

Sistema Especialista por Aprendizado de Máquina para Análise de Tuberculose

Fernando da Silva Paulo Junior¹, Bruno da Silva Alves¹, Diego Oliveira da Cruz¹,
Arnaldo de Carvalho Junior¹, Walter Augusto Varella², João Inácio da Silva Filho³

¹IFSP- Laboratório de Inteligência Artificial Embarcada (EAILAB), Instituto Federal de Educação, Ciência e Tecnologia de São Paulo, Rua Maria Cristiana, 50, Jardim Casqueiro – Cubatão/SP.

²IFSULDEMINAS - Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas, Av. Dirce Pereira Rosa, 300, Jardim Esperança - Poços de Caldas/MG.

³UNISANTA - Grupo de Lógica Paraconsistente Aplicada, Universidade Santa Cecília, Rua Oswaldo Cruz, 277 - Boqueirão - Santos/SP

E-mail: fernando.junior1@aluno.ifsp.edu.br

Received Set, 2025

Resumo: A tuberculose pulmonar ainda representa um desafio significativo à saúde pública, especialmente em regiões com infraestrutura médica precária. Considerando o avanço das técnicas de Inteligência Artificial e a necessidade de soluções acessíveis, este trabalho tem como objetivo desenvolver um sistema especialista embarcado para auxiliar na detecção automatizada da tuberculose por meio de imagens radiográficas. A metodologia adotada envolveu o uso da plataforma Edge Impulse e do modelo MobileNetV2 com transferência de aprendizado, aplicado sobre uma base de dados pública contendo 4.199 radiografias de tórax rotuladas como “com tuberculose” e “sem tuberculose”. O modelo foi treinado com técnicas de aumento de dados e otimização por quantização, visando maior eficiência computacional em dispositivos de baixo custo. Os testes demonstraram resultados promissores, alcançando acurácia de 98,48%, área sob a curva característica operacional do receptor de 0,98 e F1-score de 0,99, com desempenho superior mesmo em ambientes com restrições de processamento. A comparação entre os modelos quantizado e não quantizado confirmou a viabilidade do uso embarcado sem perda significativa de desempenho.

Palavras-chave: TinyML, Edge Impulse; Tuberculose; Sistemas Especialistas.

Machine Learning Expert System for Tuberculosis Analysis

Abstract: Pulmonary tuberculosis still represents a significant public health challenge, especially in regions with poor medical infrastructure. Considering the advancement of Artificial Intelligence techniques and the need for accessible solutions, this work aims to develop an embedded expert system to assist in the automated detection of tuberculosis through radiographic images. The methodology adopted utilized the Edge Impulse platform and the MobileNetV2 model with transfer learning, applied to a public database containing 4,199 chest radiographs labeled as either "with tuberculosis" or "without tuberculosis". The model was trained with data augmentation and quantization optimization techniques, aiming for greater computational efficiency in low-cost devices. Tests demonstrated promising results, achieving an accuracy of 98.48%, an area under the receiver's operational characteristic curve of 0.98, and an F1-score of 0.99, with superior performance even in environments with processing constraints. The comparison between the quantized and non-quantized models confirmed the viability of embedded use without significant performance loss.

Keywords: TinyML, Edge Impulse; Tuberculosis; Expert Systems

1. INTRODUÇÃO

Os pulmões são órgãos vitais que desempenham funções essenciais para a manutenção da vida. Além de realizar a troca gasosa absorvendo oxigênio e eliminando

dióxido de carbono, eles também atuam na defesa imunológica, filtrando partículas nocivas inaladas [1].

A saúde pulmonar pode ser comprometida por fatores como tabagismo, poluição e estresse, sendo fundamental adotar práticas saudáveis para preservar sua função adequada [2].

A tuberculose (TB) permanece como um grave problema de saúde pública no Brasil, com 84.308 casos notificados em 2024 e um coeficiente de incidência de 39,7 por 100 mil habitantes. As regiões Norte e Sudeste do país concentram as maiores taxas, evidenciando desigualdades estruturais no enfrentamento da doença. Em 2023, o país registrou 6.025 óbitos por TB, o maior número desde 1999 [3].

A distribuição da tuberculose no mundo é profundamente desigual, afetando desproporcionalmente países de baixa e média renda. Essa realidade é destacada no Relatório Global da Tuberculose 2023 da Organização Mundial da Saúde (OMS), que aponta que os 30 países com maior carga da doença foram responsáveis por 87% dos novos casos em 2022. Entre esses países estão Índia, Indonésia, China, Filipinas, Paquistão, Nigéria, Bangladesh e República Democrática do Congo, todos classificados como de baixa ou média renda. Além disso, a OMS alerta que cerca de 3,1 milhões de pessoas que adoeceram de tuberculose em 2022 não foram diagnosticadas ou notificadas, evidenciando lacunas significativas no acesso a serviços de saúde, especialmente em regiões mais pobres [4].


A literatura atual sobre o uso de inteligência artificial (IA) e aprendizado de máquina (*machine learning* - ML) na área da saúde demonstra um crescimento expressivo, sendo cada vez mais estratégica na identificação precoce de diversas patologias, especialmente no diagnóstico automatizado de doenças pulmonares por meio da análise de radiografias torácicas [5, 6].

As redes neurais artificiais (*artificial neural networks* - ANNs) são algoritmos de IA com alta eficácia para identificação de padrões [7]. Técnicas como redes neurais convolucionais (*convolutional neural networks* - CNNs), uma variação das ANNs, têm demonstrado um alto potencial na análise automatizada de radiografias torácicas, oferecendo apoio diagnóstico em locais onde há escassez de especialistas e recursos médicos [8]. Essa capacidade tecnológica amplia significativamente o acesso ao diagnóstico em regiões com baixa cobertura médica, contribuindo para a equidade no cuidado à saúde.

Estudos mostram que as CNNs, aliadas a técnicas como transfer learning, têm apresentado resultados superiores ou comparáveis aos de profissionais humanos em tarefas específicas de classificação de imagens médicas, incluindo pneumonia e tuberculose [8][9][10]. Isso porque as CNNs tem a capacidade de extrair características automaticamente de imagens complexas, como radiografias de tórax, sem necessidade de pré-processamentos manuais [11]. A Figura 1 mostra a arquitetura típica de uma CNN [12][13].

Nesse sentido, surge o *TinyML* como solução tecnológica emergente, permitindo a execução de modelos de IA em dispositivos de baixo custo e baixa potência, sem dependência de conectividade constante, o que o torna ideal para áreas remotas [15]. A viabilidade de sistemas de triagem baseados em IA embarcada tem sido investigada por pesquisas recentes, que demonstram seu potencial em contextos de atenção primária à saúde [16].

Em síntese, os avanços em redes neurais profundas, aliados ao uso de *transfer learning* e ao desenvolvimento de soluções embarcadas interpretáveis, formam um campo fértil e inovador para o enfrentamento de desafios como o diagnóstico precoce da tuberculose. Entretanto, a literatura ainda carece de estudos que integrem IA leve (*TinyML*), interpretabilidade clínica e detecção



automatizada da tuberculose pulmonar em ambientes de baixa infraestrutura.

Diante desse cenário, este trabalho procura preencher esta lacuna, propondo o desenvolvimento de um sistema especializado para detecção automatizada da tuberculose pulmonar a partir de imagens médicas, integrando técnicas de aprendizado de máquina diminuto (*TinyML*) com recursos de interpretabilidade, visando à criação de soluções diagnósticas acessíveis, precisas e confiáveis, especialmente adequadas para aplicação em dispositivos de baixo custo e em contextos com infraestrutura limitada [7].

2. METODOLOGIA

Foi utilizada a plataforma Kaggle®, conhecida por hospedar bases de dados de domínio público voltados a problemas reais de IA. Após pesquisa pelos termos “Radiografia de Tórax Tuberculose”, foram encontradas as fontes para compor o *dataset* de imagens deste projeto [17]. A Figura 2 ilustra amostras representativas do conjunto de dados.

Nesta pesquisa, para a análise e classificação de imagens foi escolhida a ferramenta Edge Impulse® por empregar o conceito de *no-code*, simplificando o

desenvolvimento da solução [7 e 18]. Além disso, o *Edge Impulse* permite entregar alta performance mesmo em cenários com conjuntos de dados limitados, característica comum em aplicações na área da saúde. Essa técnica permite reutilizar o conhecimento adquirido por redes neurais profundas treinadas previamente em grandes bases de dados, como a *ImageNet*, otimizando tempo de treinamento e generalização dos modelos[19].

A Figura 3 apresenta o fluxo de trabalho adotado pela *Edge Impulse* para o desenvolvimento do modelo.




Figura 3. Fluxo de trabalho do *Edge Impulse*.



Figura 2. *Dataset* de raios-X do Tórax.

A arquitetura base utilizada no processo de transferência de aprendizado foi a *MobileNetV2*, uma rede leve e eficiente, ideal para aplicação futura em dispositivos embarcados [7 e 24].

As camadas finais originais do modelo foram substituídas por uma nova estrutura densa adaptada à tarefa de classificação binária.

As configurações adotadas incluíram uma taxa de aprendizado de 0,0005, com 20 épocas de treinamento, função de ativação ReLU nas camadas ocultas e sigmoide na saída. O otimizador utilizado foi o “Adam”, com a função de perda de entropia cruzada binária (*binary crossentropy*). A base foi dividida em 80% para treinamento e 20% para teste, e foi aplicada técnica de aumento de dados (*data augmentation*) com rotações, zooms e deslocamentos aleatórios, a fim de aumentar a robustez e a generalização do modelo.

Uma análise do *dataset* foi necessária, sendo que as imagens foram cuidadosamente organizadas em diretórios correspondentes às classes “com tuberculose” e “sem tuberculose”. Após a remoção de imagens redundantes, corrompidas ou com baixa qualidade, o resultado foi uma base de dados balanceada com 4.199 imagens de radiografias torácicas. As imagens foram convertidas para tons de cinza e redimensionadas para 512×512 pixels, formato padrão de entrada da rede *MobileNetV2* do *Edge Impulse*.

O processo inicia-se com a criação de uma conta na plataforma e a configuração de um novo projeto, onde o usuário define o escopo da aplicação e estabelece a estrutura inicial do *pipeline* de inferência.

Na etapa de aquisição e preparo dos dados, realiza-se o *upload* das imagens médicas – como radiografias torácicas – previamente organizadas e rotuladas em categorias representativas, por exemplo, “tuberculose” e “normal”. Essas imagens são armazenadas nos diretórios de treinamento e teste, seguindo uma divisão adequada (tipicamente 80/20), permitindo ao sistema aprender os padrões visuais associados a cada classe.

Em seguida, configura-se o “*Impulse*”, ou fluxo de inferência. Nessa etapa, define-se o redimensionamento das imagens para 96×96 pixels, aplica-se normalização por meio do bloco de processamento (“*Image*”) e adiciona-se um bloco de aprendizado por transferência (“*Transfer Learning*”). Essa estrutura permite a reutilização de CNNs previamente treinadas em grandes bancos de dados, como a *MobileNetV2*, otimizando o

desempenho em conjuntos de dados menores e específicos.

Com o *pipeline* configurado, o treinamento do modelo é iniciado. A plataforma ajusta os parâmetros internos do classificador de forma automática, com base nos dados de entrada e nos hiperparâmetros definidos. O desempenho do modelo é monitorado por métricas como acurácia, perda e matriz de confusão, permitindo uma avaliação preliminar da eficácia do sistema.

Posteriormente, o modelo treinado é validado utilizando um conjunto de dados independente (*test set*), a fim de medir sua capacidade de generalização e evitar sobreajuste. Essa etapa garante que o sistema seja robusto e confiável para uso em campo.

Por fim, a fase de implantação (*deployment*) consiste na exportação do modelo treinado em formato compatível com microcontroladores, como *TensorFlow Lite* ou C++, permitindo a execução local das inferências em dispositivos embarcados. Esse processo viabiliza aplicações de IA embarcada em ambientes com restrições computacionais e conectividade limitada, alinhando-se à proposta de soluções tecnológicas acessíveis para a atenção primária à saúde.


3. RESULTADOS

A CNN foi configurada com 20 ciclos de treinamento, utilizando uma taxa de aprendizado de 0,0005.

O processamento foi realizado em CPU, sem utilização de otimizador aprendido e sem aplicação de técnicas de aumento de dados. O tamanho do conjunto de validação foi definido como 20% do total de dados, e o tamanho do lote foi mantido em 32, conforme Figura 4.

Para o treinamento da rede neural foi utilizado modelo quantizado (int8) demonstraram um desempenho robusto, com uma precisão geral de 98,8%, área sob a curva ROC de 0,98 e pontuação F1 ponderada de 0,99 matriz de confusão indicou uma taxa de acerto de 96,6% para pulmões doentes e 99,3% para pulmões saudáveis, com erros mínimos de classificação, conforme Figura 5.

Além das métricas obtidas durante o treinamento, foi realizada uma avaliação no ambiente de teste da própria plataforma Edge Impulse, o qual permite simular a execução do modelo final com imagens reais da base de dados. Esse teste é fundamental para validar a inferência local do modelo em condições próximas ao uso real, especialmente para aplicações embarcadas.



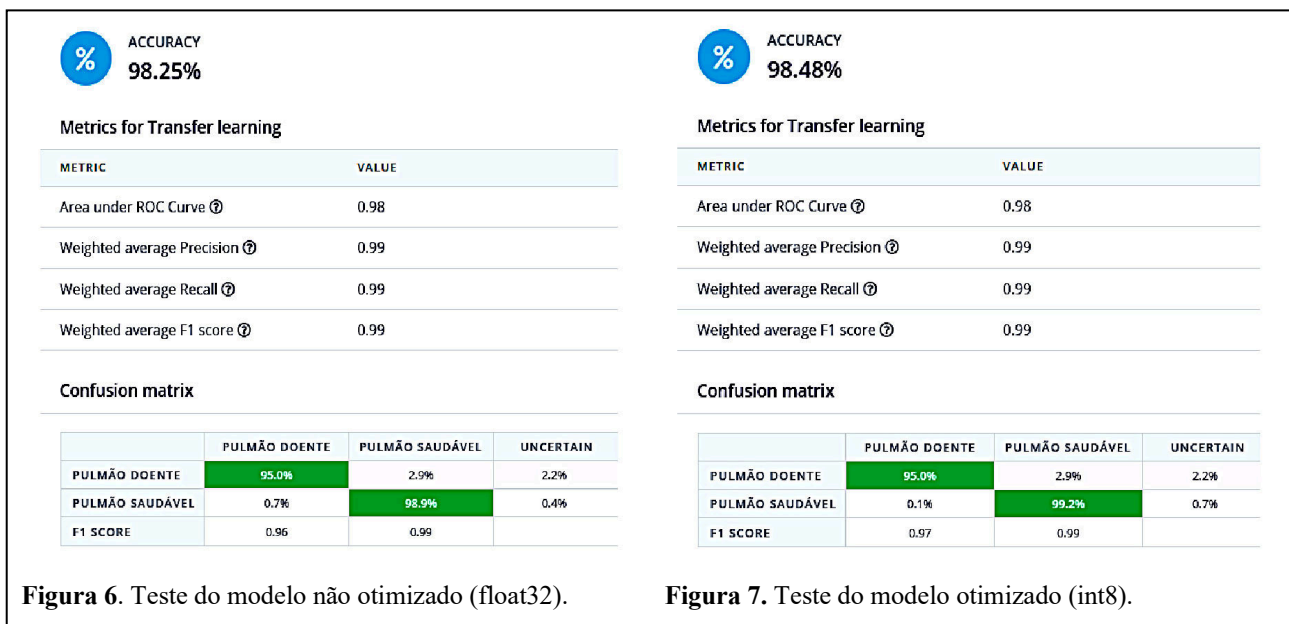
O desempenho foi analisado tanto para o modelo não otimizado (float32) quanto para o modelo otimizado via quantização (int8) podem ser observados na Figuras 6 e 7, respectivamente.

Na comparação entre os dois modelos testados, observou-se que o modelo otimizado (int8) apresentou uma acurácia de 98,48%, ligeiramente superior à do modelo não otimizado (float32), que obteve 98,45%. Apesar da diferença ser marginal, o modelo otimizado também se destacou por demandar menor tempo de inferência e menos recursos computacionais, tornando-se

mais adequado para uso em dispositivos embarcados com restrições de *hardware*.

Os resultados obtidos no treinamento do modelo evidenciam que a quantização não comprometeu o desempenho do modelo e ainda contribuiu para sua viabilidade em aplicações práticas de baixo custo e alta eficiência.

Para a realização de testes, foram utilizadas imagens de pulmão com tuberculose e pulmão saudável, respectivamente, conforme mostradas na Figura 8.





(a)



(b)

Figura 8. Imagens de Pulmão: (a) com tuberculose e (b) pulmão saudável.

Após a validação do modelo, o sistema foi implantado utilizando uma interface de *smartphone*. A plataforma EI disponibiliza um QR-code que, ao ser escaneado, inicia o aplicativo. Após a ativação, os usuários podem direcionar a câmera do *smartphone* para uma imagem de raio-X do pulmão para inferência em tempo real, conforme ilustrado na Figura 9.




Figure 9. Atuação do Sistema especialista via smartphone diagnosticando um pulmão doente.

4. CONCLUSÃO

Este estudo apresentou o desenvolvimento de um sistema especialista para a detecção automatizada de tuberculose pulmonar com base na análise de imagens radiográficas,

integrando técnicas de IA embarcada (TinyML) utilizando a plataforma Edge Impulse e arquitetura do modelo baseada em MobileNetV2 com aprendizado por transferência. O modelo quantizado, otimizado para *hardware* de baixo custo, alcançou uma acurácia de 98,48%, demonstrando desempenho robusto mesmo em ambientes com recursos computacionais limitados.

Os resultados confirmam a viabilidade da implementação de sistemas de IA leves e explicáveis para auxiliar o diagnóstico médico em contextos com poucos recursos, como em aplicações em saúde pública, particularmente na triagem precoce da tuberculose. As limitações identificadas incluem a dependência de conjuntos de dados disponíveis publicamente com variabilidade geográfica limitada, bem como desafios relacionados à otimização de memória e processamento em *hardware* embarcado. Essa abordagem tem potencial para uma implementação mais ampla em regiões carentes e abre caminho para futuras inovações na prestação de serviços de saúde remotos.

REFERÊNCIAS

- [1] TORTORA, G. J.; DERRICKSON, B. Principles of Anatomy and Physiology. 16th ed. Hoboken, NJ: John Wiley & Sons, 2019.
- [2] CAMPOS, M. R. et al. Smoking, mortality, access to diagnosis and treatment of lung cancer in Brazil. Revista de Saúde Pública, vol. 58, p. 18, 2024. <https://doi.org/10.11606/s1518-8787.2024058005704>.
- [3] MINISTÉRIO DA SAÚDE. Boletim Epidemiológico – Tuberculose-2024, Secretaria de Vigilância em Saúde e

- Ambiente, Ministério da Saúde, Brasil, p. 72, 2024. Disponível em: < <https://www.gov.br/aids/pt-br/central-de-conteudo/boletins-epidemiologicos/2024/boletim-epidemiologico-tuberculose-2024/view> >. Acesso: Junho 10, 2025.
- [4] WORLD HEALTH ORGANIZATION (WHO). Global tuberculosis report 2024. ISBN 978-92-4-010153-1. Disponível em: < <https://iris.who.int/bitstream/handle/10665/379339/9789240101531-eng.pdf> >. Acesso: Junho 10, 2025.
- [5] MEGAT RAMLI, P. N. et al. A systematic review: The role of artificial intelligence in lung cancer screening in detecting lung nodules on chest X-rays. *Diagnostics*, vol. 15, no. 3, p. 246, 2025. <https://doi.org/10.3390/diagnostics15030246>.
- [6] CHAN, H.-P. *et al.* Deep learning in medical image analysis. In: *Deep Learning in Medical Image Analysis: Challenges and Applications*, pp. 3-21, 2020. <https://doi.org/10.1146/annurev-bioeng-071516-044442>.
- [7] LITJENS, G. et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*, vol. 42, pp. 60-88, 2017. <https://doi.org/10.1016/j.media.2017.07.005>.
- [8] MOHAMMADI, R. et al. Transfer learning-based automatic detection of coronavirus disease 2019 (COVID-19) from chest X-ray images. *Journal of Biomedical Physics & Engineering*, vol. 10, no. 5, p. 559, 2020. <https://doi.org/10.31661/jbpe.v0i0.2008-1153>.
- [9] GUO, Y.; LI, X.; MENG, Q. An outlier robust finite impulse response filter with maximum correntropy. *IEEE Access*, vol. 9, pp. 17030-17040, 2021. DOI: 10.1109/ACCESS.2021.3053212. Disponível em: <<https://ieeexplore.ieee.org/document/9330603>>. Acesso Junho 10, 2025.
- [10] RAJPURKAR, P. et al. CheXNet: Radiologist-level pneumonia detection on chest X-rays with deep learning. *arXiv preprint*, arXiv:1711.05225, 2017. <https://doi.org/10.48550/arXiv.1711.05225>.
- [11] SHEN, Dinggang; WU, Guorong; SUK, Heung-II. Deep learning in medical image analysis. *Annual review of biomedical engineering*, v. 19, n. 1, p. 221-248, 2017. https://link.springer.com/chapter/10.1007/978-3-030-33128-3_1.
- [12] ANWAR, S.; HWANG, K.; SUNG, W. Structured pruning of deep convolutional neural networks. *ACM Journal on Emerging Technologies in Computing Systems (JETC)*, vol. 13, no. 3, pp. 1-18, 2017. <https://doi.org/10.1145/3005348>.
- [13] ANALOG DEVICES. What Is Machins Learning? Part 1 – Introduction to convolutional neural networks, 2024. Disponível em: < <https://www.radiolocman.com/review/article.html?di=664841> >. Acesso: Nov. 1, 2025.
- [14] DE CARVALHO, A. O Poder das CNNs Em Aplicações de ML Envolvendo Identificação e Classificação de Imagens, EAILAB, IFSP, 2025. Disponível em: < <https://eailab.labmax.org/2024/08/13/o-poder-das-cnns-em-aplicacoes-de-ml-envolvendo-identificacao-e-classificacao-de-imagens/> >. Acesso: Nov. 1, 2025.
- [15] MAMALAKIS, M. et al. DenResCov-19: A deep transfer learning network for robust automatic classification of COVID-19, pneumonia, and tuberculosis from X-rays. *Computerized Medical Imaging and Graphics*, vol. 94, p. 102008, 2021. <https://doi.org/10.1016/j.comp-medimag.2021.102008>.
- [16] EMARA, H. M. et al. Simultaneous super-resolution and classification of lung disease scans. *Diagnostics*, vol. 13, no. 7, p. 1319, 2023. <https://doi.org/10.3390/diagnostics13071319>.
- [17] RAHMAN, T. Tuberculosis (TB) chest X-ray database. *Kaggle*, 2021. Disponível em: < <https://www.kaggle.com/datasets/tawisfurrahman/tuberculosis-tb-chest-xray-dataset> >. Acesso: Junho 10, 2025.
- [18] REDDI, V. J. *Machine Learning Systems – Principles and Practices of Engineering Artificially Intelligent Systems*. Harvard University, School of Engineering and Applied Sciences, 2024. Disponível em: < <https://mlsysbook.ai/Machine-Learning-Systems.pdf> >. Acesso: Junho 10, 2025.
- [19] EDGE IMPULSE. No-code AI development for embedded systems. 2024. Disponível em: <<https://edgeimpulse.com>>. Acesso: Junho 10, 2025.
- [20] DIAB, M. S.; RODRIGUEZ-VILLEGAS, E. Performance evaluation of embedded image classification models using Edge Impulse for application on medical images. In: *2022 44th Annual Int. Conf. of the IEEE Engineering in Medicine & Biology Society (EMBC)*, pp. 2639–2642, 2022. <https://doi.org/10.1109/EMBC48229.2022.9871108>.
- [21] HOWARD, Andrew G. et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*, 2017. <https://doi.org/10.48550/arXiv.1704.04861>.