



Classificação de padrões de esclerodermia utilizando deep learning

Classification of scleroderma patterns using deep learning

Clasificación de patrones de esclerodermia mediante aprendizaje profundo

Fabio Cardoso¹, Verônica Silva Vilela², Ronaldo Carvalho Araújo Filho³, Agnaldo Lopes⁴, Roberto Mogami², Karla Figueiredo⁵

1 Aluno de mestrado, Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro (RJ), Brasil.

2 PhD/Professor, Faculdade de Ciências Médicas, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro (RJ), Brasil.

3 MSc/Médico Radiologista, Hospital Pedro Ernesto, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro (RJ), Brasil.

4 PhD/Professor, Hospital Pedro Ernesto, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro (RJ), Brasil.

5 PhD/Professor, Ciência da Computação, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro (RJ), Brasil.

Autor correspondente: Fabio Cardoso

E-mail: slynricks@gmail.com

Resumo

Objetivo: A esclerodermia é uma doença que não é conhecida a causa e tem como consequência o enrijecimento da pele e dos órgãos internos. Diante disso, este trabalho tem como objetivo desenvolver modelos de deep learning para auxiliar os médicos na avaliação da progressão e mortalidade da doença. **Método:** Foram desenvolvidos modelos de classificação de padrões PIU e PINE com a arquitetura MobileNetV2, VGG16, ResNet50 e EfficientNet para imagens de tomografia computadorizada de pacientes com esclerodermia. **Resultados:** Todos os modelos alcançaram acurácia de 100% nos conjuntos de treino, validação e teste e, portanto, foi possível realizar a diferenciação dos padrões apresentados nas imagens de tomografia computadorizada de pacientes que estiveram no Hospital Pedro Ernesto durante o período de 2017 e 2022. **Conclusão:** Dentre os modelos avaliados, o melhor é a MobileNetV2 devido possuir a menor quantidade de parâmetros entre todas as arquiteturas avaliadas neste trabalho.

Descritores: Deep Learning; Classificação; Esclerodermia.



Abstract

Objective: Scleroderma is a disease whose cause is unknown and which results in the stiffening of the skin and internal organs. This study aims to develop deep learning models to help doctors assess the progression and mortality of the disease.

Method: PIU and PINE pattern classification models were developed with the MobileNetV2, VGG16, ResNet50 and EfficientNet architecture for computerized tomography images of patients with scleroderma. **Results:** All the models achieved 100% accuracy in the training, validation and test sets and, therefore, it was possible to differentiate the patterns presented in the computerized tomography images of patients who were at the Pedro Ernesto Hospital between 2017 and 2022.

Conclusion: Among the models evaluated, MobileNetV2 is the best because it has the fewest parameters of all the architectures evaluated in this study.

Keywords: Deep Learning; Classification; Scleroderma.

Resumen

Objetivo: La esclerodermia es una enfermedad cuya causa se desconoce y que provoca la rigidez de la piel y de los órganos internos. En vista de ello, este trabajo pretende desarrollar modelos de aprendizaje profundo para ayudar a los médicos a evaluar la progresión y mortalidad de la enfermedad. **Método:** Se desarrollaron modelos de clasificación de patrones PIU y PINE con la arquitectura MobileNetV2, VGG16, ResNet50 y EfficientNet para imágenes de tomografía computarizada de pacientes con esclerodermia. **Resultados:** Todos los modelos alcanzaron una precisión del 100% en los conjuntos de entrenamiento, validación y prueba y, por lo tanto, fue posible diferenciar los patrones presentados en las imágenes de tomografía computarizada de los pacientes que estuvieron en el Hospital Pedro Ernesto entre 2017 y 2022. **Conclusión:** Entre los modelos evaluados, MobileNetV2 es el mejor porque tiene el menor número de parámetros de todas las arquitecturas evaluadas en este estudio.

Descriptores: Deep Learning; Clasificación; Esclerodermia.

Introdução

A esclerodermia é uma doença que se apresenta com o enrijecimento da pele e dos órgãos internos, afetando o funcionamento normal destes⁽¹⁾. Essa doença



ainda não possui causa conhecida e acomete 44 a cada 100,000 pessoas⁽²⁾ e, portanto, é um assunto de grande interesse da reumatologia. Atualmente o diagnóstico de esclerodermia é realizado através de dados clínicos, laboratoriais e de imagem⁽³⁾. Além disso, a classificação é feita através dos critérios do Colégio Americano de Reumatologia (ACR) e da Liga Europeia Contra o Reumatismo (ACR/EULAR) de 2013⁽⁴⁾.

Utilizando dados de imagem é possível identificar a progressão e a mortalidade da doença através da busca de padrões em imagens de Tomografia Computadorizada no Tórax (TC-Tórax). Os padrões principais são a pneumopatia usual (PIU) e a pneumopatia intersticial não específica (PINE)^(5,6), porém são padrões de difícil distinção, pois o padrão PINE em um estado grave pode ser confundido com o padrão PIU. Além disso, o padrão PINE acontece em 80-90% dos casos e possui melhor prognóstico do que o padrão PIU.

Uma das vantagens para o uso de *Deep Learning* (DL)⁽⁷⁾ em imagens de exames de pacientes, sejam em imagens de Raio-X ou TC, seja para classificar ou segmentar (duas das principais tarefas mais frequentes em imagens médicas), está no apoio aos radiologistas na análise de grandes quantidades de imagens de radiográficas^(8,9).

Susanto et al.⁽¹⁰⁾ realizaram a comparação e avaliação do desempenho das arquiteturas MobileNetV3 Large, MobileNetV3 Small, MobilenetV2, ResNet101 e EfficientNetB0 para tarefa de classificação e segmentação de COVID-19 e a arquitetura MobileNetV2 obteve o melhor resultado alcançando precisão de 81%.

TÜRK et al.⁽¹¹⁾ apresentaram um trabalho para classificação de COVID-19 com imagens de TC, tendo como melhor modelo encontrado a MobileNet com acurácia de 95%, o que mostra bons resultados da arquitetura em classificação de padrões em imagens de TC.

As arquiteturas da família MobileNet possuem a característica de serem leves e poderem realizar inferências e treinamentos em dispositivos com apenas CPU integrado. Almeida et al.⁽¹²⁾ propõe a utilização desta arquitetura para treinamento de modelo que será usado em dispositivos móveis para auxiliar médicos na classificação de padrões em imagens de ultrassom de pulmão.



De forma geral, para o treinamento de modelos baseados em DL, é necessária uma grande quantidade de dados para o aprendizado. No caso de imagens radiográficas de pacientes, isso representa uma tarefa desafiadora, pois um grupo de médicos radiologistas precisam realizar a anotação manual de todas as imagens, além de confrontar suas avaliações.

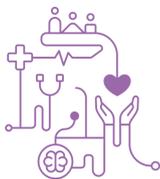
Assim, para resolver o problema da pequena quantidade de imagens rotuladas para o treinamento de arquiteturas baseadas em Deep Learning, tem sido a prática se recorrer às técnicas de *augmentation* e *transfer learning*.

A primeira técnica aumentar artificialmente o tamanho do conjunto de dados de treinamento, aplicando várias transformações e distorções às imagens originais, com o objetivo é melhorar a robustez e a generalização do modelo, tornando-o menos sensível a variações nos dados e ajudando a evitar *overfitting*.

A segunda técnica permite que se aproveite os pesos ajustados de uma determinada arquitetura DL, por treinamento a partir bases de dados que disponham grandes quantidades de dados. Essa técnica possibilita que o treinamento desta determinada arquitetura DL usando a nova base de dados (com menor número de imagens), use os parâmetros já ajustados nas camadas convolucionais (que aprenderam a identificar e a extração de características das imagens) na nova aplicação, e ajuste os pesos das camadas de topo, que realizam o mapeamento entre os dados extraídos (pelas camadas de convolucionais) e as classes de saída. Esta técnica viabiliza a solução de problemas como o deste trabalho, ao mesmo tempo que reduz as chance de *overfitting*^(13,14).

Zhang et al.⁽¹⁵⁾ apresentou um trabalho para diagnóstico de COVID-19 utilizando a arquitetura MobileNet com aplicação de *transfer learning* e otimização bayesiana, que permitiram alcançar uma acurácia de 93%.

O trabalho de Hilmizen et al.⁽¹⁶⁾ propõe o uso de DL multimodal para diagnosticar COVID-19 a partir de imagens de TC e Raio-X do tórax. Neste trabalho são apresentados resultados de treinamento de arquiteturas como DenseNet121, MobileNet, Xception, InceptionV3, ResNet50 e VGG16, além de realizar concatenação de arquiteturas como ResNet50 e VGG16, DenseNet121 e MobileNet e Xception e InceptionV3. O melhor modelo foi o concatenado de ResNet50 e VGG16 alcançando uma acurácia de 99,9%.



O estudo realizado por Martins et al.⁽¹⁷⁾ teve como objetivo desenvolver um modelo de aprendizado profundo para classificação de COVID-19 através de imagens de Raio-X do Tórax. Neste trabalho foi realizado um pré-processamento das imagens para realçar as características dos padrões e estas imagens submetidas ao método Padrão Binário Local (LBP) para extração de características que foram usadas como entrada para uma arquitetura de rede neural totalmente conectada (FCNN). Após o treinamento do modelo foi possível alcançar uma acurácia média de 96,52% na classificação de indivíduos saudáveis e doentes.

Trombetta et al.⁽¹⁸⁾ propõe a utilização da arquitetura VGG-19 para o diagnóstico de COVID-19 utilizando imagens de Raio-X do Tórax. Para o treinamento do modelo foram utilizadas 798 imagens divididas igualmente entre os padrões COVID, Pneumonia bacteriana e Normal e alcançou um resultado de 96% de acurácia com a arquitetura VGG-19.

Assim, apesar de possuir uma quantidade pequena de dados, este trabalho tem como objetivo de auxiliar a tomada de decisão para os profissionais da área da saúde (reumatologista, radiologistas, etc.), permitindo a discriminação entre os padrões PIU e PINE observados em imagens de TC de pacientes diagnosticados com Esclerodermia. Vale ressaltar que até o presente momento não se identificou qualquer trabalho relacionado à esclerodermia e machine learning, incluindo o tema tratado neste trabalho que é a identificação de padrões em imagens de TC em pacientes com esclerodermia.

Material e Metodologia

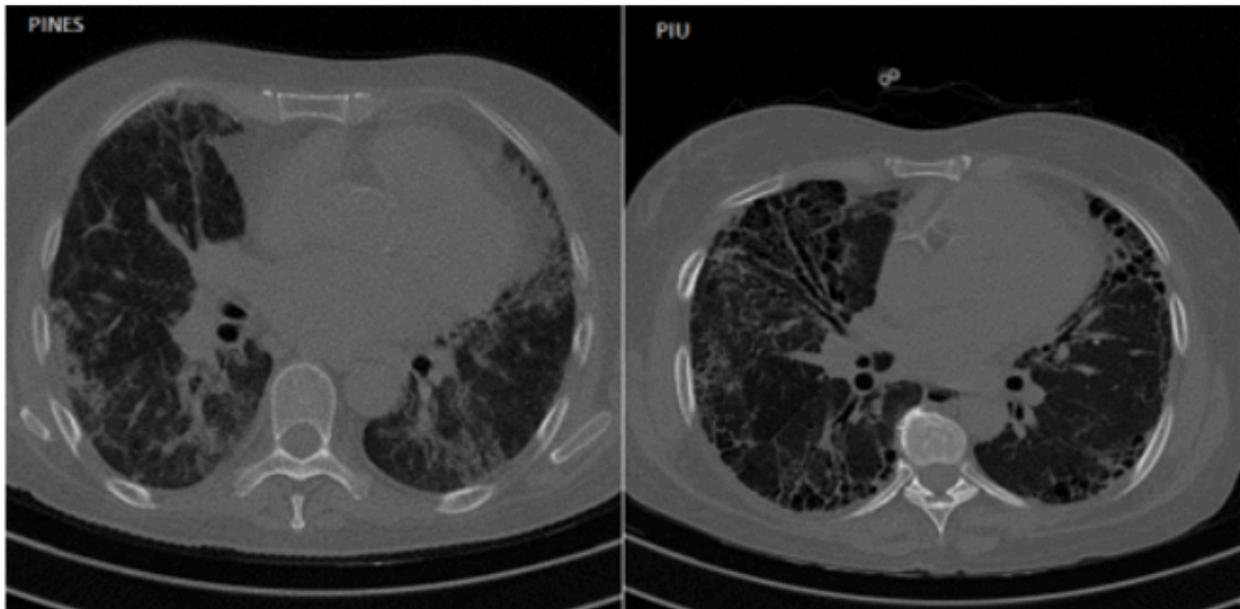
A base de dados utilizada para este trabalho pertence ao Hospital Universitário Pedro Ernesto (HUPE) e apresenta dados de oito pacientes com padrões de PIU e PINE em imagens de TC, que realizaram o exame de imagem no hospital durante o período de 2017 e 2022 e todas as imagens foram anotadas por radiologistas do hospital.

A pesquisa foi submetida para o Comitê de Ética em Pesquisa do Hospital Universitário Pedro Ernesto (HUPE), que aprovou a pesquisa com o número de referência 1363230.1.0000.5282. O termo de consentimento foi dispensado, pois foi utilizado apenas o banco de dados do hospital.



A base de dados possui 813 imagens com padrão PINE e 333 imagens com padrão PIU. O padrão PINE apresenta características predominantes de opacidade em vidro fosco, enquanto no padrão PIU apresenta pouca opacidade em vidro fosco e essas diferenças entre os padrões podem ser visualizadas na Figura 1.

Figura 1 – Exemplos de imagem com padrão PINE à esquerda e padrão PIU à direita



A base de dados utilizada neste trabalho está desbalanceada e, portanto, é necessário realizar o balanceamento para evitar viés no treinamento do modelo para classificação dos padrões. Diante disso, foi aplicado a técnica de *random undersampling* na classe majoritária, de forma que os padrões PINE e PIU tenham exatamente 333 imagens cada um.

Para o treinamento e avaliação do modelo a base de dados foi separada em três conjuntos: conjunto de treino, de validação e de teste. O conjunto de treino possui 422 imagens de TC, o conjunto de validação possui 110 imagens de TC e o conjunto de teste possui 134 imagens de TC, além disso, a equalização tornou os padrões PINE e PIU igualmente estratificados nos três conjuntos de dados.

Conforme já mencionado e exemplificado, as redes neurais do tipo convolucionais possuem grandes quantidades de parâmetros (pesos) e, em geral, apresentam bom desempenho na tarefa de classificação às custas de uma grande quantidade grande de dados anotados para o treinamento/validação/teste. Assim, o intuito de aumentar a quantidade de dados e evitar o *overfitting* é possível utilizar a técnica de *data augmentation*⁽¹⁹⁾, apresentada na seção de introdução.



Dessa forma, como o número de imagens disponível para o problema abordado neste trabalho é pequeno (422 imagens para o treinamento), então foi necessário utilizar *data augmentation*. Neste trabalho foram realizados os seguintes métodos para *augmentation* de dados no conjunto de imagens (já normalização e com tamanho da imagem ajustado para 512x512) do treinamento e validação: cortes na imagem, *flip* horizontal e rotação aleatória entre -15 e 15 graus. É importante ressaltar que todas as técnicas usadas para *data augmentation* não alteraram os padrões PIU e PINES encontrados na imagem, além disso, reforça-se que o processo de *data augmentation* tem como objetivo aumentar a capacidade de generalização do modelo. Assim, para cada imagem original foram gerados outras três sintéticas, totalizando 1688 imagens no conjunto de treinamento e 440 imagens no conjunto de validação, conforme os exemplos apresentados na Figura 2 e Figura 3.

Figura 2 – Exemplos de imagens do conjunto de treino depois da aplicação de aumento de dados

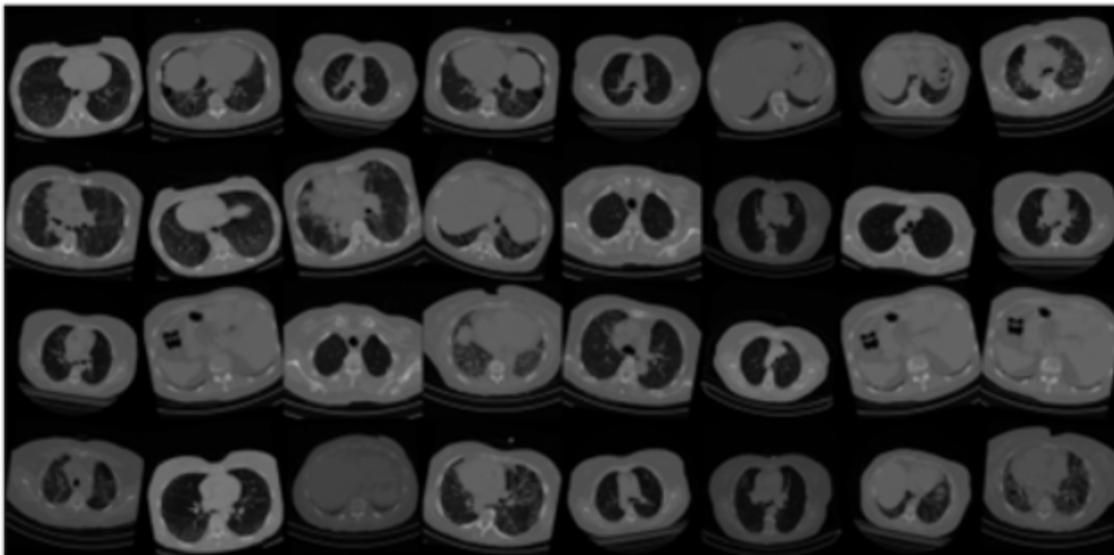
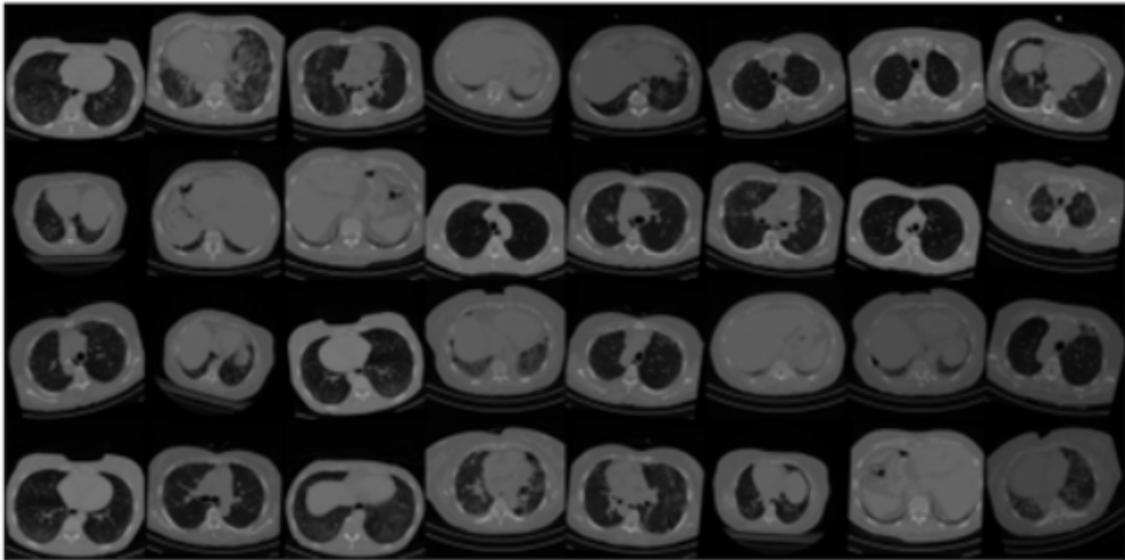
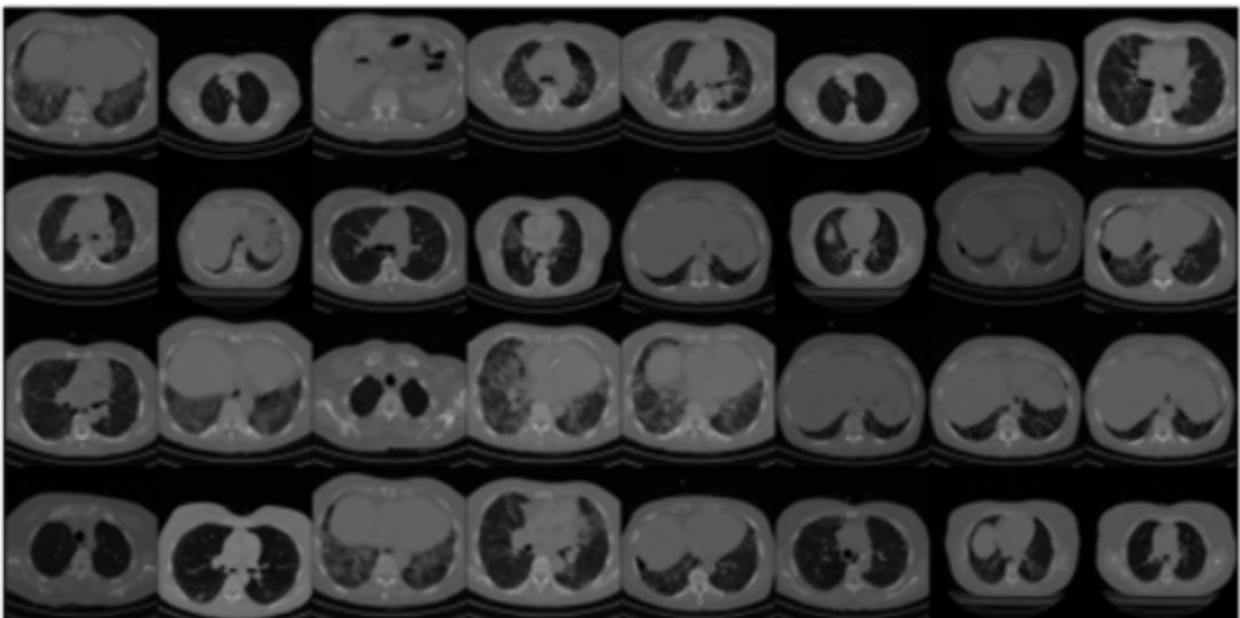


Figura 3 – Exemplos de imagens do conjunto de validação depois da aplicação de aumento de dados



No conjunto de testes não é aplicado *data augmentation*, pois este tem como objetivo permitir a avaliação do modelo em condições reais. Diante disso, a quantidade total de imagens (134 imagens) de TC é mantida, e algumas imagens deste conjunto de dados são apresentadas na Figura 4.

Figura 4 – Exemplos de imagens do conjunto de testes



Este trabalho realizou uma comparação entre as arquiteturas MobileNetV2⁽²⁰⁾, VGG16⁽²¹⁾, ResNet-50⁽²²⁾ e EfficientNet⁽²³⁾ para a tarefa de classificação de padrão



PIU e PINES em imagem de TC de pacientes diagnosticados com esclerodermia, buscando identificar a arquitetura mais adequada, visto que há pouca quantidade de dados.

O modelo MobileNetV2 foi desenvolvido para ter melhor eficiência em dispositivos móveis, sem necessidade de processamento em placa gráfica (GPU) e este modelo possui a característica de utilização de blocos residuais invertidos, que permitem menor complexidade da rede e, como consequência, menor quantidade de parâmetros.

Em contrapartida, a arquitetura VGG16 é conhecida por sua simplicidade e uniformidade, porém com uma quantidade de parâmetros muito superior às arquiteturas usadas para este trabalho.

A arquitetura ResNet-50 se destaca entre os modelos com a utilização de blocos residuais como recurso para reduzir a degradação do desempenho de modelos profundos e sendo mais eficiente que a VGG16, por possuir uma quantidade menor de parâmetros.

Por fim, a arquitetura *EfficientNet* oferece um equilíbrio entre acurácia dos resultados e eficiência do modelo, sendo uma arquitetura simples que apresenta resultados próximos de outras arquiteturas mais complexas, mas com uma quantidade de parâmetros menor.

Cada uma das arquiteturas utilizadas neste trabalho possui complexidades distintas, sendo a VGG16 a rede de maior custo computacional e número de parâmetros e a MobileNetV2 a que possui a menor quantidade de parâmetros e o custo computacional mais baixo.

Para a seleção do melhor modelo, será considerada a acurácia obtida a partir do conjunto de validação. Em caso de empate na acurácia do conjunto de validação entre dois ou mais modelos, a decisão pelo melhor modelo será baseada na quantidade de parâmetros. Assim, entre as arquiteturas empatadas, será escolhida a que tiver a menor quantidade de parâmetros, pois possui menor custo de aprendizado e inferência.

Resultados

Para o treinamento dos modelos para classificação entre os padrões PIU e PINES foi utilizado como função de perda a entropia cruzada e foi utilizado Adam⁽²⁴⁾



como algoritmo de aprendizado. O algoritmo de aprendizado Adam foi usado com taxa de aprendizado de 0,0001 e penalidade L2 com peso de 0,001. Todos os modelos foram treinados utilizando tamanho de *batch* com 32 imagens por até 30 épocas.

Mesmo com a aplicação do *data augmentation*, ainda existem poucos dados para o treinamento e, portanto, foi necessário realizar o *transfer learning* de pesos do treinamento deste modelo com o conjunto de dados *ImageNet*, que possui 1000 classes. Os pesos foram transferidos e a última camada foi substituída para uma saída de duas classes que são PIU e PINES. Nesse caso, a última camada é ajustada com os dados de treinamento indicados na seção Material e Metodologia. Este foi um dos motivos para que não se buscasse desenvolver uma arquitetura própria, pois a necessidade do uso de *transfer learning* para bases de dados pequenas é quase sempre mandatória.

Os modelos para as quatro arquiteturas alcançaram acurácia de 100% nos conjuntos de treino, validação e teste. A Tabela 1 indica que todos os modelos treinados conseguiram distinguir os padrões PIU e PINE para as 134 imagens de TC e, portanto, não errou nenhuma classificação, alcançando uma acurácia de 100% no conjunto de testes.

Diante disso, o modelo que apresenta o menor número de parâmetros também se apresenta como o modelo de melhor custo-benefício, uma vez que com menor quantidade de parâmetros o tempo de resposta do modelo é menor e o tipo de *hardware* necessário para hospedar o modelo também terá menor custo. Vale ressaltar novamente que o modelo MobileNetV2, com aproximadamente 2 milhões de parâmetros, pode ser executado em CPU, não sendo necessário uma placa gráfica (GPU).

Tabela 1 – Resultado dos modelos treinados

Modelo	Acurácia no conjunto de testes	Número de parâmetros
MobileNetV2	100%	2226434
VGG16	100%	134277186
Resnet-50	100%	23512130
EfficientNet b0	100%	4010110



Conclusão e Trabalhos Futuros

De acordo com os resultados do experimento usando o modelo MobileNetV2, foi possível discriminar os padrões PIU e PINE em TC para auxiliar os médicos na avaliação do diagnóstico, progressão e desfecho da Esclerodermia. Os bons resultados mostram que apesar da alta acurácia no treinamento, os modelos treinados possuem grande capacidade de generalização, pois mantiveram o mesmo padrão de acurácia nas bases de validação e teste.

É importante destacar que o modelo MobileNetV2 possui melhor custo-benefício entre os demais avaliados neste trabalho, devido a acurácia encontrada com uma quantidade muito menor de parâmetros. A MobileNetV2 possui aproximadamente 2 milhões de parâmetros e pode ser hospedada em uma máquina sem placa gráfica (GPU).

Além disso, é possível notar que a tarefa de classificação entre padrões PIU e PINES foi realizada com êxito, pois mesmo com modelo mais simples, ou seja, com menor quantidade de parâmetros, foi possível alcançar bons resultados. Vale salientar que a inovação deste trabalho está na aplicação, ou seja, na identificação de padrões em imagem TC de pacientes com esclerodermia, considerando que até o presente momento não se identificou qualquer trabalho envolvendo machine learning e esclerodermia.

Para continuidade do trabalho se propõe a identificar dos padrões PIU e PINES nas imagens, por meio algoritmos de segmentação de semântica, visando o cálculo do o volume do pulmão que está comprometido com qualquer dos padrões: PIU e PINES.

Além disso, como é possível que os dois padrões aconteçam juntos em um mesmo corte de imagem de TC, o aumento do volume de imagens com maior variedade de anomalias conjuntas, enriqueceria o modelo de classificação e também o de segmentação.

Referências

1. Sociedade Brasileira de Reumatologia (2017, October 27). Esclerodermia - Sociedade Brasileira de Reumatologia.



2. Leite, C, Maia, A. "Sintomas de doença e adaptação psicológica em pacientes brasileiros com esclerodermia". *Revista Brasileira de Reumatologia* 2013; 53(5):405–411.
3. Steen, V, Oddis, C, Conte, C, Janoski, J, Casterline, G, Medsger, T. "Incidence of systemic sclerosis in Allegheny County, Pennsylvania. A twenty-year study of hospital-diagnosed cases, 1963-1982". *Arthritis Rheum* 1997; 40(3):441–445.
4. Frank van den Hoogen, Dinesh Khanna, Jaap Fransen, Sindhu R Johnson, Murray Baron, Alan Tyndall, Marco Matucci-Cerinic, Raymond P Naden, Thomas A Medsger, J, Patricia E Carreira, Gabriela Riemekasten, Philip J Clements, Christopher P Denton, Oliver Distler, Yannick Allanore, Daniel E Furst, Armando Gabrielli, Maureen D Mayes, Jacob M van Laar, James R Seibold, Laszlo Czirjak, Virginia D Steen, Murat Inanc, Otylia Kowal-Bielecka, Ulf Muller-Ladner, Gabriele Valentini, Douglas J Veale, Madelon C Vonk, Ulrich A Walker, Lorinda Chung, David H Collier, Mary Ellen Csuka, Barri J Fessler, Serena Guiducci, Ariane Herrick, Vivien M Hsu, Sergio Jimenez, Bashar Kahaleh, Peter A Merkel, Stanislav Sierakowski, Richard M Silver, Robert W Simms, John Varga, Janet E Pope. "2013 classification criteria for systemic sclerosis: an American college of rheumatology/European league against rheumatism collaborative initiative". *Annals of the Rheumatic Diseases* 2013; 72(11):1747–1755.
5. Desai, S, Veeraraghavan, S, Hansell, D, Nikolakopoulou, A, Goh, N, Nicholson, A, Colby, T, Denton, C, Black, C, Bois, R, Wells, A. "CT Features of Lung Disease in Patients with Systemic Sclerosis: Comparison with Idiopathic Pulmonary Fibrosis and Nonspecific Interstitial Pneumonia". *Radiology* 2004; 232(2):560-567.
6. Jonathan G. Goldin, David A. Lynch, Diane C. Stollo, Robert D. Suh, Dean E. Schraufnagel, Philip J. Clements, Robert M. Elashoff, Daniel E. Furst, Sarinnapha Vasunilashorn, Michael F. McNitt-Gray, Mathew S. Brown, Michael D. Roth, Donald P. Tashkin. "High-Resolution CT Scan Findings in Patients With Symptomatic Scleroderma-Related Interstitial Lung Disease". *Chest* 2008; 134(2):358–367.
7. Goodfellow, I, Bengio, Y, Courville, A. *Deep Learning*. MIT Press; 2016.
8. Alexander Selvikvåg Lundervold, Arvid Lundervold. "An overview of deep learning in medical imaging focusing on MRI". *Zeitschrift für Medizinische Physik* 2019; 29(2):102-127
9. Montagnon, A. "Deep learning workflow in radiology: a primer". *Insights into Imaging* 2020; 11(1):22.
10. Prastyo Eko Susanto, Arrie Kurniawardhan, Dhomas Hatta Fudholi, Ridho Rahmadi. "A Mobile Deep Learning Model on Covid-19 CT-Scan Classification". *International Journal of Artificial Intelligence Research* 2022; 6(2).
11. TÜRK V, ÇATAL REİS H, KAYA S. Derin öğrenme mimarilerini kullanarak göğüs BT görüntülerinden otomatik Covid-19 tahmini. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. Gumushane University Journal of Science and Technology Institute; 2022. Disponível em: <http://doi.org/10.17714/gumusfenbil.1002738>
12. Almeida, A, Bilbao, A, Ruby, L, Rominger, M, López-De-Ipiña, D, Dahl, J, ElKaffas, A, Sanabria, S. Lung ultrasound for point-of-care COVID-19 pneumonia stratification: computer-aided diagnostics in a smartphone. *First experiences classifying semiology*



- from public datasets. In 2020 IEEE International Ultrasonics Symposium (IUS) 2020 (pp. 1-4).
13. Torrey L, Shavlik J. Transfer Learning. Handbook of Research on Machine Learning Applications and Trends. IGI Global; 2010. p. 242–64. Disponível em: <http://doi.org/10.4018/978-1-60566-766-9.ch011>
 14. Yu X, Wang J, Hong QQ, Teku R, Wang SH, Zhang YD. Transfer learning for medical images analyses: A survey. Vol. 489, Neurocomputing. Elsevier BV; 2022. p. 230–54. Disponível em: <http://doi.org/10.1016/j.neucom.2021.08.159>
 15. Zhang X, Zhou J, Sun W, Kumar Jha S. A Lightweight CNN Based on Transfer Learning for COVID-19 Diagnosis. Vol. 72, Computers, Materials & Continua. Computers, Materials and Continua (Tech Science Press); 2022. p. 1123–37. Disponível em: <http://doi.org/10.32604/cmc.2022.02458>
 16. Hilminen N, Bustamam A, Sarwinda D. The Multimodal Deep Learning for Diagnosing COVID-19 Pneumonia from Chest CT-Scan and X-Ray Images. 2020 3rd International Seminar on Research of Information Technology and Intelligent Systems (ISRITI). IEEE; 2020. Disponível em: <http://doi.org/10.1109/ISRITI51436.2020.9315478>
 17. Martins JVG, Gregório MP, Baffa M de FO, Coelho AM. Classificação da COVID-19 em Radiografias do Tórax Utilizando Redes Neurais Profundas e Padrões Binários Locais. J Health Inform. 15º de março de 2021 [citado 29º de abril de 2024];12. Disponível em: <https://jhi.sbis.org.br/index.php/jhi-sbis/article/view/843>
 18. Trombetta GBW, Fröhlich W da R, Rigo SJ, Rodrigues CA. Aplicação de Deep Learning para Diagnóstico de Pneumonia Causada por COVID -19 a partir de Imagens de Raio X. J Health Inform. 15º de março de 2021 [citado 29º de abril de 2024];12. Disponível em: <https://jhi.sbis.org.br/index.php/jhi-sbis/article/view/828>
 19. Mikołajczyk, A, Grochowski, M. Data augmentation for improving deep learning in image classification problem. In 2018 International Interdisciplinary PhD Workshop (IIPhDW) 2018 (pp. 117-122).
 20. Mark Sandler, Andrew Howard, Menglong Zhu, Andrey Zhmoginov, Liang-Chieh Chen. MobileNetV2: Inverted Residuals and Linear Bottlenecks.
 21. Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv; 2014. Disponível em: <https://arxiv.org/abs/1409.1556>
 22. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition. arXiv; 2015. Disponível em: <https://arxiv.org/abs/1512.03385>
 23. Tan M, Le QV. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. arXiv. 2019; Disponível em: <https://arxiv.org/abs/1905.11946>
 24. Kingma DP, Ba J. Adam: A Method for Stochastic Optimization. arXiv; 2014. Disponível em: <https://arxiv.org/abs/1412.6980>