

## DIAGNÓSTICO DE MANIFESTAÇÕES PATOLÓGICAS EM EDIFICAÇÕES POR MEIO DE VISÃO COMPUTACIONAL E APRENDIZADO DE MÁQUINA

JAIR HENRIQUE DOS PASSOS VELOZO<sup>1</sup>; NUNNO WAKIYAMA DINIZ CARVALHO<sup>2</sup>; JOÃO CONSTANTINO PONTES BARRETO<sup>3</sup>; EVERSON SILVA DE ALBUQUERQUE<sup>4</sup>; ELIANA CRISTINA BARRETO MONTEIRO<sup>5</sup>

<sup>1</sup>Mestrando em Engenharia Civil, UNICAP, Recife-PE, jairhenri.765@gmail.com;

<sup>2</sup>Graduando em Ciência da Computação, UNICAP, Recife-PE, nunno.00000849115@unicap.br;

<sup>3</sup>Graduando em Ciência da Computação, UNICAP, Recife-PE, joao.00000849518@unicap.br;

<sup>4</sup>Mestrando em Engenharia Civil, UPE, Recife-PE, everson15.silva@hotmail.com;

<sup>5</sup>Dr. (a) Prof. (a), UPE e UNICAP, Recife - PE, eliana@poli.br.

Apresentado no  
Congresso Técnico Científico da Engenharia e da Agronomia – CONTECC  
15 a 17 de setembro de 2021

**RESUMO:** Este artigo apresenta o desenvolvimento de um *software* baseado em redes neurais convolucionais (CNNs) com o objetivo de identificar e propor soluções para manifestações patológicas visíveis em fachadas de edificações. A ferramenta automatiza o diagnóstico de falhas como bolor, fissuras, corrosão, umidade e vegetação, por meio da análise de imagens e aprendizado profundo. A metodologia compreende a coleta e o processamento de dados, o treinamento da rede, a validação do modelo e a criação de uma interface *web* funcional. Os resultados demonstram que, mesmo com um conjunto limitado de dados, a padronização das imagens e o uso de técnicas como *Transfer Learning* e *Fine-Tuning* contribuíram significativamente para a acurácia do modelo. A aplicação representa um avanço relevante no campo da engenharia diagnóstica e da manutenção preditiva de edificações, tornando-se uma ferramenta promissora para a modernização das práticas de inspeção.

**PALAVRAS-CHAVE:** redes neurais convolucionais; manifestações patológicas; fachadas; inteligência artificial; manutenção predial.

### DIAGNOSIS OF PATHOLOGICAL MANIFESTATIONS IN BUILDINGS THROUGH COMPUTER VISION AND MACHINE LEARNING

**ABSTRACT:** This article presents the development of a software based on convolutional neural networks (CNNs) with the objective of identifying and proposing solutions for pathological manifestations visible in building facades. The tool automates the diagnosis of faults such as mold, cracks, corrosion, humidity and vegetation, through image analysis and deep learning. The methodology comprises data collection and processing, network training, model validation, and the creation of a functional web interface. The results demonstrate that, even with a limited set of data, the standardization of the images and the use of techniques such as Transfer Learning and Fine-Tuning contributed significantly to the accuracy of the model. The application represents a relevant advance in the field of diagnostic engineering and predictive maintenance of buildings, becoming a promising tool for the modernization of inspection practices.

**KEYWORDS:** convolutional neural networks; pathological manifestations; Facades; artificial intelligence; Building maintenance.

### INTRODUÇÃO

Manifestações patológicas como fissuras, bolor, corrosão e infiltrações representam desafios significativos na engenharia civil por comprometerem a durabilidade e segurança das edificações (Costa, 2022; Silva, 2024). O diagnóstico precoce dessas falhas, aliado à adoção de tecnologias avançadas, é essencial para prolongar a vida útil das construções e evitar prejuízos financeiros (Dutra *et al.*, 2023).

No contexto da transformação digital na engenharia diagnóstica, destaca-se o uso de redes neurais convolucionais (CNNs) como ferramenta para a inspeção automatizada de fachadas. Essa abordagem reduz a dependência de avaliações manuais e torna o processo mais ágil, seguro e eficaz (Silva e Costa, 2022).

O presente estudo objetiva investigar e implementar uma aplicação baseada em CNNs capaz de identificar cinco tipos de manifestações patológicas: bolor, corrosão, fissura, umidade e vegetação. A proposta visa aprimorar os métodos tradicionais de inspeção por meio da inteligência artificial (IA) e da visão computacional, promovendo a eficiência operacional e a tomada de decisões técnicas embasadas.

## MATERIAL E MÉTODOS

A metodologia adotada nesta pesquisa envolveu três etapas principais: (i) coleta e processamento de dados, (ii) treinamento e validação do modelo de rede neural convolucional, e (iii) desenvolvimento de uma aplicação *web* para integração da inteligência artificial ao processo de diagnóstico. Essa estrutura metodológica foi baseada em abordagens consagradas no uso de aprendizado de máquina para classificação de imagens (Ludermir, 2021), adaptadas às necessidades específicas da engenharia diagnóstica.

### Coleta e Processamento de Dados

A base de dados (*dataset*) foi composta por imagens reais de manifestações patológicas em fachadas, reunidas a partir de bancos públicos, registros de inspeções e pesquisas visuais online. Inicialmente, foi criado um conjunto com 1.475 imagens, classificadas em cinco categorias: bolor, corrosão, fissura, umidade e vegetação. As imagens foram distribuídas em dois subconjuntos: 80% para treinamento e 20% para validação. No entanto, a heterogeneidade na resolução, formato e enquadramento das imagens resultou em baixo desempenho do modelo.

Visando solucionar essas limitações, foi criado um segundo dataset contendo 250 imagens padronizadas com resolução de 400x400 pixels e formatos uniformes. Esse conjunto, embora menor, proporcionou resultados superiores. A padronização é apontada na literatura como fator determinante para a performance de modelos de visão computacional, Tabela 1, uma vez que reduz o ruído nos dados de entrada e facilita o aprendizado de padrões consistentes (Barros e Silva, 2024).

Tabela 1. Comparação entre os dois conjuntos de dados utilizados no treinamento e validação da rede neural convolucional.

| Dataset   | Total de imagens | Imagens do treinamento | Imagens de validação | Resolução | Classes                                      |
|-----------|------------------|------------------------|----------------------|-----------|--|
| Dataset 1 | 1475             | 1.250(80%)             | 225(20%)             | Variável  | Bolor, Corrosão, Fissura, Umidade, Vegetação |
| Dataset 1 | 250              | 200(80%)               | 50(20%)              | 400x400   | Bolor, Corrosão, Fissura, Umidade, Vegetação |

Técnicas avançadas de pré-processamento também foram aplicadas, incluindo:

- Data Augmentation*, para ampliar artificialmente o número de amostras por meio de rotações, mudanças de brilho, zoom e espelhamento das imagens, promovendo maior robustez do modelo;

- Transfer Learning*, com uso de modelos pré-treinados em grandes bases (como *ImageNet*), ajustados às características do dataset específico por meio de *fine-tuning*;

- Fine-Tuning*, para refinar os pesos das camadas superiores da rede com foco nas peculiaridades das manifestações patológicas.

Essas abordagens são recomendadas especialmente quando se trabalha com bases de dados reduzidas ou especializadas (Ludermir, 2021; Velozo *et al.*, 2024), pois permitem acelerar o treinamento e evitar problemas como *overfitting*.

### Treinamento e Validação do Modelo

O modelo foi implementado utilizando bibliotecas de aprendizado profundo em *python* (*TensorFlow/Keras*), com camadas convolucionais, de *pooling* e totalmente conectadas. A função de ativação ReLU foi empregada para acelerar a convergência, enquanto a função *softmax* foi usada na camada de saída para classificação multiclasse.

Durante o treinamento, foram monitoradas métricas como acurácia, perda (*loss function*) e comportamento da matriz de confusão, que fornece uma visualização clara dos acertos e erros em cada classe. Para controle de *overfitting*, foram aplicadas técnicas como validação cruzada, regularização com *dropout* e *early stopping*.

A análise dos resultados demonstrou que o segundo *dataset*, mesmo com menor volume de imagens, produziu acurácia significativamente superior, evidenciando a eficácia da padronização e do uso de técnicas de generalização.

### Desenvolvimento da Aplicação

Com o modelo treinado, foi desenvolvida uma aplicação *web* funcional que permite o envio de imagens pelo usuário e a classificação automática da manifestação patológica presente. A interface foi criada com a biblioteca *React*, com integração *backend* em *python*. O sistema foi hospedado na plataforma Vercel, garantindo acessibilidade e leveza na navegação.

O uso de assistentes de codificação com IA, como *ChatGPT*, *Google Gemini* e *GitHub Copilot*, contribuiu na geração de *scripts* otimizados e na resolução de problemas técnicos. Essa etapa promoveu uma ponte entre o modelo científico e sua aplicação prática, validando a proposta como uma solução tecnológica de baixo custo e alto impacto para inspeções prediais automatizadas.

## RESULTADOS E DISCUSSÃO

A comparação entre os dois *datasets* revelou que a uniformidade na resolução das imagens é mais impactante para a performance do modelo do que a quantidade total de dados. O segundo *dataset* obteve melhor acurácia, mesmo com menos imagens, demonstrando que qualidade e padronização são cruciais.

A evolução do modelo foi evidenciada nas matrizes de confusão e nos gráficos de treinamento. Observou-se uma melhora significativa na capacidade de generalização da rede neural, principalmente na identificação correta das subclasses com imagens inéditas.

A interface *web* foi testada com imagens externas ao treinamento, confirmando o funcionamento adequado da aplicação em condições reais, Figura 1. A proposta mostra viabilidade técnica e potencial para ser aplicada em inspeções de campo.

Figura 1. Reconhecimento de manifestações patológicas com visão computacional.



Apesar dos avanços, limitações como a pequena base de dados ainda impactam a precisão final. A ampliação do *dataset* e o refinamento do modelo são etapas futuras necessárias para garantir maior confiabilidade nos diagnósticos.

## CONCLUSÃO

O estudo comprovou o potencial das redes neurais convolucionais no diagnóstico automatizado de manifestações patológicas em fachadas, promovendo um avanço tecnológico relevante para a engenharia civil. A aplicação desenvolvida mostra-se eficaz e acessível, podendo ser utilizada por profissionais para inspeções visuais rápidas e com menor custo operacional.

Os resultados reforçam a importância da padronização das imagens para treinar modelos robustos, além do uso de técnicas como *transfer learning* e *data augmentation*. O projeto representa uma contribuição importante à modernização das práticas de manutenção predial e abre perspectivas para futuras melhorias, como a integração com drones e sensores.

## AGRADECIMENTOS

Agradecemos à Universidade Católica de Pernambuco (UNICAP), aos colegas do curso de Ciência da Computação e Engenharia Civil, e aos orientadores e colaboradores pelo suporte técnico, acadêmico e motivacional durante o desenvolvimento deste projeto.

## REFERÊNCIAS

BARROS, G. A.; SILVA, A. A. P. Inovações na correção de manifestações patológicas em edifícios: revisão de literatura. *Revista Científica: Semana Acadêmica*, v.12, 2024.

COSTA, L. S.; SILVA, W. A. Manifestações patológicas em fachadas de construções históricas: estudo de caso da Igreja de Nossa Senhora do Carmo. *Research, Society and Development*, v.11, 2022.

DUTRA, A. P. et al. Diagnóstico sobre la Fachada de la Iglesia de São José. *XVII Congreso Latinoamericano de Patología de Construcción*, 2023.

LUDERMIR, T. B. *Inteligência artificial e aprendizado de máquina: estado atual e tendências*. UFPE, 2021.

SILVA, A. S.; COSTA, D. B. *Análise do uso de tecnologias digitais para identificação automatizada de patologias em construções*. Canela, 2022.

VELOZO, J. H. P. et al. Uso de redes neurais para detecção de manifestações patológicas utilizando imagens capturadas por aeronaves remotamente pilotadas. ANAIS DO 65º Congresso Brasileiro do Concreto, 2024.