



Uma visão sobre a classificação de pneumonia viral e bacteriana por radiografias de tórax

An insight into classifying viral and bacterial pneumonia on chest x-rays

Una visión de la clasificación de la neumonía viral y bacteriana mediante radiografías de tórax

Gabriel Martins Gomes¹, Kairo Antonio Lopes da Silva², Fabrizzio Soares³, Afonso Ueslei de Fonseca³, Deborah Fernandes³

1 Graduando, Instituto de Informática, Universidade Federal de Goiás, GO, Brasil.

2 Mestrando, Instituto de Informática, Universidade Federal de Goiás, GO, Brasil.

3 Doutor(a), Instituto de Informática, Universidade Federal de Goiás, GO, Brasil.

Autor correspondente: Gabriel Martins Gomes

E-mail: gabriel.martins@discente.ufg.br

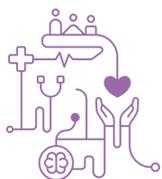
Resumo

Objetivo: Este estudo apresenta uma revisão sistemática sobre o uso de Inteligência Artificial (IA), especialmente *Deep Learning* (DL), no diagnóstico e classificação da pneumonia por radiografias de tórax (RXT). **Método:** O estudo segue o protocolo PRISMA conduzindo a revisão em fases de identificação, triagem e análise de artigos da base Scopus. **Resultados:** A revisão recuperou 25 artigos relevantes entre 121 retornados e identificou crescente interesse científico pelo tema, além de avanços no diagnóstico, com alguns estudos alcançando até 99,7% acurácia no modelo proposto. **Conclusão:** A detecção precoce da pneumonia é essencial para um tratamento mais eficaz, e soluções que auxiliem especialistas são fundamentais. A literatura mostra que há uma evolução constante dessas soluções, embora ainda existam gargalos importantes a serem resolvidos.

Descritores: Pneumonia; Radiografias de tórax; Inteligência Artificial

Abstract

Objective: This study presents a systematic review of the use of Artificial Intelligence (AI), especially Deep Learning (DL), in the diagnosis and classification of pneumonia



using chest X-rays (CXR). Method: The study follows the PRISMA protocol, conducting a phased review of identification, screening, and analysis of articles from the Scopus database. Results: The review retrieved 25 relevant articles among 121 returned and identified growing scientific interest in the topic, in addition to advances in diagnosis, with some studies reaching up to 99.7% accuracy in the proposed model. Conclusion: Early detection of pneumonia is essential for more effective treatment, and solutions that help specialists are crucial. The literature shows that these solutions constantly evolve, although bottlenecks must be resolved.

Keywords: Pneumonia; Chest X-rays; Artificial Intelligence

Resumen

Objetivo: Este estudio presenta una revisión sistemática del uso de la Inteligencia Artificial (IA), especialmente el Aprendizaje Profundo (DL), en el diagnóstico y clasificación de la neumonía mediante radiografías de tórax (CXR). Método: El estudio sigue el protocolo PRISMA, realizando una revisión por fases de identificación, selección y análisis de artículos de la base de datos Scopus. Resultados: La revisión recuperó 25 artículos relevantes entre 121 retornados e identificó un creciente interés científico en el tema, además de avances en el diagnóstico, alcanzando algunos estudios hasta 99,7% de precisión en el modelo propuesto. Conclusión: La detección temprana de la neumonía es esencial para un tratamiento más eficaz, y las soluciones que ayuden a los especialistas son cruciales. La literatura muestra que estas soluciones están en constante evolución, aunque aún hay obstáculos por resolver.

Descriptores: Neumonía; Radiografías de tórax; Inteligencia Artificial

Introdução

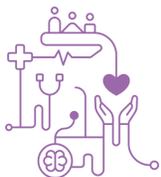
A pneumonia, uma inflamação pulmonar desencadeada por bactérias e vírus, afeta aproximadamente 7% da população mundial e causa cerca de 2 milhões de mortes anualmente¹. A Organização Mundial da Saúde (OMS) reporta que, em países em desenvolvimento, surgem anualmente cerca de 151 milhões de novos casos de pneumonia em crianças². Detectar a pneumonia precocemente e determinar sua origem



são cruciais para garantir um tratamento eficaz e oportuno. E a tipificação da pneumonia em viral e bacteriana é importante para que se possa definir o tipo de tratamento a ser aplicado. O diagnóstico, geralmente, é realizado por meio de exames clínicos, radiografias de tórax (RXT), tomografia computadorizada (TC), broncoscopia, entre outros, sendo o RXT amplamente utilizado devido ao seu baixo custo, rapidez e capacidade de identificar sintomas de pneumonia^(1,3). No entanto, a análise manual das RXT por especialistas apresenta desafios, como o tempo necessário para uma avaliação precisa e o risco de fadiga, que pode resultar em diagnósticos incorretos. Diante desse cenário, muitos pesquisadores têm buscado soluções baseadas em Inteligência Artificial (IA) para automatizar a análise das radiografias e auxiliar os especialistas.

Assim, este estudo apresenta uma revisão sistemática da literatura (RSL) sobre o uso de técnicas de IA, principalmente Deep Learning (DL), para o diagnóstico e classificação da pneumonia a partir de radiografias de tórax para verificar se está havendo interesse e quais as técnicas presentes no estado da arte para este problema. Para isso, foi conduzida uma revisão utilizando o protocolo PRISMA, realizando inicialmente uma busca nas bases de dados, como a Scopus. Dos 121 estudos identificados, foram aplicados critérios de inclusão e exclusão, resultando em 25 artigos relevantes. Posteriormente, foram extraídas informações, como a técnica utilizada, a abordagem proposta, o conjunto de dados utilizado, as métricas de desempenho, entre outros, que serão sumarizadas ao longo do texto. Por meio desse processo, foi possível observar uma significativa busca por soluções para esse problema, com estudos alcançando métricas impressionantes, como uma acurácia de até 99,7% no modelo proposto.

A seguir vamos ter os métodos utilizados para a pesquisa, em seguida a síntese dos artigos contendo um resumo das técnicas utilizadas por cada um agrupados por semelhança na abordagem, a discussão sobre os resumos e finalmente a conclusão.



Método

A pesquisa foi conduzida utilizando o protocolo PRISMA⁽²⁶⁾ e a base de dados Scopus. Para definição da base de dados e *string* de busca, testes pilotos foram feitos em outras bases que incluíam IEEE Xplore, Embase e Google Scholar. Os termos usados na *string* de busca foram refinados nestes testes até chegar em uma combinação que mantivesse o melhor equilíbrio entre a sensibilidade e a especificidade dos resultados. Em seguida, adaptamos a *string* final para o mecanismo de busca da Scopus e buscamos os artigos através dos metadados Título, Resumo e Palavras-chave (TITLE-ABS-KEY). A *string* resultante ficou da seguinte maneira: *TITLE-ABS-KEY ((viral AND bacterial)) AND TITLE-ABS-KEY (pneumonia) TITLE-ABS-KEY (diagnos* OR identifi* OR detect* OR screen OR classifica* OR diferen* OR distingui*) AND TITLE-ABS-KEY ((chest AND (x-ray OR radiograp* AND imaging) OR CXR)) AND TITLE-ABS-KEY ("Artificial Intelligence" OR AI OR "Machine Learning" OR ML OR "deep Learning" OR DL OR "Computer Vision" OR "Convolutional Neural Networks" OR CNN OR "Computer-Aided" OR CAD OR NET OR Transformer)*

A busca considerou artigos publicados entre 2010 e 2024 e foi realizada em novembro de 2023. Foram recuperados 121 artigos, que foram exportados e analisados na ferramenta o Parsifal¹ tomando os seguintes critérios de inclusão: Artigos em Inglês, abordam o tema de diagnóstico de pneumonia, utilizam DL e o modelo proposto diferencia pneumonia viral e bacteriana.

Foi feita uma análise preliminar descartando os artigos que o resumo e a conclusão demonstraram não ter alguns dos critérios acima. Posteriormente foi feita a leitura mais aprofundada dos artigos restantes que resultou na seleção de 25 artigos. A Figura 1 traz uma ilustração das fases deste processo.

Os dados de extração utilizados foram a técnica/ algoritmo, métricas, fonte do conjunto de dados, tamanho do conjunto de dados, classes utilizadas.

¹<https://parsif.al/about/>

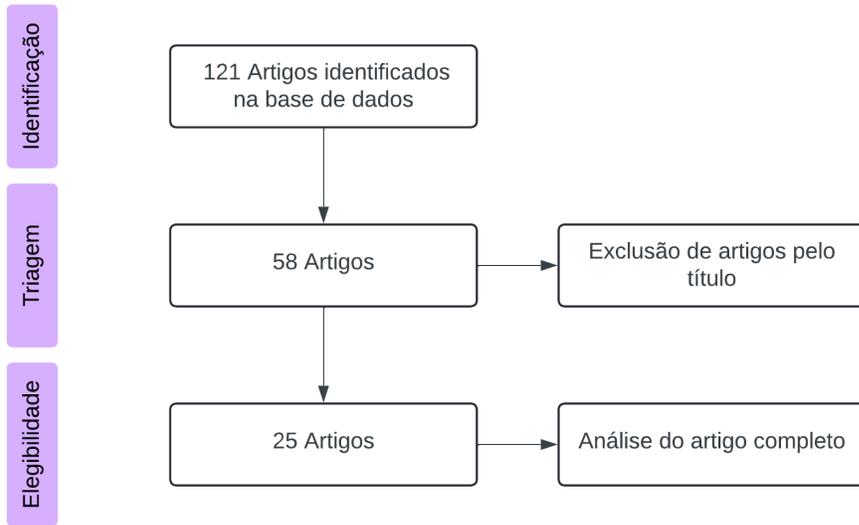


Figura 1: Fluxograma do processo adotado na pesquisa, baseado no protocolo PRISMA.

Síntese e Discussão

Muitos artigos classificaram os RXTs em mais de 3 classes como é possível conferir na Tabela 1, na análise consideramos apenas os modelos que diferenciam pneumonia bacteriana e viral independente do número de classes.

Zhao *et al.* (2021)⁵ realizam uma comparação entre a classificação binária (viral e bacteriana) utilizando o modelo ResNet-50 e quatro revisores sendo dois médicos e dois radiologistas. O modelo alcançou uma AUC de 0,919, sensibilidade de 79% e especificidade de 88,9%. Os resultados indicaram que o modelo e o revisor 1 apresentaram a melhor concordância no diagnóstico.

Tabela 1 - Visão Detalhada dos resultados do mapeamento realizado.

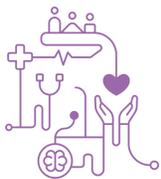
Visão Detalhada								
Autores	Classes	ACC	TVP	TVN	AUC	AD	Fonte	Algoritmo
Hu et al. (2022)	V,B,N	72,00	71,00			Sim	1	Context Fusion CNN
Acharya e Satapathy (2020)	V,B,N				95,00	Não	2	CNN Siamesa
Narayanan et al. (2020)	V,B,N	97,80			99,00	Não	3	CNN Original
Darici er al. (2020)	V,B,N	75,00	78,00			Sim	3	CNN Ensemble Learning
Ferreira et al. (2020)	V,B,N	92,70	96,30	85,10		Não	3	VGG16 Ensemble Learning
Rajaraman et al. (2018)	V,B,N	91,80	90,00	96,00	93,90	Não	3	VGG16 customized



Visão Detalhada								
Garstka e Strzelecki (2020)	V,B,N	85,00	95,00	86,00		Sim	3	CNN Original
Polat et al. (2021)	V,B,N	92,00				Não	3	CNN com MDC
Avolio et al. (2022)	V,B,N		82,00	66,00		Não	3	Multiple Instance Learning
Thanh et al. (2021)	V,B,N	85,20	83,00			Não	3	VGG19
Ibrahim et al. (2021)	C,V,B,N	93,42	89,18	98,92		Não	4, 5, 7, 3	AlexNet
Liu et al. (2022)	C,V,B,N	99,04	99,65			Não	5, 4	ResNet34, ResNet18
Zhao et al. (2021)	V,B		79,00	88,90	91,90	Sim	8	ResNet50
Hariri e Avşar (2023)	C,V,B,N	89,89	87,75			Sim	9	CNN Original
Avola et al. (2022)	C,V,B,N		83,43	94,48	95,20	Sim	3, 4	MobileNet v3
Nillmani et al. (2022)	C,V,B,N,T	92,70	92,70		92,00	Sim	3, 5, 11	VGG16
Alsharif et al. (2021)	V,B,N	99,70	99,74	99,85	98,12	Sim	3	Pneumonianet
Naseem et al. (2022)	C,V,B,N,T,P	87,29	87,29	97,45		Sim	5, 3, 10, 12	DenseNet201
Masud et al. (2021)	V,B,N	86,30		95,41	95,33	Sim	3	CNN + Random Forest
Khaled et al. (2022)	C,V,B,N	96,15	98,46			Sim	3, 8	AVRDIS
Sarkar et al. (2023)	C,V,B,N,T,F, O	96,05	95,00		94,00	Sim	5, 6, 8, 13	MS-CNN
Sudarshan et al. (2022)	C,V,B,N,T	90,96	97,24	95,41		Não	3, 4, 10	VEntNet
Jha et al. (2022)	C,V,B,N,O	90,86	85,20			Sim	5, 9	Inception-ResNet-v2
Bhosale e Yadav (2024)	C,V,B,N,T	95,50	95,50			Sim	3, 4, 5, 10	DWTMBCConvNet
Vashisht et al. (2023)	V,B,N	98,55				Não	2	CNN Híbrida

Métricas dos estudos (%), **V**: Pneumonia Viral, **B**: Pneumonia Bacteriana, **N**: CXR Normal, **M**: Micoplasmas, **C**: Covid-19, **T**: Tuberculose, **P**: Pneumotórax, **O**: Opacidade Pulmonar, **F**: Fibrose. **ACC**: Acurácia, **TVP**: Taxa de verdadeiro positivo ou sensibilidade, **TVN**: Taxa de verdadeiro negativo ou especificidade, **AD**: Aumento de Dados. Fontes: [1]: Beijing children's hospital, [2]: Kaggle, [3]: <https://data.mendeley.com/datasets/rschjbr9sj/2>, [4]: <https://arxiv.org/abs/2006.11988>, [5]: <https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>, [6]: <http://arxiv.org/abs/1705.02315>, [7]: <https://github.com/CSSEGISandData/COVID-19>, [8]: Curadoria dos autores, [9]: <https://data.mendeley.com/datasets/9xkhqts2s6/3>, [10]: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4256233/>, [11]: <https://ieeexplore.ieee.org/document/9224622/>, [12]: <https://kaggle.com/competitions/siim-acr-pneumothorax-segmentation>, [13]: <https://journals.asim.org/doi/full/10.1128/jcm.01013-17>,

Acharya & Satapathy (2020)⁴, Avolio et al. (2022)¹⁰ e Bhosale & Yadav (2024)²² foram os que tiveram abordagens mais diferentes. Acharya & Satapathy (2020)⁴ propuseram uma rede neural siamesa, tendo dois fluxos de análise um para cada lado do pulmão e Avolio et al. (2022)¹⁰ aplicou dois modelos de *Multiple Instance Learning* (MIL): *Machine Instance Learning by Lagrange Relaxation* (MIL-RL) e o *Semiproximal Support Vector Machine for Multiple Instance Learning* (mi-SPSVM). Bhosale & Yadav (2024)²² propõem uma nova arquitetura de CNN que utiliza o bloco Mobile Inverted



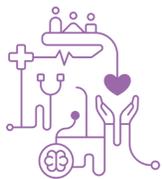
Residual Bottleneck Convolution (MBConv) para classificar RXT. Na configuração de 5 classes, o modelo alcançou uma acurácia de 95,5%, sensibilidade de 95,5%, *F1-Score* de 95,5% e especificidade de 98,9%.

Narayanan *et al.* (2020)¹ e Polat *et al.* (2021)⁹ tiveram abordagens semelhantes, fazendo dois estágios onde o primeiro detecta a presença de pneumonia e o segundo classifica o tipo de pneumonia. Narayanan *et al.* (2020)¹ utilizou modelos pré-treinados como a Inception-v3 e obteve a melhor acurácia com 97,9% e AUC de 0,99.

Liu *et al.* (2022)¹⁹ propõem um método Multi-branch fusion auxiliary learning (MBFAL). O método MBFAL consiste em dividir o problema em duas tarefas, a primeira é um classificador de 3 categorias, e a segunda é um classificador que identifica entre os 3 tipos de pneumonia. O método proposto conseguiu uma acurácia média de 95,607 e uma AUC de 0,994.

Garstka & Strzelecki (2020)⁸, Darici *et al.* (2020)⁶, Alsharif *et al.* (2021)¹² utilizaram técnicas de aumento de dados para lidar com a falta de imagens e o desbalanceamento do conjunto de dados. Darici *et al.* (2020)⁶ utilizaram o método *Synthetic Minority Over-sampling Technique* (SMOTE). Naseem *et al.* (2022)²⁴ utilizam *transfer learning* com técnicas de aumento de dados para equilibrar as amostras. O modelo que obteve melhor desempenho na classificação das 6 classes foi o DenseNet121. Alsharif *et al.* (2021)¹² fez introdução de ruído além do redimensionamento e transformações para aumento de dados alcançando os melhores resultados com 99,72% de acurácia, 99,74% de sensibilidade, 99,85% de especificidade, 99,70% de precisão, 99,72% de *F1-Score* e 98,12% de AUC.

Ferreira *et al.* (2020)³, Rajaraman *et al.* (2018)⁷, Thanh *et al.* (2021)¹¹, Avola *et al.* (2022)¹⁵, Khaled *et al.* (2022)¹⁶, Ibrahim *et al.* (2021)¹⁷, Hariri & Avşar (2023)¹⁸, Sudarshan *et al.* (2022)²⁰, Nillmani *et al.* (2022)²¹ e Jha *et al.* (2022)²³ propuseram o uso de modelos pré-treinados, como a VGG16, para a classificação de RXTs. Rajaraman *et al.* (2018)⁷ utilizaram *Class Activation Maps* (CAM) e *Local Interpretable Model-agnostic Explanations* (LIME). Thanh *et al.* (2021)¹¹ avaliaram o desempenho de três modelos de redes neurais - VGG16, VGG19 e DenseNet169. O modelo de Ferreira *et al.* (2020)³ utilizou as features da imagem com *Contrast-limited Adaptive Histogram Equalization*

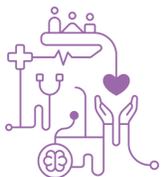


(CLAHE) concatenada com as features da imagem original para ter mais características extraídas. Avola *et al.* (2022)¹⁵ comparou 12 desses modelos verificando que o MobileNet v3 apresenta ótimos resultados e tem pouco custo de processamento desde que tenha quantidade de imagens suficientes para o treinamento. Ibrahim *et al.* (2021)¹⁷ utiliza o AlexNet com um *transfer learning* normal. Hariri & Avşar (2023)¹⁸ propõem um modelo de diagnóstico diferencial leve utilizando técnicas de transfer learning. Sudarshan *et al.* (2022)²⁰ propôs o VEntNet que é um modelo VGG19 combinado com características de entropia, Jha *et al.* (2022)²³ utilizam o modelo Inception-ResNet-v2 junto com técnicas de aumento de dados para mitigar o desbalanceamento do conjunto. enquanto Nillmani *et al.* (2022)²¹ comparou diversos modelos aplicando o *transfer learning* conseguindo o melhor resultado com o VGG16. Já Khaled *et al.* (2022)¹⁶ utiliza os modelos os combinando para então gerar a classificação final e com isso conseguiu o melhor desempenho com 96,15% de acurácia 95,52% de precisão, 98,46% de sensibilidade e 96,96% de *F1-Score*.

Masud *et al.* (2021)¹³ e Vashisht *et al.* (2023)¹⁴ apresentaram o uso de técnicas de DL juntamente com técnicas mais clássicas. Masud *et al.* (2021)¹³ utilizaram dois extratores de características, um baseado em técnicas de estatísticas e o outro em DL. Enquanto Vashisht *et al.* (2023)¹⁴ propôs uma combinação de CNN com outros algoritmos de classificação como SVM, KNN, Naive Bayes e ANN. Vashisht *et al.* (2023)¹⁴ obteve uma melhor acurácia de 98,55% utilizando a CNN, porém não foi informada outra métrica.

Hu *et al.* (2022)² propuseram o uso de CNN para classificar o tipo de pneumonia utilizando CXRs. Utilizando o algoritmo XLSor, realizou-se a segmentação automática e manual dos pulmões. Foram desenvolvidos três modelos CNN derivados da DenseNet121, cada um destinado a diferentes enfoques: o pulmão completo, a área da lesão e a fusão de contexto. Paralelamente, um modelo clínico foi construído para comparação. O modelo de fusão de contexto destacou-se com uma acurácia de 72%, precisão de 73% e recall de 72% no conjunto de teste.

Sarkar *et al.* (2023)²⁵ propuseram a utilização de uma arquitetura denominada *Multi-Scale Convolutional Neural Network* (MS-CNN) que combina as predições obtidas



a partir da extração de mapas de características em diferentes escalas de resolução para a classificação de doenças a partir de CXRs. No conjunto de dados 9, o modelo classificou seis categorias, alcançando 97,47% de acurácia, 96% de precisão, 95% de recall, 95% de F1-Score e 99% de AUC.

Estudos têm explorado classificações em mais de 3 classes, como o trabalho de Sarkar *et al.*⁽²⁵⁾ (2023), que obteve uma acurácia de 96,05% ao classificar o problema em 7 classes de doenças, entretanto muitos focam em diferenciar pneumonia COVID que do ponto de vista médico não faz diferença da pneumonia viral, isso porque o tratamento é o mesmo. A diversidade de técnicas de Deep Learning para classificação de pneumonia é evidente, desde CNNs simples até abordagens mais sofisticadas, como a de Avolio *et al.*⁽¹⁰⁾ (2022). O trabalho de Alsharif *et al.* (2021)⁽¹²⁾ se destacou pelos melhores resultados, alcançando 99,7% de acurácia, AUC de 98,12 e especificidade de 99,85, utilizando uma CNN de 50 camadas. Apesar da escassez de conjuntos de dados públicos de alta qualidade, muitos autores utilizam conjuntos semelhantes, possibilitando uma comparação mais justa entre os resultados. No entanto, muitos estudos se limitam à classificação binária de pneumonia, e nenhum utiliza *transformers*, uma tecnologia promissora tanto em Processamento de Linguagem Natural quanto no processamento de imagens. Além disso podemos observar no Gráfico 1, nos anos 2020 e 2022 houve um aumento significativo de estudos que abordam o tema, impulsionado pelo surgimento da COVID-19 e a necessidade de diagnóstico rápido de pneumonias, porém com oscilações entre os anos.

Conclusão

A aplicação de técnicas de DL, especialmente as CNNs, mostra-se promissora na análise de radiografias para o diagnóstico de pneumonia, auxiliando os especialistas e aumentando a precisão dos diagnósticos. No entanto, a escassez de conjuntos de dados públicos e de fácil acesso dificulta a avaliação da capacidade de generalização desses modelos. É crucial que esses modelos possam lidar com uma variedade de radiografias e não estejam condicionados aos dados de treinamento para serem eficazes na prática clínica. Para futuras pesquisas, seria interessante explorar o uso de



transformers aplicados a esse problema, além de criar conjuntos de dados adicionais de radiografias para experimentação com os modelos estudados. Esses esforços permitiriam uma avaliação mais abrangente da capacidade de generalização dos modelos e sua aplicabilidade em situações do mundo real.

Referências

1. Narayanan, B. N., Davuluru, V. S. P., *et al.* (2020, March). Two-stage deep learning architecture for pneumonia detection and its diagnosis in chest radiographs. In *Medical Imaging 2020: Imaging Informatics for Healthcare, Research, and Applications* (Vol. 11318, pp. 130-139). SPIE.
2. Hu, S., Zhu, Y., Dong, D., *et al.* (2022). Chest Radiographs Using a Context-Fusion Convolution Neural Network (CNN): Can It Distinguish the Etiology of Community-Acquired Pneumonia (CAP) in Children?. *Journal of Digital Imaging*, 35(5), 1079-1090.
3. Ferreira, J. R., Cardenas, D. A. C., Moreno, R. A., *et al.* (2020, July). Multi-view ensemble convolutional neural network to improve classification of pneumonia in low contrast chest x-ray images. In *2020 42nd annual international conference of the IEEE engineering in Medicine & Biology Society (EMBC)* (pp. 1238-1241). IEEE.
4. Acharya, A. K., & Satapathy, R. (2020). A deep learning based approach towards the automatic diagnosis of pneumonia from chest radiographs. *Biomedical and Pharmacology Journal*, 13(1), 449-455.
5. Zhao, B., Liu, H., Zheng, C., *et al.* (2021). Image-based deep learning in diagnosing the etiology of pneumonia on pediatric chest X-rays. *Pediatric Pulmonology*, 56(5), 1036-1044.
6. Darici, M. B., Dokur, Z., & Olmez, T. (2020). Pneumonia detection and classification using deep learning on chest x-ray images. *International Journal of Intelligent Systems and Applications in Engineering*, 8(4), 177-183.
7. Rajaraman, S., Candemir, S., Kim, I., *et al.* (2018). Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs. *Applied Sciences*, 8(10), 1715.
8. Garstka, J., & Strzelecki, M. (2020). Pneumonia detection in X-ray chest images based on convolutional neural networks and data augmentation methods. In *2020 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)* (pp. 18-23). IEEE.
9. Polat, Ö., Ölmez, Z., & Ölmez, T. (2021). Determination of Pneumonia in X-ray Chest Images by Using Convolutional Neural Network. *Turkish Journal of Electrical Engineering and Computer Sciences*, 29(3), 1615-1627
10. Avolio, M., Fuduli, A., Vocaturo, E., *et al.* (2022). Multiple Instance Learning for viral pneumonia chest X-ray Classification. In *SEBD* (pp. 359-366).



11. Thanh, H. T., Yen, P. H., & Ngoc, T. B. (2021, March). Pneumonia classification in X-ray images using artificial intelligence technology. In 2020 Applying New Technology in Green Buildings (ATiGB) (pp. 25-30). IEEE.
12. Alsharif, R., Al-Issa, Y., Alqudah, A. M., *et al.*(2021). PneumoniaNet: Automated detection and classification of pediatric pneumonia using chest X-ray images and CNN approach. *Electronics*, 10(23), 2949.
13. Masud, M., Bairagi, A. K., Nahid, A. A., *et al.* (2021). A pneumonia diagnosis scheme based on hybrid features extracted from chest radiographs using an ensemble learning algorithm. *Journal of Healthcare Engineering*, 2021.
14. Vashisht, S., Lamba, S., Sharma, B., *et al.*(2023, May). Pneumonia Classification Model using Deep Learning Algorithm. In 2023 International Conference on Advancement in Computation & Computer Technologies (InCACCT) (pp. 249-253). IEEE.
15. Avola, D., Bacciu, A., Cinque, L., *et al.*(2022). Study on transfer learning capabilities for pneumonia classification in chest X-ray images. *Computer Methods and Programs in Biomedicine*, 221, 106833.
16. Khaled, M., Gaceb, D., Touazi, F., *et al.*(2022). Progressive and Combined Deep Transfer Learning for pneumonia diagnosis in chest X-ray images. In *IDDM* (pp. 160-173).
17. Ibrahim, A. U., Ozsoz, M., Serte, S., *et al.*(2021). Pneumonia classification using deep learning from chest X-ray images during COVID-19. *Cognitive Computation*, 1-13.
18. Hariri, M., & Avşar, E. (2023). COVID-19 and pneumonia diagnosis from chest X-ray images using convolutional neural networks. *Network Modeling Analysis in Health Informatics and Bioinformatics*, 12(1), 17.
19. Liu, J., Qi, J., Chen, W., *et al.*(2022). Multi-branch fusion auxiliary learning for the detection of pneumonia from chest X-ray images. *Computers in Biology and Medicine*, 147, 105732.
20. Sudarshan, V. K., A. Ramachandra, R., Tan, N. S. M. *et al.*(2022). VEntNet: Hybrid deep convolutional neural network model for automated multi-class categorization of chest X-rays. *International Journal of Imaging Systems and Technology*, 32(3), 778-797.
21. Nillmani, Jain, P. K., Sharma, N., *et al.*(2022). Four types of multiclass frameworks for pneumonia classification and its validation in X-ray scans using seven types of deep learning artificial intelligence models. *Diagnostics*, 12(3), 652.
22. Bhosale, R. D., & Yadav, D. M. (2024). Customized convolutional neural network for pulmonary multi-disease classification using chest x-ray images. *Multimedia Tools and Applications*, 83(6), 18537-18571.
23. Jha, A., John, E., & Banerjee, T. (2022, August). Transfer Learning for COVID-19 and Pneumonia Detection using Chest X-Rays. In 2022 IEEE 65th International Midwest Symposium on Circuits and Systems (MWSCAS) (pp. 1-4). IEEE.



24. Naseem, M. T., Hussain, T., Lee, C. S., *et al.*(2022). Classification and Detection of COVID-19 and Other Chest-Related Diseases Using Transfer Learning. *Sensors*, 22(20), 7977.
25. Sarkar, O., Islam, M. R., Syfullah, M. K.,*et al.* (2023). Multi-scale CNN: An explainable ai-integrated unique deep learning framework for lung-affected disease classification. *Technologies*, 11(5), 134