

MODELAGEM DE IMAGENS MÉDICAS TORÁCICAS USANDO REDES NEURAIS PROFUNDAS PARA CLASSIFICAÇÃO E ANÁLISE

Felipe Dos Santos Vieira¹; Dinalva Aires de Sales²

¹Universidade Federal do Rio Grande - FURG – Felyipe23@gmail.com

²Universidade Federal do Rio Grande - FURG – dinalvaires@gmail.com

1. INTRODUÇÃO

Atualmente, diagnóstico preciso de doenças é realizado de diversas formas, demonstrando a partir das visualizações dos conhecimentos de anatomia e fisiologia humana como podemos identificar e diagnosticar se um segmento anatômico está ou não em suas funções normais. Uma das formas mais comuns é o diagnóstico por imagem, que utiliza de equipamentos de radiação ionizante e não ionizante para a produção de imagens para a identificação desses segmentos da anatomia e fisiologia humana (DA SILVA, 2019).

O processamento de imagens médicas utilizando IA é uma das principais inovações tecnológicas que revolucionaram o campo da medicina nos últimos anos, permitindo melhorias significativas no diagnóstico, monitoramento e tratamento de doenças. A combinação de algoritmos de IA com imagens médicas, incluindo os raios-x, tomografia computadorizada (CT), permite que os profissionais de saúde classifiquem as patologias de forma mais eficiente. A separação dos possíveis casos de positivos pode agilizar e facilitar o processo de diagnóstico devido ao grande volume de imagens geradas (JAUHAR, 2025).

Portanto, o processamento de imagens médicas e a classificação de padrões são ferramentas essenciais, a diferenciação precisa dos tipos de doenças permite um diagnóstico médico rápido e um tratamento eficaz.

2. METODOLOGIA

A amostra de imagens selecionadas foi extraída de domínio público (KERMANY, D, 2018). O uso de amostras de imagens médicas de domínio público desempenha um papel crucial no avanço da pesquisa em saúde e medicina (BRANCO, Sérgio, 2011).

O modelo base escolhido para a rede neural foi o *Visual Geometry Group 16* (VGG16) uma rede neural profunda projetada para a tarefa de reconhecimento de imagens, possui 16 camadas e consegue classificar imagens em até 1000 categorias.

O Treinamento utilizando o VGG16 como base para o treinamento de imagens médicas foi realizada em *Python* utilizando os pacotes *Keras* e *TensorFlow*.

O modelo proposto inicia no *input*, acessando o *dataset* com as classes separadas: Normal, Bactéria e Vírus. Em seguida, as imagens passam pelo modelo VGG16, cujos parâmetros são congelados. Na sequência foram adicionadas camadas densas personalizadas, compostas por uma camada *flatten* que converte o tensor 3D de saída do VGG16 para em um vetor 1D, duas camadas *dense* de 1024 neurônios divididas por uma camada de normalização em lote *batch normalization*, as camadas densas aprendem os padrões complexos e o *batch normalization* normaliza a saída entre as camadas para

acelerar o treinamento. A camada densa final, gera as probabilidades de cada classe e finaliza com o *output*.

Neste trabalho, considerou-se a avaliação de cada caso separadamente. A análise separada para o modelo se baseia na hipótese da complexidade de uma classificação multiclasse (LANGO, Mateusz, 2022) e da importância de diagnosticar cada tipo de pneumonia, pois cada tipo possui um tratamento diferente.

Os métodos matemáticos usados para a avaliação do modelo foram *loss* (perda de aprendizagem), acurácia. A avaliação das predições do modelo analisa a matriz de confusão, verificando as predições e as taxas de verdadeiros positivos e falsos positivos nas classificações realizadas pelo modelo.

3. RESULTADOS E DISCUSSÃO

Neste desenvolvimento, para determinar os parâmetros de desempenho geral do modelo, analisaremos as métricas do treinamento e validação do modelo proposto.

Tabela 1: Comparação das Métricas de Acurácia e Perda. Fonte: do autor.

Referência	Acurácia	Perda
Ayan e Ünver, (2019)	0,87	0,34
BHANDARY, Abhir (2020)	0,84	0,11
Jain, R, et al. (2020)	0,95	0,12
Kermany, Daniel S, (2018)	0,96	0,17
REZAEI, et al. (2020)	0,99	0,02
Metodo Proposto	0,88	0,39

É possível notar na Tabela 1 que os valores obtidos para o modelo proposto em termos de acurácia e perda de aprendizado, as diferenças nos valores pode ser compreendida analisando a quantidade de classes aprendidas em cada modelo. Os autores da referência classificam seus modelos em duas classes, enquanto o modelo proposto classifica em três.

Por sua vez, a matriz de confusão apresenta as predições do modelo, diferenciando as classes aprendidas pelo treinamento da rede neural. Para testar o modelo, foram selecionadas imagens não anteriormente utilizadas no treinamento e na validação, que são inéditas para o sistema.

Tabela 2: Matriz de Confusão. Fonte: do autor.

<i>True Label</i> <i>/Predicted Label</i>	Previsto Normal	Previsto Bactéria	Previsto Vírus
Real Normal	197 (TP)	13 (FP)	25 (FP)
Real Bactéria	7 (FN)	235 (TP)	0 (FP)
Real Vírus	3 (FN)	26 (FN)	119 (TP)

A predição obtida pelo teste do modelo proposto está apresentada na Tabela 2. O teste utilizou 625 imagens, sendo 235 para normal, 242 para bactéria e 148 para vírus. A matriz de confusão normalizada para cada caso permite verificar a acurácia em relação aos totais de cada uma das classes. A Tabela 2 apresenta, no lado esquerdo, a *True Label*, que corresponde à classe real e verdadeira, enquanto na parte superior temos a *Predicted Label*, que

corresponde à classe predita, que corresponde a predição aprendida quando a rede analisa a imagem e a classifica a partir da sua análise.

A partir da matriz de confusão apresentada na Tabela 2, obtém-se os valores das métricas de desempenho das classe do modelo apresentados na Tabela 3, a avaliação do desempenho do modelo para as classes Normal, Bactéria e Vírus, incluindo os valores de *True Positive Rate* (TPR) e *False Positive Rate* (FPR) em tradução direta Taxa de Verdadeiros Positivos e a Taxa de Falsos Positivos.

A análise dos valores mostra que o modelo teve um bom desempenho na detecção das classes. Para a classe Normal, o TPR de 0,952 indica que 95,2% dos casos foram corretamente identificados, enquanto o FPR de 0,208 mostra que 20,8% dos casos de outras classes foram erroneamente classificados como

Tabela 3: Métricas de Desempenho das Classes. Fonte: do autor.

Classe	TPR	FPR	sensibilidade	Especificidade
Normal	0,952	0,208	0,952	0,792
Bactéria	0,877	0,113	0,877	0,887
Vírus	0,804	0,076	0,084	0,924

Normal. Na classe Bactéria, o TPR de 0,877 e o FPR de 0,113 sugerem que 11,3% das amostras de outras classes foram incorretamente classificadas como Bactéria. Para a classe Vírus, o TPR de 0,804 indica um desempenho ligeiramente inferior, com um FPR de 0,076, sugerindo que 7,6% dos casos de outras classes foram classificados como Vírus.

Os resultados obtidos indicam que o modelo alcançou uma acurácia de 88%, com uma perda de 0,39%. Embora esses resultados sejam competitivos, eles ficam ligeiramente abaixo dos alcançados por outros estudos, como como Ayan e Ünver, (2019), Jain, R, et al. (2020) e Kermany, Daniel S, (2018), que reportaram acurácias de 87%, 95% e 96%, respectivamente. Em particular, a especificidade (83,8%) e a sensibilidade (83,0%) atingidas pelo modelo indicam um equilíbrio adequado entre a capacidade de identificar corretamente tanto os casos positivos quanto os negativos de pneumonia.

4. CONCLUSÕES

Neste trabalho, propomos a classificação multiclasse de imagens de raio-x com e sem a presença de pneumonia como forma de auxílio ao diagnóstico médico. A separação dos tipos de pneumonia auxilia na diferenciação e escolha do tratamento adequado para cada caso de pneumonia. A utilização de imagens médicas de domínio público é fundamental no avanço da pesquisa em saúde, devido a escassez de *dataset* validados especialmente de doenças como a pneumonia. Utilização de redes neurais na classificação de imagens medicas, são ferramentas de apoio e auxilio, surgem como forma de otimizar o tempo e facilitar aos médicos e radiologistas qual imagem dos pacientes tem a maior probabilidade de realmente estar com a patologia, e assim agilizar em seu respectivo tratamento, a decisão final de qual paciente priorizar e qual tratamento usar é de responsabilidade dos profissionais medicos.

5. REFERÊNCIAS BIBLIOGRÁFICAS

AYAN, Enes; ÜNVER, Halil Murat. Diagnosis of pneumonia from chest X-ray images using deep learning. In: 2019 Scientific meeting on electrical-electronics & biomedical engineering and computer science (EBBT). Ieee, 2019. p. 1-5.

BHANDARY, Abhir et al. Deep-learning framework to detect lung abnormality–A study with chest X-Ray and lung CT scan images. Pattern Recognition Letters, v. 129, p. 271-278, 2020.

BRANCO, Sérgio. O domínio público no direito autoral brasileiro: uma obra em domínio público. 2011.

DA SILVA, Ana Maria Marques; PATROCÍNIO, Ana Cláudia; SCHIABEL, Homero. Processamento e análise de imagens médicas. REVISTA BRASILEIRA DE FÍSICA MÉDICA (ONLINE), 2019.

Jain, R., Nagrath, P., Kataria, G., Kaushik, V. S., & Hemanth, D. J. (2020). Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning. Measurement, v. 165.

JAUHAR, Marcus Henrique Oliveira; THOMES, Caroline Rodrigues. Inteligência Artificial Em Imagens Médicas: Impactos E Desafios. Cognitus Interdisciplinary Journal, v. 2, n. 1, p. 160-171, 2025.

KERMANY, D.; ZHANG, K.; GOLDBAUM, M. Large Dataset of Labeled Optical Coherence Tomography (OCT) and Chest X-ray Images. 2018. Acessado em 28 fev. 2025. Online. Disponível em: <https://doi.org/10.17632/rscbjbr9sj.3>.

KERMANY, Daniel S. et al. Identifying medical diagnoses and treatable diseases by image-based deep learning. cell, v. 172, n. 5, p. 1122-1131. e9, 2018.

M. Lango e J. Stefanowski, “What Makes Multi-Class Imbalanced Problems Difficult? An Experimental Study”, Expert Systems with Applications, v. 199, p. 116 962, 2022, issn: 0957-4174. doi: 10 . 1016 / j . eswa . 2022 . 116962. Acessado em 28 fev. 2025. Online. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0957417422003888>.

REZAEI, Khosro; BADIEI, Afsoon; MESHGINI, Saeed. A hybrid deep transfer learning based approach for COVID-19 classification in chest X-ray images. In: 2020 27th national and 5th international Iranian conference on biomedical engineering (ICBME). IEEE, 2020. p. 234-241.