

# Comparação de Modelos Neurais de Classificação de Imagens de Raios-X para Detecção de COVID-19

Jimi Togni e Romis Attux

**Resumo**— Este trabalho apresenta uma análise comparativa de métodos para detecção de infecção por COVID-19 em imagens radiográficas. As imagens utilizadas, pertencentes a bases disponibilizadas publicamente, foram divididas em três categorias: 'normal', 'pneumonia' e 'covid'. Para a realização dos experimentos, empregando transferência de aprendizagem, foram utilizadas oito redes pré-treinadas: SqueezeNet, DenseNet, ResNet, AlexNet, VGG, GoogleNet, ShuffleNet, MobileNet. A rede DenseNet obteve a melhor acurácia, com 97,64%, ao usar a função de otimização ADAM na abordagem multiclasse. Na abordagem binária, obteve-se um melhor resultado em termos de precisão: 99,98% para as redes VGG, ResNet e MobileNet. Realizou-se ainda uma avaliação comparativa baseada em mapas de calor.

**Palavras-Chave**— Aprendizado de Máquina, Transferência de Aprendizado, Covid-19.

**Abstract**— This work presents a comparative analysis of methods for detecting COVID-19 in radiographic images. The images were obtained from public databases and divided into three categories: 'normal', 'pneumonia' and 'covid'. Eight pre-trained networks were used for transfer learning: SqueezeNet, DenseNet, ResNet, AlexNet, VGG, GoogleNet, ShuffleNet, MobileNet. The DenseNet network obtained the best accuracy, with 97.64%, when using the ADAM optimization function in the multiclass approach. For the binary approach, the best result in terms of accuracy (99.98%) was obtained for VGG, ResNet and MobileNet networks. Finally, a comparative evaluation was carried out with the aid of heat maps.

**Keywords**— Machine learning, Transfer Learning, Covid-19.

## I. INTRODUÇÃO

Em 2020, o mundo foi impactado por uma pandemia provocada por um vírus denominado SARS-CoV-2 (geralmente chamado de 'coronavírus' [1]). Após um rápido crescimento no número de casos na China, a doença se espalhou pelo planeta, tendo sido confirmados, no início de maio de 2021, mais de 150 milhões de casos e 3,2 milhões de mortes.

As duas formas de detecção mais utilizadas são, segundo o Ministério da Saúde do Brasil [2], os testes realizados por meio das técnicas de RT-PCR em tempo real e sequenciamento parcial ou total do genoma viral. Outra técnica é o Teste Rápido, que é utilizado para detecção de anticorpos (IgM e IgC) contra o coronavírus na pessoa infectada, tendo por base a metodologia de cromatografia de fluxo lateral. Apesar da

Jimi Togni, DSPCOM/FEEC, UNICAMP, Campinas-SP, e-mail: j226359@dac.unicamp.br; Romis Attux, DSPCOM/FEEC, UNICAMP, Campinas-SP, e-mail: attux@dca.fee.unicamp.br. Este trabalho foi parcialmente financiado pelo CNPq (157956/2019-9, 308811/2019-4).

relevância desses testes, questões como tempo de processamento e custo podem ser fatores limitantes [2], o que abre espaço para a possibilidade de apoio através de ferramentas rápidas de detecção automática.

Muitos trabalhos abordam a detecção de COVID-19 a partir de imagens de raios-X, como mostram diversos 'surveys' recentes S. Bhattacharya et. al. (2021) [3]. Alguns deles foram importantes para o desenvolvimento de nossa proposta. No trabalho feito por S. Basu (2020) [4], os autores utilizaram a transferência de aprendizado em um contexto com 4 classes: 'normal', 'pneumonia', 'covid19' e 'outras doenças', a acurácia geral foi de 90,13%. Um trabalho semelhante foi R. Jain et. al. (2021) [5], nele, os autores utilizaram modelos pré-treinados Inception V3, Xception, e ResNeXt. Havia no conjunto de dados 6432 imagens de raios-X do tórax, sendo 5467 usadas para treinamento e 965 imagens para validação, a rede Xception foi a que obteve a maior acurácia, com 97,97%.

O objetivo deste trabalho é realizar uma análise comparativa de métodos para a detecção de um quadro causado pelo vírus SARS-CoV-2 a partir de imagens de raios-X do tórax. Propõe-se utilizar redes neurais convolucionais (CNN - do inglês Convolutional Neural Networks), e, pela quantidade relativamente pequena de dados disponíveis, a estratégia de transferência de aprendizado (TL - do inglês Transfer Learning). As imagens de raios-X do tórax, neste trabalho, obtidas em bases públicas de dados [6], são classificadas como: 'normal' ou seja, sem presença das características de covid-19, 'pneumonia' quando o modelo encontra as características de pneumonia nas imagens e 'covid' quando são encontrados padrões de contaminação pelo SARS-CoV-2 na imagem de raios-X. Para isso, as redes convolucionais são treinadas com imagens pré-classificadas por um especialista, em uma abordagem supervisionada. Quando infectado, o paciente tem seus pulmões afetados, ocasionando pneumonia grave, edema pulmonar, síndrome de desconforto respiratório agudo (SDRA) ou falência de múltiplos órgãos, gerando um padrão peculiar de infecção nos pulmões quando se analisam as imagens de raios-X [1].

O trabalho está organizado da seguinte forma: na Seção II, foi exposta a proposta do trabalho, e, na Seção III, detalhou-se a metodologia utilizada; a Seção IV tem por objetivo avaliar os elementos das imagens que levam à diferenciação entre as classes, utilizando, para isso, o mapeamento de ativação por calor; os resultados de todos os testes realizados são discutidos na Seção V, e, finalmente, as conclusões são apresentadas na Seção VI.

## II. PROPOSTA

Neste trabalho, fez-se uso de uma abordagem online para geração do conjunto de dados. Nela, o conjunto físico de dados não sofre alteração: as transformações são feitas a cada incremento das épocas na fase de treinamento do modelo, ou seja, a cada época de treinamento concluída, as imagens são transformadas de acordo com as especificações definidas. Essa estratégia tem sido usada comumente na literatura, e é importante devido ao risco de enviesamento causado pela quantidade relativamente pequena de imagens disponíveis.

Nos testes de classificação multiclasse, foram utilizadas imagens radiográficas rotuladas por especialistas de acordo com as seguintes classes: 'normal', 'pneumonia' e 'covid'. Já no teste binário, apenas as classes 'pneumonia' e 'covid' foram utilizadas. O número total de imagens obtidas foi de 3856. O conjunto de dados contendo as imagens utilizadas foi obtido no website Kaggle [6]. As imagens obtidas originalmente não possuíam nenhum tipo de padronização em relação a tamanho, resolução ou brilho, a padronização das imagens foi feita na etapa de redimensionamento para um tamanho padrão. Para a realização dos testes com aumento de dados online, todas as imagens sofreram as seguintes transformações: normalização do tamanho seguindo o padrão de 224 pixels de altura por 224 pixels de largura; rotação das extremidades com ponto fixo no centro das imagens de -10 a +10 graus, a cada época, e de forma aleatória, e inversão horizontal aplicada com 5% de probabilidade a cada imagem e a cada época. Na Figura 1, pode-se observar exemplos aleatórios de imagens de todas as classes. O número final de imagens nos conjuntos de teste, treinamento e validação são mostrados nas Tabelas I e II.

## III. METODOLOGIAS AVALIADAS

Um ponto importante para este trabalho foi a aplicação da transferência de aprendizado [7]. Transferência de aprendizado (TL, do inglês transfer learning) é uma técnica que possibilita a utilização de certo número de camadas de uma CNN já treinada. No caso de uma tarefa como a que estamos analisando, uma possibilidade é considerar redes testadas em competições de reconhecimento de imagens, como a 'ImageNet Large Scale Visual Recognition Challenge (ILSVRC)' ou ImageNet Challenge [8]. Esses modelos são treinados com um grande número de imagens de diferentes categorias, como imagens de animais, carros e objetos cotidianos [9]. Tanto a base quanto algumas das redes estão disponíveis, facilitando a criação e a avaliação de novos modelos. Note-se que é possível usar as redes já treinadas e realizar treinamento sobre quaisquer partes da estrutura. Isso significa que é possível aproveitar, por exemplo, as camadas iniciais da rede - já treinadas para a tarefa geral de reconhecimento de imagens - e treinar especificamente apenas algumas camadas finais sobre o problema abordado [10]. É dessa forma que usaremos TL no trabalho, e a principal motivação é a pequena quantidade de imagens de raios-X disponíveis para treinamento de um sistema de classificação envolvendo a COVID-19.

O conjunto de imagens foi dividido em três partes: Treinamento, Validação e Teste. Esta divisão foi feita, inicialmente, nas proporções de 80% para treinamento, 19% para validação

e 1% para teste. Optou-se por esta forma de divisão, com apenas 1% para o conjunto de teste, pois, no momento em que este trabalho estava sendo realizado, era possível adquirir novas imagens de raios-X previamente diagnosticadas como pertencentes à classe 'covid' diariamente, no repositório do Github [11], tornando assim, a inclusão dessas novas imagens nos conjuntos de treinamento e validação impraticável, uma vez que teríamos que retreinar todos os modelos novamente. Portanto, todas as novas imagens que recebemos após a fase de treinamento das redes foram colocadas apenas na pasta de teste, como forma de garantir que nossos modelos estariam aptos para fazer uma boa generalização com as novas imagens obtidas após seu treinamento. Na Tabela II, pode-se verificar a quantidade total de imagens e as quantidades de cada classe. Diante do exposto, na finalização deste trabalho, a pasta 'teste' possuía 387 imagens normalizadas, proporcionando uma melhor avaliação da capacidade de generalização dos modelos testados.

Em todos os testes, o número de épocas (EP) foi igual a 100 e as taxas de aprendizado (LR, do inglês 'learning rate') foram  $10^{-3}$ ,  $10^{-4}$ ,  $10^{-5}$ . Optou-se por um conjunto de otimizadores (OPT) diversificado e representativo: ADAM (Adaptive Moment Estimation), SGD (Stochastic Gradient Descent) e RMSProp [12]. A quantidade de amostras utilizadas em cada iteração de treinamento - conhecida como 'batch size' (BS) - variou entre 8, 16 e 32. O critério (CRT) escolhido para quantificar o erro foi a Entropia Cruzada (CE) na abordagem multiclasse e a Entropia Cruzada Binária (BCE) para a abordagem binária. A acurácia é apontada pela sigla (ACC) nas tabelas. O framework que auxilia a execução das técnicas de aprendizado de máquina utilizado nos testes foi o PyTorch.

A partir do desempenho reportado na literatura e de testes preliminares, as seguintes redes foram selecionadas para compor, através de TL, os classificadores: AlexNet [13], que foi a vencedora a competição ImageNet de 2012 [8]; DenseNet [14], que propõe uma arquitetura que garante o máximo fluxo de informações básicas entre as camadas; GoogleNet [15], que na competição ILSVRC de 2014 usou 12 vezes menos parâmetros do que a rede vencedora da época; MobileNet [16], baseada na ideia de se ter uma rede especificamente adaptada para celulares e recursos restritos, diminuindo significativamente o número de operações e a memória necessária, e mantendo a mesma precisão; ResNet [17], rede residual de 152 camadas que venceu a competição de classificação ILSVRC 2015; ShuffleNet [18], que alcançou um desempenho superior, por uma margem significativa, em relação ao primeiro colocado na ImageNet no nível de 40 MFLOPs; SqueezeNet [19], que alcança uma precisão do nível da rede AlexNet, no conjunto de dados da ImageNet, porém com 50 vezes menos parâmetros, e a rede VGG [20], que participou do ImageNet Challenge de 2014 [21], onde garantiu primeiro e segundo lugares na competição, nas categorias de detecção e classificação de imagens, respectivamente.

## IV. MAPAS DE CALOR

O Mapeamento de Ativação das Classes, também conhecido como CAM ('Class Activation Mapping') ou mapa de calor

TABELA I  
Número total de imagens por classes.

Classes	Imagens
Normal (Nm)	1341
Pneumonia (Pn)	1345
Covid (Cv)	1170
Total	3856

TABELA II  
Número de imagens para cada classe divididas entre os conjuntos de dados utilizados para treinamento, validação e teste.

Classes	Divisão do conjunto de dados		
	Treino	Teste	Validação
Normal (Nm)	1051	14	255
Pneumonia (Pn)	1097	13	240
Covid (Cv)	937	11	238
Total	3085	38	733

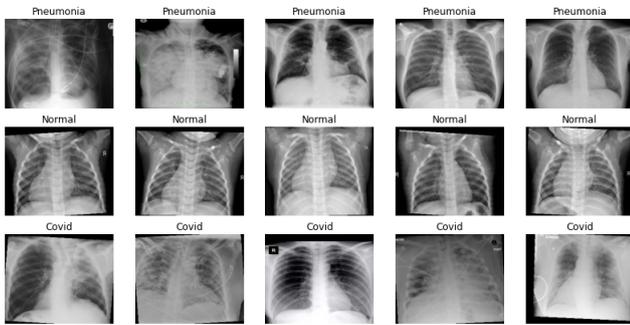


Fig. 1. Amostra de imagens para cada classe com as transformações aplicadas no aumento de dados.

(‘Heat Map’), tem por objetivo mostrar quais partes são particularmente relevantes para a rede no momento da classificação. A cor vermelha indica forte ativação de uma região, o amarelo indica uma ativação um pouco menor e as cores azul-claro e azul-escuro representam baixa ou nenhuma ativação no local.

Nas Figuras 2 e 3, pode-se observar que, do ponto de vista das redes neurais convolucionais utilizadas neste trabalho, as classes ‘covid’ e ‘pneumonia’ são bastante distintas. As imagens da classe ‘pneumonia’ têm a maior concentração de calor (em vermelho) do lado esquerdo do tórax. Este padrão parece razoável em comparação com as imagens de raios-X explicadas no site ‘Radiology Assistant - Educational site of the Radiological Society of the Netherlands’ [22], embora uma análise mais rigorosa só possa ser feita, no futuro, com o auxílio de um especialista. Já as imagens classificadas como ‘covid’ têm a maior concentração de calor no lado direito e esquerdo superior do tórax, o que parece similar ao discutido em [23].

## V. RESULTADOS

As Tabelas III e IV mostram os melhores resultados de cada rede e quais foram os melhores hiperparâmetros utilizados. Podem-se observar os valores de sensibilidade, precisão e

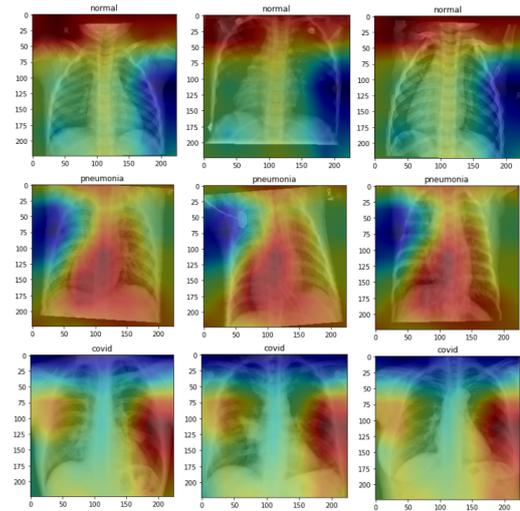


Fig. 2. Mapa de Calor para classificação multiclasse.

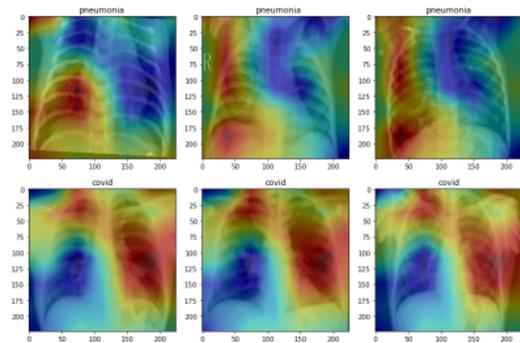


Fig. 3. Mapa de Calor para classificação binária.

pontuação F1, para a abordagem multiclasse na Tabela V e para a abordagem binária na Tabela IV.

TABELA III  
Hiperparâmetros que levaram à melhor acurácia de validação para a abordagem multiclasse.

Modelos	EP	LR	BS	OPT	CRT	ACC
AlexNet	100	$10^{-4}$	8	ADAM	CE	94,50%
DenseNet			16			97,64%
GoogLeNet			8			95,81%
MobileNet			8			96,46%
ResNet			8			96,20%
ShuffleNet			8			95,15%
SqueezeNet			16			96,60%
VGG	8	96,20%				

As Tabelas VII e VIII apresentam os desempenhos das redes para cada um dos classificadores, a fim de encontrar o método de melhor acurácia total. Após terem sido testados todos os hiperparâmetros descritos na Seção III, observou-se que o melhor resultado foi obtido para uma taxa de aprendizado de  $10^{-4}$  em conjunto com o otimizador ADAM, como pode-se observar na Tabela III. Não obstante, os outros dois otimizadores (SGD e RMSprop) tiveram performances melhores ou iguais em alguns casos, e.g. nos modelos da MobileNet e

TABELA IV

Hiperparâmetros que levaram à melhor acurácia de validação para a abordagem binária.

Modelos	EP	LR	BS	OPT	CRT	ACC
AlexNet	100	10 <sup>-4</sup>	16	SGD	BCE	99,06%
DenseNet				ADAM		99,94%
GoogLeNet				ADAM		99,63%
MobileNet				ADAM		99,98%
ResNet				ADAM		99,98%
ShuffleNet				RMSprop		99,81%
SqueezeNet				SGD		99,56%
VGG				RMSprop		99,98%

TABELA V

Maior precisão obtida intra-idade, de cada rede para a abordagem multiclasse.

Modelos	Sens %			Precisão %			F1 Score %		
	Nm	Cv	Pn	Nm	Cv	Pn	Nm	Cv	Pn
AlexNet	96	95	91	98	92	95	97	93	92
Dense	97	97	96	100	96	96	99	97	96
Google	97	97	96	100	96	96	99	97	96
Mobile	96	95	95	100	95	95	96	95	95
ResNet	95	94	95	100	95	95	94	95	95
Shuffle	96	94	93	99	93	94	96	94	94
Squeeze	97	97	95	99	95	96	98	96	95
Vgg	94	95	95	100	95	95	96	95	94

TABELA VI

Maior precisão obtida intra-idade, de cada rede para a abordagem binária.

Modelos	Sens %		Precisão %		F1 Score %	
	Cv	Pn	Cv	Pn	Cv	Pn
AlexNet	99	99	99	99	99	99
Dense	99	99	99	99	99	99
Google	100	99	99	100	100	100
Mobile	100	100	100	100	100	100
ResNet	100	100	100	100	100	100
Shuffle	100	100	100	100	100	100
Squeeze	100	100	100	100	100	100
Vgg	99	99	99	99	99	99

TABELA VII

Melhor acurácia atingida em relação a cada classificador e otimizadores testados na abordagem multiclasse.

Modelos	Acurácia Média		
Parametros	SGD	ADAM	RMSProp
SqueezeNet	95,94%	96,59%	96,33%
DenseNet	97,25%	97,64%	97,38%
ResNet	96,22%	96,01%	96,18%
VGG	97,38%	97,59%	97,55%
AlexNet	95,85%	95,76%	95,76%
GoogLeNet	96,53%	96,55%	96,43%
MobileNet	97,51%	97,51%	97,47%
ShuffleNet	92,32%	97,18%	96,93%

TABELA VIII

Melhor acurácia atingida em relação a cada classificador testado na abordagem binária.

Modelos	Acurácia Média		
Parametros	SGD	ADAM	RMSProp
SqueezeNet	99,56%	99,08%	98,08%
DenseNet	99,90%	99,94%	99,05%
ResNet	99,10%	99,63%	99,98%
VGG	99,52%	99,77%	99,98%
AlexNet	99,06%	98,88%	98,76%
GoogLeNet	99,63%	99,23%	98,87%
MobileNet	99,83%	99,98%	99,87%
ShuffleNet	99,55%	99,53%	99,81%

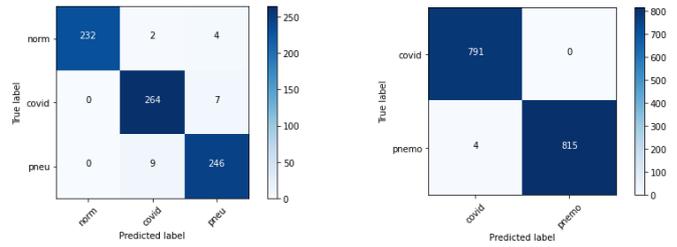


Fig. 4. Matriz de confusão para abordagem multiclasse à esquerda e, à direita, resultados da abordagem binária.

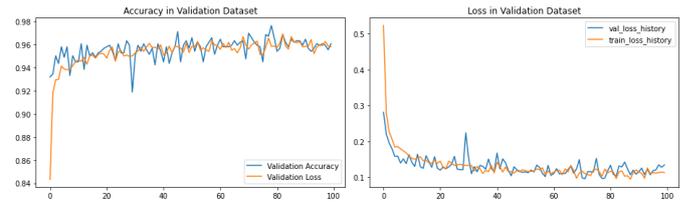


Fig. 5. Curvas da abordagem multiclasse para o melhor resultado obtido entre todas as redes testadas com o modelo DenseNet.

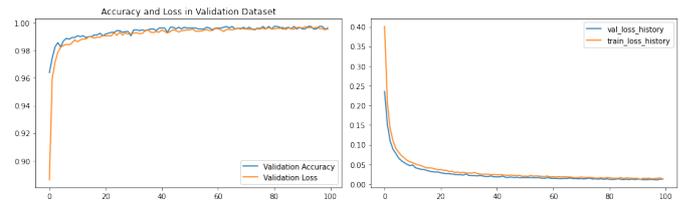


Fig. 6. Curvas da abordagem binária para o melhor resultado obtido com o modelo MobileNet que obteve as melhores acurácias em relação aos três otimizadores testados, como demonstrado na Tabela VIII.

ResNet, como demonstrado na Tabela VII.

O melhor resultado obtido, entre todas as redes testadas neste trabalho, na abordagem multiclasse, foi alcançado com a rede DenseNet, conforme demonstrado na Tabela VII. Com o uso do otimizador ADAM, uma precisão de 97,64% foi atingida. Pode-se observar também, na Tabela V, sua acurácia de sensibilidade, precisão e pontuação F1. Na Figura 4, é

possível observar as matrizes de confusão resultantes dos testes da rede DenseNet, tanto em configuração multiclasse (Figura 4 à esquerda) quanto binária (Figura 4 à direita). Na Figura 5, mostra-se a evolução da precisão e da taxa de erro para o caso multiclasse, e, na Figura 6, quando se aborda o problema de forma binária.

## VI. CONCLUSÕES

Neste trabalho, realizou-se uma análise comparativa de diferentes abordagens de redes neurais na solução do problema de classificação de imagens de raios-X de tórax. A meta era permitir a detecção de padrões correspondentes àqueles

de pacientes com COVID-19, fornecendo subsídios para a pesquisa nessa área de grande relevância no contexto atual.

Os resultados mostram que há diferentes estruturas convolucionais que abordam de maneira competente o problema de classificação em esquema de transferência de aprendizado. A DenseNet se mostra uma opção bem interessante, e cabe, agora realizar uma investigação mais ampla sobre seu desempenho tendo em vista a perspectiva de uma aplicação mais próxima da realidade do diagnóstico clínico. Para tanto, em um trabalho futuro, seria importante cooperar com os profissionais da área médica, buscando formar uma base ampla de imagens e aproximando as condições de projeto da estrutura presente àqueles que atuam na linha de frente.

#### AGRADECIMENTOS

Os autores agradecem ao CNPq o apoio financeiro.

#### REFERÊNCIAS

- [1] X. Zhang, Y. Tan, Y. Ling, G. Lu, F. Liu, Z. Yi, X. Jia, M. Wu, B. Shi, S. Xu *et al.*. “Viral and host factors related to the clinical outcome of COVID-19”. *Nature*, vol. 583, no. 7816, pp. 437–440, 2020.
- [2] *Ministério da Saúde do Brasil. Diagnóstico Clínico e Laboratorial*, (Acessado em: 2020-11-05). <https://coronavirus.saude.gov.br/diagnostico-clinico-e-laboratorial>.
- [3] S. Bhattacharya, P. K. Reddy Maddikunta, Q.-V. Pham, T. R. Gadekallu, S. R. Krishnan S, C. L. Chowdhary, M. Alazab and M. Jalil Piran. “Deep learning and medical image processing for coronavirus (COVID-19) pandemic: A survey”. *Sustainable Cities and Society*, vol. 65, pp. 102589, 2021.
- [4] S. Basu, S. Mitra and N. Saha. “Deep Learning for Screening COVID-19 using Chest X-Ray Images”, 2020.
- [5] R. Jain, M. Gupta, S. Taneja and D. J. Hemanth. “Deep learning based detection and analysis of COVID-19 on chest X-ray images”. *Applied Intelligence*, vol. 51, no. 3, pp. 1690–1700, 2021.
- [6] T. Rahmann. *COVID-19 Radiography Database on Kaggle*, (Acessado em: 2020-11-05). <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>.
- [7] S. J. Pan and Q. Yang. “A Survey on Transfer Learning”. *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, no. 10, pp. 1345–1359, 2010.
- [8] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein *et al.*. “Imagenet large scale visual recognition challenge”. *International journal of computer vision*, vol. 115, no. 3, pp. 211–252, 2015.
- [9] *ImageNet Project. ImageNet Overview*, (Acessado em: 2020-11-05). <http://www.image-net.org/about-overview>.
- [10] I. Goodfellow, Y. Bengio and A. Courville. *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.
- [11] J. P. Cohen, P. Morrison, L. Dao, K. Roth, T. Q. Duong and M. Ghassemi. *Covid-19 image data collection: Prospective predictions are the future*, (Acessado em: 2020-11-05). <https://github.com/ieee8023/covid-chestxray-dataset>.
- [12] *Torch Contributors. Otimizadores utilizados e suas diferenças*, (Acessado em: 2020-11-05). <https://pytorch.org/docs/stable/optim.html>.
- [13] A. Krizhevsky, I. Sutskever and G. E. Hinton. “Imagenet classification with deep convolutional neural networks”. *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, 2017.
- [14] G. Huang, Z. Liu, L. Van Der Maaten and K. Q. Weinberger. “Densely Connected Convolutional Networks”. In *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2261–2269, 2017.
- [15] C. Szegedy, Wei Liu, Yangqing Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke and A. Rabinovich. “Going deeper with convolutions”. In *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1–9, 2015.
- [16] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov and L.-C. Chen. “Mobilenetv2: Inverted residuals and linear bottlenecks”. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 4510–4520, 2018.
- [17] K. He, X. Zhang, S. Ren and J. Sun. “Deep Residual Learning for Image Recognition”. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778, 2016.
- [18] X. Zhang, X. Zhou, M. Lin and J. Sun. “Shufflenet: An extremely efficient convolutional neural network for mobile devices”. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 6848–6856, 2018.
- [19] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally and K. Keutzer. “SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size”. *arXiv preprint arXiv:1602.07360*, 2016.
- [20] S. Liu and W. Deng. “Very deep convolutional neural network based image classification using small training sample size”. In *2015 3rd IAPR Asian Conference on Pattern Recognition (ACPR)*, pp. 730–734, 2015.
- [21] *ImageNet Project. The ImageNet Large Scale Visual Recognition Challenge (ILSVRC)*, (Acessado em: 2020-11-05). <http://www.image-net.org/challenges/LSVRC/>.
- [22] *Radiology Assistant - Educational site of the Radiological Society of the Netherlands. These images are of a young patient with pneumonia*, (Acessado em: 2021-04-15). <https://radiologyassistant.nl/chest/chest-x-ray>.
- [23] *Radiology Assistant - Educational site of the Radiological Society of the Netherlands. 83 year old male with mitral insufficiency and pulmonary hypertension was diagnosed with COVID-19 infection*, (Acessado em: 2021-04-15). <https://radiologyassistant.nl/chest/covid-19/covid19-imaging-findings>.