

Aplicação de DenseNet na Identificação de Pneumonia em Radiografias Torácicas

Roney Nogueira de Sousa¹, Maria Elizabeth de Aguiar Lima²,
Francisca Raquel de Vasconcelos Silveira²

¹ Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE) — Campus Fortaleza
Av. Treze de Maio, 2081 — Benfica, Fortaleza–CE, 60040-531

²Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)
Av. Tabelaão Luiz Nogueira de Lima S/N – Tianguá – CE – Brazil

{nogueiraroney453, elizabethbeth500}@gmail.com, raquel.silveira@ifce.edu.br

Abstract. *We evaluated the effectiveness of DenseNet in pneumonia diagnosis using public chest X-ray data. Employing data augmentation techniques and training for 100 epochs, we achieved satisfactory results: accuracy of 95.67%, AUC of 98.52%, precision of 96.20%, and recall of 96.69%. These findings underscore the effectiveness of the architecture in classifying X-ray images for pneumonia diagnosis.*

Resumo. *Avaliamos a eficácia da DenseNet no diagnóstico de pneumonia, usando dados públicos de raios-x torácicos. Com técnicas de data augmentation e treinamento por 100 épocas, obtivemos resultados satisfatórios: acurácia de 95,67%, AUC de 98,52%, precisão de 96,20%, e recall de 96,69%. Esses resultados destacam a eficácia da arquitetura na classificação de imagens de raios-x para o diagnóstico de pneumonia.*

1. Introdução

A pandemia de COVID-19 destacou a importância das doenças respiratórias, aumentando a necessidade de técnicas computacionais para auxiliar no diagnóstico. A demanda por soluções tecnológicas se tornou ainda mais relevante devido à urgência em encontrar métodos eficazes de diagnóstico e tratamento para a doença [GBD 2015 et al. 2017].

Neste estudo, utilizou-se a Rede Neural Convolucional (RNC) DenseNet para classificar pneumonia a partir de imagens de raios-x do tórax. No treinamento e avaliação do modelo, empregou-se um conjunto de dados público denominado “*Chest X-Ray Images (Pneumonia)*”¹, ele é composto por amostras de imagens de raios-x torácicos de pacientes tanto com quanto sem pneumonia.

Este estudo destaca-se pela análise dos mapas de calor gerados pela RNC, combinada com técnicas de geração de dados sintéticos. A abordagem de *Transfer Learning* foi aplicada à RNC, utilizando a estrutura e parâmetros pré-treinados na base ImageNet, com ajustes para evitar *overfitting*. A principal motivação é a aplicação de técnicas de inteligência artificial para aprimorar o diagnóstico de pneumonia, contribuindo para procedimentos técnicos mais eficazes e a redução de possíveis erros médicos.

¹<https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>

2. Metodologia

O objetivo do experimento foi avaliar a RNC DenseNet na classificação de raios-x torácicos, distinguindo entre pessoas saudáveis e com pneumonia. Para transferência de aprendizado, a arquitetura base foi DenseNet121, com adição de camadas, incluindo *Flatten*, quatro densas, uma de saída *softmax*, e quatro *Batch Normalization*, com *Dropout* em quatro pontos da rede.

Adições de camadas à RNC buscam aprimorar a representação do modelo para classificação, incorporando densas para extração profunda de características, saída *softmax* para interpretação, *Batch Normalization* para normalizar ativações e *Dropout* para evitar *overfitting*. Essas modificações visam melhorar o desempenho e a robustez do modelo no diagnóstico.

2.1. Base de Dados

O modelo foi treinado e avaliado na base de dados pública "Chest X-Ray Images (Pneumonia)", organizada em três pastas (treinamento, teste e validação) com subpastas para cada classe. As imagens de raios-x torácicos foram obtidas de pacientes pediátricos com idades entre um e cinco anos no *Guangzhou Women and Children's Medical Center*, em Guangzhou, China. Todas as imagens estão em formato JPEG.

Para a montagem da base de dados, as radiografias foram avaliadas quanto à qualidade, removendo as de baixa qualidade. E teve o diagnóstico feito por dois especialistas, com um terceiro verificando o conjunto para evitar erros.

2.2. Preparação de Dados e dos Classificadores

Dado o tamanho pequeno e desbalanceado do conjunto de dados, este estudo utiliza técnicas de aumento de dados, incluindo zoom, flip horizontal e adição de ruídos no conjunto de treino. A Tabela 1 apresenta a distribuição após o *Data Augmentation*.

Tabela 1. Distribuição das classes na base de dados

Classes	Quantidade Original	Quantidade Atual
Pessoas Saudáveis	1583	6332
Pneumonia	4273	7530
Total	5856	13862

As transformações foram aplicadas sequencialmente, variando em cada imagem. Essa técnica foi exclusiva no conjunto de treinamento para evitar duplicação de dados no conjunto de testes e prevenir superestimação da precisão do modelo.

Não aplicamos alteração de brilho, pois, segundo [da Silva Bomfim et al. 2023], a identificação de áreas opacas nos pulmões é crucial identificação da pneumonia, podendo variar em tamanho e distribuição, afetando a precisão do modelo em relação à classe de pacientes saudáveis, se o brilho for alterado.

Treinamos o modelo por 100 épocas, validando-o a cada época com o conjunto de validação, e, em seguida, avaliamos seu desempenho com o conjunto de testes.

Durante o treinamento, foram usadas duas funções de *callback*: o *Early Stopping*, que interrompeu o treinamento após 5 épocas consecutivas sem melhorias na métrica

AUC para evitar *overfitting*, e o *LearningRateScheduler*, que dinamicamente ajustou a taxa de aprendizagem no início de cada época com base em uma função predefinida, considerando a época e a taxa de aprendizagem atual.

A RNC foi implementada em *Python* [Van Rossum and Drake 2009] usando *Keras* [Chollet et al. 2015], com visualização facilitada pela *Visualkeras* [Gavrikov 2020] e os gráficos foram feitos com *Matplotlib* [Hunter 2007].

3. Resultados e Discussões

Os resultados do treinamento e validação do modelo proposto são apresentados na Figura 1. O gráfico apresenta métricas de acurácia, precisão, *loss*, *Recall* e área sob a curva ROC (AUC). A arquitetura convergiu rapidamente durante o treinamento, estabilizando-se com apenas 15 épocas.

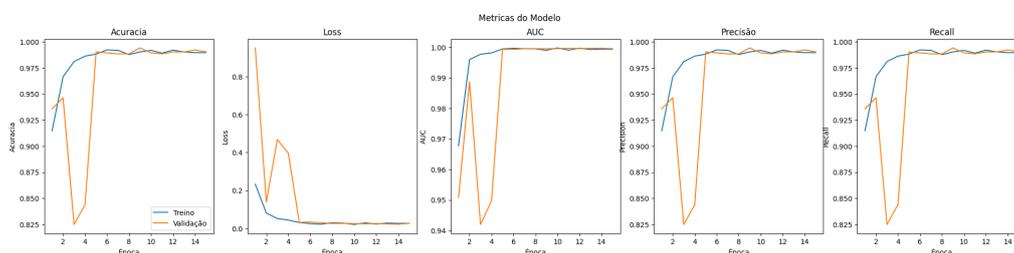


Figura 1. Resultados obtidos no conjunto de treinamento

As métricas que a RNC alcançou no conjunto de testes constam na Tabela 2.

Tabela 2. Métricas obtidas no processo de testes da rede

Métrica	Valor (%)
Acurácia	95,67
Precisão	96,20
<i>Recall</i>	96,69
AUC	98,52

Os indicadores na Tabela 2 evidenciam notável desempenho na classificação de pneumonia em imagens de raios-x, demonstrando alta precisão, *recall* e capacidade de distinguir casos positivos e negativos.

O Grad-CAM (Gradient-weighted Class Activation Mapping) é uma técnica de interpretabilidade para RNCs que utiliza gradientes de retropropagação para visualizar e destacar regiões relevantes na imagem para a decisão de classificação do modelo.

Nesta pesquisa, os segmentos radiopacos corretamente detectados pelos filtros ao classificar pacientes saudáveis e com pneumonia são destacados usando gradientes da última camada convolucional. A Figura 2 exibe exemplos de imagens classificadas corretamente com seus mapas de calor.

O modelo proposto, como mostrado na Figura 2, identifica com precisão as manifestações de pneumonia em imagens radiográficas, destacando áreas radiopacas nos pulmões dos pacientes. A maioria das ativações ocorreu no pulmão direito, frequentemente mais afetado pela pneumonia.

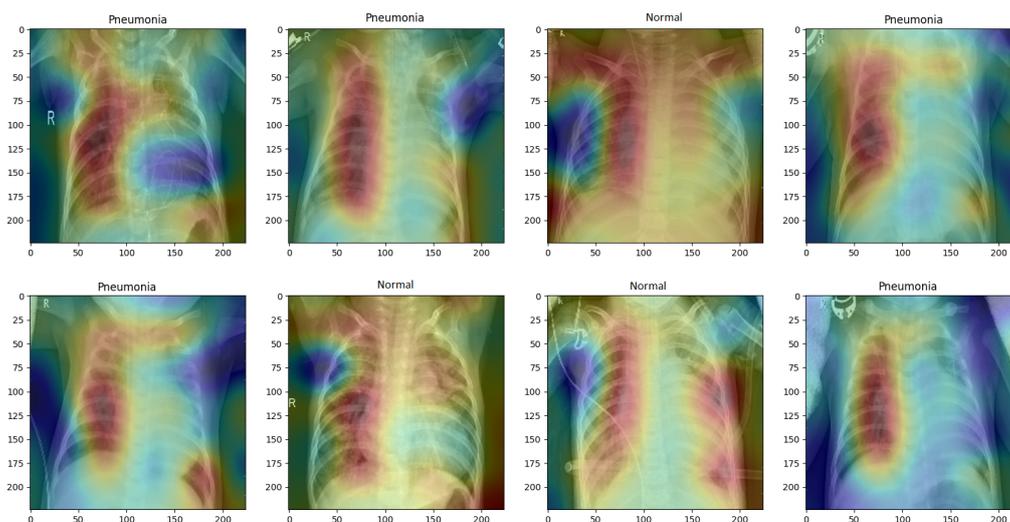


Figura 2. Mapas de calor de imagens classificadas usando Grad-CAM

A capacidade do modelo em detectar corretamente os locais afetados nos pulmões dos pacientes é confirmada, sendo uma informação valiosa para a obtenção de um diagnóstico mais preciso e eficiente, logo, um tratamento mais rápido.

4. Conclusão

Este estudo utiliza a RNC DenseNet como suporte ao diagnóstico de pneumonia, reconhecendo a importância do diagnóstico rápido para melhorar a eficácia do tratamento. A metodologia incluiu o treinamento e análise do modelo em um conjunto de dados público, inicialmente com 5856 amostras e expandido para 13862.

Os resultados obtidos demonstram que a arquitetura de rede atende às necessidades de resolução do problema em questão. Mostrando-se eficiente, com capacidade de generalização elevada e bom desempenho sem *overfitting*.

Referências

- Chollet, F. et al. (2015). Keras. <https://github.com/fchollet/keras>.
- da Silva Bomfim, V. V. B., de Andrade Brandão, M., et al. (2023). Aspectos radiológicos no diagnóstico de pneumonia. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, 9(5):2523–2532.
- Gavrikov, P. (2020). Visualkeras. <https://github.com/paulgavrikov/visualkeras>.
- GBD 2015, C. R. D. C. et al. (2017). Global, regional, and national deaths, prevalence, disability-adjusted life years, and years lived with disability for chronic obstructive pulmonary disease and asthma, 1990–2015: a systematic analysis for the global burden of disease study 2015. *The Lancet. Respiratory Medicine*, 5(9):691.
- Hunter, J. D. (2007). Matplotlib: A 2d graphics environment. *Computing in Science & Engineering*, 9(3):90–95.
- Van Rossum, G. and Drake, F. L. (2009). *Python 3 Reference Manual*. CreateSpace, Scotts Valley, CA.