

2.2 MODELO DE DEEP LEARNING PROPOSTO: CT-FASTNET

A estrutura do modelo proposto e apresentada na Figura 2. As imagens extraídas da TC são primeiramente pré-processadas para normalização de dados. Posteriormente, os dados pré-processados são alimentados em uma rede de segmentação onde as regiões de lesões pulmonares podem ser extraídas automaticamente. O treinamento e inferência bloco a bloco são efetuados e a decisão é feita com o auxílio da função de ativação.

Neste estudo, empregamos os modelos de pré-treinamento AlexNet [Iandola et al. 2016], Vgg-16 [Alippi et al. 2018], ResNet-18, ResNet-34 e ResNet-50 [Venkatesh et al. 2017] para classificar automaticamente se o paciente apresentou diagnostico positivo ou negativo para o COVID-19. Diversos valores de épocas são testados e a melhor configuração e modelo são escolhidos para fazerem parte dos testes finais e validação. É importante destacar que o modelo de classificação proposto inclui uma função de ativação que possibilitou acelerar o processo treinamento, o que diminui o tempo desta fase. Tal função é denominada de *Soft-Root-Sign* (SRS) [Zhou et al. 2020] que pode ser ajustada de forma adaptativa. A função possui melhor desempenho de generalização e velocidade de aprendizado mais rápida. Tal função tem como proposito acelerar a velocidade de treinamento para uso com os modelos de treinamento, pelo que o modelo proposto e denominado CT-FastNet.

A função de ativação do SRS é definida a seguir.

$$funcao(p) = \frac{p}{\frac{p}{\alpha} + e^{-\frac{p}{\beta}}}$$

onde as variáveis α e β representam parâmetros positivos e trináveis de um dado p .

A derivada da funcao(p) é definida a seguir.

$$funcao(p) = \frac{\left(1 + \frac{p}{\beta}\right)^{\frac{p}{\beta}}}{\left(\frac{p}{\alpha} + e^{-\frac{p}{\beta}}\right)^2}$$

O valor esperado e a variação de funcao(p) em relação a um dado p pode ser calculado a seguir.

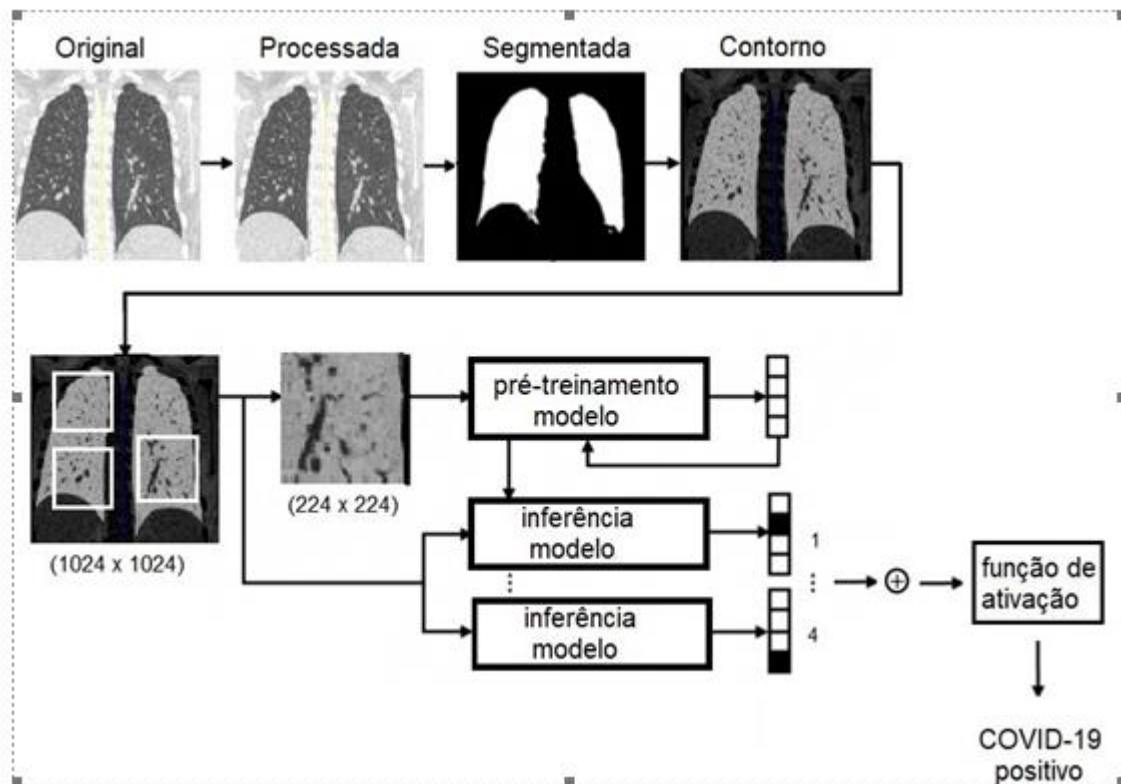
$$E[funcao(p)] = \int_{-\infty}^{+\infty} funcao(p) \cdot f_p(p) dx$$

Na classificação, os rótulos foram divididos em duas classes: normal e pneumonia viral causada pela infecção por COVID-19. A rede de classificação foi implementada em duas versões diferentes: abordagens globais e locais a fim de comparação de ambas.

Na abordagem global, as imagens foram redimensionadas para 224×224 , e assim são alimentadas na rede. Essa configuração foi escolhida, pois muitas soluções existentes empregam procedimentos semelhantes [Apostolopoulos and Tzani 2020, Hemdan et al. 2020].

Na abordagem local baseada em blocos, as imagens são cortadas em blocos onde são detectados grânulos ou outras anomalias por meio de um script de forma automática em Python, baseado em [Colin 2020]. A detecção de anomalias foi adaptada por meio do treinamento com as imagens de TC das bases de dados utilizadas neste trabalho. As imagens possuem um tamanho de 224×224 , e os blocos resultantes são usados como as entradas do modelo. A abordagem local é usada no modelo proposto conforme mostrado na Figura 2.

Figura 2. Solução Proposta com as Etapas de Pré-processamento, Normalização de dados e segmentação até a classificação do COVID-19



Durante a inferência dos dados, um número x de blocos representam o atributo de uma imagem i . O número x é escolhido de acordo com que todos os pixels relevantes da imagem do

pulmão sejam considerados. Assim, cada bloco é introduzido na rede neural para gerar uma saída mediante a função de ativação.

Para treinamento em rede, parâmetros pré-treinados dos modelos AlexNet, Vgg- 16, ResNet-18, ResNet-34 e ResNet-50 são usados para a inicialização do peso da rede. Uma taxa de aprendizado de 0,00001 foi utilizada. Testes foram feitos na rede com um treinada com 10, 20, 40, 60, 80 e 100 épocas. A rede de classificação foi implementada por meio da Biblioteca Pytorch [Crestani et al. 2018].

2.3 MEDIDAS DE PERFORMANCE UTILIZADAS E COMPARATIVO COM O MODELO DECOVNET

O desempenho dos métodos de classificação foi avaliado usando as métricas definidas a seguir, acurácia, precisão e medida F1. Onde *True Positive* é definido como TP, *True Negative* e TN, *False Positive* e FP e foram obtidos valores de *Negative False*, o NF.

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

$$Precisão = \frac{TP}{(TP + FP)}$$

$$MedidaF1 = 2 * \frac{(Precisão+Revocação)}{(Precisão+Revocação)}$$

onde Revocação, também denominada de Sensibilidade ou Recall é definida a seguir.

$$Revocação = \frac{TP}{(TP+FN)}$$

O modelo DeCoVNet será utilizado como comparativo com o método proposto neste trabalho por possuir alta acurácia em estudos relacionados na área de segmentação pulmonar. DeCoVNet utiliza um modelo de segmentação pulmonar usando máscaras geradas a partir de método de aprendizado não supervisionado [Wang et al. 2020]. Adicionalmente, o modelo DeCoVNet propõe uma detecção de lesão COVID-19 supervisionada, combinando regiões de ativação de aprendizado e regiões de ativação de componentes conectados não supervisionadas.

3 RESULTADOS E DISCUSSÃO

Nesta seção são discutidos os principais resultados experimentais obtidos na análise de diagnóstico do COVID-19 por meio do uso da solução proposta.

3.1 AVALIAÇÃO DA PERFORMANCE DE SEGMENTAÇÃO

O desempenho da segmentação foi avaliado de acordo com o coeficiente de similaridade de Jaccard [Seifoddini and Djassemi 1991]. A Tabela 1 apresenta o coeficiente de similaridade de Jaccard de cada base de dados utilizada neste trabalho.

O coeficiente de similaridade de Jaccard mede a semelhança e a diversidade dos conjuntos de amostras utilizados, onde os valores superiores a 0,90 representam que houve um bom desempenho de segmentação.

Table 1. Desempenho da segmentação por meio do coeficiente de similaridade de Jaccard

Base de dados	Coeficiente Jaccard
COVID-CT-Dataset	0,96
BD COVID Sociedade Italiana	0,94
BD COVID Brsail-SP	0,95

3.2 AVALIAÇÃO DO DESEMPENHO DE CLASSIFICAÇÃO

A Tabela 2 mostra os resultados obtidos de acurácia e medida F1 de acordo com os testes feitos com os modelos de pré-treinamento AlexNet, Vgg-16, ResNet-18, ResNet-34 e ResNet-50 e considerando ambas as abordagens global e local (global / local). Comparado a abordagem global à abordagem local notamos uma acurácia, medida F1 e precisão significativamente mais alta que a global, o que confirma a eficácia do método proposto. Assim, nos próximos resultados focaremos somente na abordagem local.

Table 2. Resultados obtidos de acurácia e medida F1 de acordo com os testes feitos com os modelos de pré-treinamento AlexNet, Vgg-16, ResNet-18, ResNet-34 e ResNet-50, considerando as abordagens global e local (global/local).

Modelos	Acurácia	Precisão	Medida F1
AlexNET	0,81/0,86	0,82/0,85	0,82/0,86
VGG-16	0,85/0,89	0,83/0,87	0,86/0,90
ResNet-18	0,88/0,92	0,88/0,91	0,89/0,92
ResNet-34	0,92/0,95	0,91/0,94	0,93/0,95
ResNet-50	0,94/0,97	0,93/0,96	0,95/0,98

Conforme os resultados obtidos, utilizou-se no modelo final o ResNet-50. Fez-se testes com várias épocas e o melhor resultado foi com o valor de época igual a 100.

A Tabela 3 mostra os resultados de classificação obtidos pelo método proposto, obtendo-se uma acurácia superior a 0,97% para detecção do COVID-19 no método de abordagem local, que foi um desempenho superior ao modelo de diagnostico atual padrão RT-PCR que possui uma sensibilidade aproximada de 91% [Wong et al. 2020].

Table 3. Classificação resultante da abordagem local por meio de blocos para as três bases de dados.

Base de Dados	Acurácia	Precisão	Medida F1
COVID-CT-Dataset	0,98	0,98	0,98
BD COVID Sociedade Italiana	0,99	0,98	0,98
BD COVID Brasil-SP	0,98	0,99	0,99

Como pode ser observado o modelo proposto CT-FastNet alcançou valores altos de acurácia para as duas classes.

Table 4. Classificação resultante da abordagem local da classe normal.

Base de Dados	Acurácia	Precisão	Medida F1
COVID-CT-Dataset	0,98	0,97	0,97
BD COVID Sociedade Italiana	0,96	0,96	0,96
BD COVID Brasil-SP	0,98	0,94	0,95

Como pode ser observado o modelo proposto CT-FastNet alcançou valores altos de acurácia para as duas classes.

3.3 COMPARAÇÃO COM O MÉTODO DECOVNET

Como mostrado na Tabela 5, nosso método mostrou uma acurácia média de 0,98 para COVID-19, enquanto o método DeCoVNet alcançou uma acurácia de 0,94. Como mencionado anteriormente, o modelo CT-FastNet é implementado somente considerando a abordagem local, o qual teve melhores resultados. É importante salientar que para estes testes de comparação de desempenho foram utilizadas as três BD descritas na Seção 2.

Table 5. Resultados da classificação de COVID-19 com o método DeCoVNet e o método proposto.

Método	Acurácia	Precisão	Medida F1
CT-FastNet	0,98	0,98	0,98
DeCoVNet	0,94	0,93	0,93

Finalmente, é importante destacar que o tempo de treinamento do método proposto foi 81,3% do tempo utilizado pelo DeCoVNet, utilizando o mesmo computador e as mesmas BDs. Isto se deve a utilização da função de ativação SRS no CT-FASNET.

4 CONCLUSÃO

As abordagens existentes baseadas em IA para a detecção do COVID-19 mostram resultados promissores. Porém, apresentam resultados de acurácia inferior a 96% e com um tempo elevado de treinamento [Wang et al. 2020, Chen et al. 2020, Fang et al. 2020]. Neste trabalho propomos a solução denominada de CT-FastNet que por meio da uso da ResNet-50 obteve-se um aumento na

acurácia na detecção do COVID-19, alcançando valores de 0,98 e por meio da aplicação da função de Ativação SRS na ResNet-50 obteve-se uma diminuição do tempo de treinamento das imagens, em torno de 20% menor que o método DeCoVNet.

Assim, por meio dos resultados experimentais comprovamos a eficácia do método proposto quando comparado com o método DeCoVNet, o qual foi proposto recentemente. Adicionalmente, o método de segmentação da imagem em blocos, denominado de local atingiu resultados superiores ao método global que é o utilizado em trabalhos relacionados, pelo que foi adotado no desenvolvimento do CT-FastNet.

Como trabalhos futuros, pretende-se estudar demais técnicas de segmentação e aperfeiçoá-las para poder trabalhar com pequenas bases de dados. Pois, muitas regiões, no início de determinadas doenças possuem poucas imagens para uso nos treinamentos.

REFERÊNCIAS

- Affonso, E. T., Rosa, R. L., and Rodríguez, D. Z. (2018). Speech quality assessment over lossy transmission channels using deep belief networks. *IEEE Signal Processing Letters*, 25(1):70–74.
- Akiba, T., Suzuki, S., and Fukuda, K. (2017). Extremely large minibatch sgd: Training resnet-50 on imagenet in 15 minutes.
- Alippi, C., Disabato, S., and Roveri, M. (2018). Moving convolutional neural networks to embedded systems: The alexnet and vgg-16 case. In *2018 17th ACM/IEEE International Conference on Information Processing in Sensor Networks (IPSN)*, pages 212–223.
- Apostolopoulos, I. and Tzani, M. (2020). Covid-19: Automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Australasian physical engineering sciences in medicine / supported by the Australasian College of Physical Scientists in Medicine and the Australasian Association of Physical Sciences in Medicine*, 43.
- Ardila, D., Kiraly, A., Bharadwaj, S., Choi, B., Reicher, J., Peng, L., Tse, D., Etemadi, M., Ye, W., Corrado, G., Naidich, D., and Shetty, S. (2019). End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography. *Nature Medicine*, 25:1.
- Chen, J., Wu, L., Zhang, J., Zhang, L., Gong, D., Zhao, Y., Hu, S., Wang, Y., Hu, X., Zheng, B., Zhang, K., Wu, H., Dong, Z., Xu, Y., Zhu, Y., Chen, X., Yu, L., and Yu, H. (2020). Deep learning-based model for detecting 2019 novel coronavirus pneumonia on high-resolution computed tomography: a prospective study. *medRxiv*.
- Chung, M., Bernheim, A., Mei, X., Zhang, N., Huang, M., Zeng, X., Cui, J., Xu, W., Yang, Y., Fayad, Z. A., Jacobi, A., Li, K., Li, S., and Shan, H. (2020). Ct imaging features of 2019 novel coronavirus (2019-ncov). *Radiology*, 295(1):202–207. PMID: 32017661.
- Colin ((accessed July 3, 2020)). Lung Analysis. <https://luna16.grandchallenge.org/data/>.
- Crestani, A. N. V., de Souza, P. S. S., dos Santos Marques, W., Konzen, M. P., and Rossi, F. D. (2018). Avaliando o desempenho do pytorch sobre gpu embarcadas. In *Anais da XVIII Escola Regional de Alto Desempenho do Estado do Rio Grande do Sul*, Porto Alegre, RS, Brasil. SBC.
- da Silva, M. J., Melgarejo, D. C., Rosa, R. L., and Rodríguez, D. Z. (2020). Speech quality classifier model based on DBN that considers atmospheric phenomena. *Journal of Communications Software and Systems*, 16(1):75–84.
- Dantas, R., Rosa, R. L., and Rodríguez, D. Z. (2019). Performance improvement of a nonintrusive voice quality metric in lossy networks. *IET Communications*, 13(20):3401–3408.
- de Almeida, F. L., Rosa, R. L., and Rodriguez, D. Z. (2018). Voice quality assessment in communication services using deep learning. In *Proc. 15th International Symposium on Wireless Communication Systems (ISWCS)*, pages 1–6.

de Radiologia Medica, S. I. (2020 (accessed July 3, 2020)). *Coronavirus (COVID-19)*. <https://www.sirm.org/category/senza-categoria/covid-19/>.

Dong, D., Tang, Z., Wang, S., Hui, H., Gong, L., Lu, Y., Xue, Z., Liao, H., Chen, F., Yang, F., Jin, R., Wang, K., Liu, Z., Wei, J., Mu, W., Zhang, H., Jiang, J., Tian, J., and Li, H. (2020). The role of imaging in the detection and management of covid-19: a review. *IEEE Reviews in Biomedical Engineering*, PP:1–1.

Eduardo, P. (2020 (accessed July 3, 2020)). *SARS-COV-2 Ct-Scan Dataset*. <https://www.kaggle.com/plameneduardo/sarscov2-ctscan-dataset>.

Fang, M., He, B., Li, L., Dong, D., Yang, X., Li, C., Meng, L., Zhong, L., Li, H., Li, H., and Tian, J. (2020). Ct radiomics can help screen the coronavirus disease 2019 (covid-19): a preliminary study. *Science China Information Sciences*, 63.

He, K., Zhang, X., Ren, S., and Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In *2015 IEEE International Conference on Computer Vision (ICCV)*, pages 1026–1034.

Hemdan, E. E.-D., Shouman, M. A., and Karar, M. E. (2020). Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images.

Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., and Keutzer, K. (2016). Squeezenet: Alexnet-level accuracy with 50x fewer parameters and 0.5mb model size.

Lasmar, E. L., de Paula, F. O., Rosa, R. L., Abrahao, J. I., and Rodriguez, D. Z. (2019). Rsr: Ridesharing recommendation system based on social networks to improve the user's qoe. *IEEE Transactions on Intelligent Transportation Systems*, 20(12):4728–4740.

LeCun, Y., Bengio, Y., and Hinton, G. (2015). Deep learning. *nature*, 521(7553):436–444.

Nair, V. and Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th International Conference on International Conference on Machine Learning*, page 807–814, Madison, WI, USA.

Ourworldindata. (2020 (accessed July 3, 2020)). *Coronavirus (COVID-19)*. <https://ourworldindata.org/covid-cases>.

Pinto, D. C. G., Vidigal, T. d. A., Castro, B. d., Santos, B. H. d., and Sousa, N. J. A. d. (2008). Doença de Rosai-Dorfman com o diagnóstico diferencial de linfadenopatia cervical. *Revista Brasileira de Otorrinolaringologia*, 74:632 – 635.

Ramachandran, P., Zoph, B., and Le, Q. V. (2017). Searching for activation functions.

Rodríguez, D. Z. and Moller, S. (2019). Speech quality parametric model that considers wireless network characteristics. In *2019 Eleventh International Conference on Quality of Multimedia Experience (QoMEX)*, pages 1–6.

- Roosa, K., Lee, Y., Luo, R., Kirpich, A., Rothenberg, R., Hyman, J., Yan, P., and Chowell, G. (2020). Real-time forecasts of the covid-19 epidemic in china from february 5th to february 24th, 2020. *Infectious Disease Modelling*, 5:256 – 263.
- Rosa, R. L., Schwartz, G. M., Ruggiero, W. V., and Rodríguez, D. Z. (2019). A knowledge-based recommendation system that includes sentiment analysis and deeplearning. *IEEE Transactions on Industrial Informatics*, 15(4):2124–2135.
- Rothan, H. A. and Byrareddy, S. N. (2020). The epidemiology and pathogenesis of coronavirus disease (covid-19) outbreak. *Journal of Autoimmunity*, 109:102433.
- Seifoddini, H. and Djassemi, M. (1991). The production data-based similarity coefficiente versus jaccard's similarity coefficient. *Computers Industrial Engineering*, 21(1):263 – 266.
- Shi, H., Han, X., Jiang, N., Cao, Y., Alwalid, O., Gu, J., Fan, Y., and Zheng, C. (2020). Radiological findings from 81 patients with covid-19 pneumonia in wuhan, china: a descriptive study. *The Lancet Infectious Diseases*, 20(4):425 – 434.
- Sombra, T. R., Santini, R. M., Morais, E. C., Walmir Oliveira Couto, A. d. J. Z., da Silva Campos, P. S., de Almeida, J. F. S., and Chase, O. A. (2020). Scientific social networks and artificial intelligence - a systematic review applied to recognition of standards. *Brazilian Journal of Development*, 6(3):9941–9954.
- Song, S., Wu, F., Liu, Y., Jiang, H., Xiong, F., Guo, X., Zhang, H., Zheng, C., and Yang, F. (2020). Correlation Between Chest CT Findings and Clinical Features of 211 COVID- 19 Suspected Patients in Wuhan, China. *Open Forum Infectious Diseases*, 7(6).
- Suzuki, K. (2017). Overview of deep learning in medical imaging. *Radiological Physics and Technology*, 10.
- Venkatesh, G., Nurvitadhi, E., and Marr, D. (2017). Accelerating deep convolutional networks using low-precision and sparsity. In *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 2861–2865.
- Wang, H., Wang, Z., Dong, Y., Chang, R., Xu, C., Yu, X., Zhang, S., Tsamlag, L., Shang, M., Huang, J., Wang, Y., Xu, G., Shen, T., Zhang, X., and Cai, Y. (2020). Phaseadjusted estimation of the number of coronavirus disease 2019 cases in wuhan, china. *Cell Discovery*, 6.
- Wang, X., Deng, X., Fu, Q., Zhou, Q., Feng, J., Ma, H., Liu, W., and Zheng, C. (2020). A weakly-supervised framework for covid-19 classification and lesion localization from chest ct. *IEEE Transactions on Medical Imaging*, pages 1–1.
- Wong, H. Y. F., Lam, H., Fong, A. H.-T., Leung, B. S. T., Chin, T., Lo, C., Lui, M., Lee, J., Chiu, W. H., Chung, T., Lee, E., Wan, E., Hung, F., Lam, T., Kuo, M., and Ng, M.-Y. (2020). Frequency and distribution of chest radiographic findings in covid 19 positive patients. *Radiology*, page 201160.

Wu, Z., Shen, C., and [van den Hengel], A. (2019). Wider or deeper: Revisiting the resnet model for visual recognition. *Pattern Recognition*, 90:119 – 133.

Yang, X., He, X., Zhao, J., Zhang, Y., Zhang, S., and Xie, P. (2020). Covid-ct-dataset: A ct scan dataset about covid-19.

Yong, S. E. F., Anderson, D. E., Wei, W. E., Pang, J., Chia, W. N., Tan, C. W., Teoh, Y. L., Rajendram, P., Toh, M. P. H. S., Poh, C., Koh, V. T. J., Lum, J., Suhaimi, N.- A. M., Chia, P. Y., Chen, M. I.-C., Vasoo, S., Ong, B., Leo, Y. S., Wang, L., and Lee, V. J. M. (2020). Connecting clusters of covid-19: an epidemiological and serological investigation. *The Lancet Infectious Diseases*, 20(7):809 – 815.

Zhou, Y., Li, D., Huo, S., and Kung, S.-Y. (2020). Soft-root-sign activation function.

Zhou, Z., Siddiquee, M. M. R., Tajbakhsh, N., and Liang, J. (2018). Unet++: A nested u-net architecture for medical image segmentation.

Ênio dos Santos Silva, da Silva, D. H., dos Santos Albuquerque, A., and Bastos, R. C. (2020). Proposal for a teaching tool of artificial intelligence using learning by enhancement applied to the solution of dynamic mazes. *Brazilian Journal of Development*, 6(3):13107–13118.