CHAPTER X

SOFTWARE BASED ON CONVOLUTIONAL NEURAL NETWORKS FOR THE DIAGNOSIS AND TREATMENT OF PATHOLOGICAL MANIFESTATIONS IN FACADES

SOFTWARE BASEADO EM REDES NEURAIS CONVOLUCIONAIS PARA DIAGNÓSTICO E TRATAMENTO DE MANIFESTAÇÕES PATOLÓGICAS EM FACHADAS

DOI: 10.51859/amplla.sset.3125-10

Jair Henrique dos Passos Velozo [1]
Nunno Wakiyama Diniz Carvalho [2]
João Constantino Pontes Barreto [3]
Everson Silva de Albuquerque [4]
Rômulo Pereira da Silva [5]
Eliana Cristina Barreto Monteiro [6]

[1] Mestrando do curso de Pós-graduação em Desenvolvimento de Processos Ambientais. Universidade Católica de Pernambuco – UNICAP. https://orcid.org/0009-0003-4253-1045.
[2] Graduando do curso em Ciência da Computação. Universidade Católica de Pernambuco – UNICAP. https://orcid.org/0009-0008-9762-1052.
[3] Graduando do curso em Ciência da Computação. Universidade Católica de Pernambuco – UNICAP. https://orcid.org/0009-0005-7672-5379.
[4] Mestrando do curso de Pós-graduação em Engenharia Civil. Universidade de Pernambuco – UNICAP. https://orcid.org/0009-0004-9384-9552.
[5] Mestrando do curso de Pós-graduação em Desenvolvimento de Processos Ambientais. Universidade Católica de Pernambuco – UNICAP. https://orcid.org/0009-0004-4445-4116.
[6] Professora Adjunta. Universidade Católica de Pernambuco e Universidade de Pernambuco – UNICAP / UPE. https://orcid.org/0000-0003-0842-779X.

ABSTRACT

This study explores the creation of an unprecedented computer program, using artificial neural networks, with the purpose of detecting problems and suggesting resolutions for the visible flaws in the external walls of buildings. The main goal is to make automatic the recognition of imperfections such as insulation problems, rust in internal metal structures, cracks, mold and infiltrations, in addition to presenting specialized recommendations for the solution of these setbacks. To achieve this, Convolutional Neural Networks (CNNs) were used, able to examine photos of the facades, identify the problems mentioned with great accuracy, and propose repair methods that follow best practices and current technical regulations. The research comprised the obtaining and processing of concrete information, followed by the learning and evaluation of the digital model, ensuring its good performance in various construction situations. The proposed tool signifies remarkable progress in the area of building conservation, helping to improve work efficiency, reduce costs and protect the integrity of structures.

Keywords: Software; Pathological manifestations; Facades; Data processing; Maintenance.

RESUMO

Este estudo explora a criação de um programa de computador inédito, utilizando redes neurais artificiais, com o propósito de detectar problemas e sugerir resoluções para as falhas visíveis nas paredes externas dos prédios. A grande meta é tornar automático o reconhecimento de imperfeições como problemas de isolamento, ferrugem nas estruturas

metálicas internas, rachaduras, mofo e infiltrações, além de apresentar recomendações especializadas para a solução desses contratempos. Para alcançar isso, foram usadas Redes Neurais Convolucionais (CNNs), aptas a examinar fotos das fachadas, identificar os problemas mencionados com grande exatidão e propor métodos de conserto que seguem as práticas recomendadas e os regulamentos técnicos atuais. A pesquisa compreendeu a obtenção e o tratamento de informações concretas, seguidos pelo aprendizado e avaliação do modelo digital, assegurando seu bom desempenho em diversas situações de construção. A ferramenta proposta significa um progresso notável na área da conservação de edifícios, auxiliando para uma melhor eficiência no trabalho, redução de gastos e proteção da integridade das estruturas.

Palavras-chave: Software; Manifestações patológicas; Fachadas; Processamento de dados; Manutenção.

1 INTRODUÇÃO

As manifestações patológicas em edificações como bolor, corrosão, fissuras, presença de vegetação indesejada e umidade representam sérios desafios para a engenharia civil. Esses fenômenos indicam falhas nos materiais ou no desempenho dos sistemas construtivos, podendo comprometer tanto a segurança quanto a durabilidade das estruturas (Costa, 2022). Quando negligenciadas, essas manifestações patológicas tendem a se agravar, afetando a funcionalidade da edificação e reduzindo significativamente sua vida útil. Por isso, a detecção precoce e o tratamento adequado dessas manifestações são essenciais para mitigar riscos, evitar prejuízos maiores e otimizar os custos de manutenção ao longo do tempo.

A presença dessas manifestações patológicas pode ter diversas origens, como o uso inadequado de materiais, falhas no processo construtivo, ausência de manutenção preventiva, exposição prolongada a agentes agressivos (como umidade ou poluição), além de ações do tempo e da própria deterioração natural dos componentes da edificação (Dutra *et al.*, 2023). Independentemente da causa, é certo que tais manifestações, quando não diagnosticadas e tratadas em tempo hábil, tendem a evoluir, ampliando os danos e gerando prejuízos financeiros consideráveis, além de riscos à integridade dos usuários da edificação (Silva, 2024).

As inspeções técnicas e a estratégia de manutenção têm como objetivo identificar de que forma e em que ritmo uma determinada estrutura está se degradando, a fim de determinar a necessidade de eventuais reparos, o momento em que esses reparos devem ocorrer especialmente quando o desempenho da estrutura deixa de atender às expectativas iniciais e, por fim, garantir a manutenção ou até a ampliação de sua vida útil (Velozo *et al.*, 2024).

Conforme mencionado por Dutra *et al.* (2023), a inspeção periódica é um componente fundamental da metodologia de manutenção preventiva. Quando realizada de forma adequada, torna-se um instrumento essencial para assegurar a durabilidade da construção, tendo como objetivo registrar danos e anomalias, além de avaliar sua relevância em relação ao desempenho e à segurança estrutural.

No entanto, essas atividades ainda demandam a atuação de inspetores experientes para a avaliação direta das condições estruturais. Além disso, trata-se de uma metodologia tradicional que é, em muitos casos, onerosa, demorada, laboriosa e potencialmente arriscada, especialmente em áreas de difícil acesso (Silva e Costa, 2022).

Para Silva e Costa (2022), o avanço das imagens digitais, aliado às técnicas de processamento de dados, tem aprimorado significativamente as estratégias de inspeção, permitindo avaliações automatizadas das condições dos elementos construtivos. Tecnologias emergentes, como drones e sistemas de visão computacional, têm se mostrado ferramentas valiosas nesse contexto, por automatizar o processo de inspeção e torná-lo mais ágil, seguro, confiável e eficaz. Diante desse cenário, evidencia-se a necessidade de mapear o estado da arte na aplicação do processamento de imagens para o reconhecimento automático de manifestações patológicas em construções, com vistas ao desenvolvimento de pesquisas futuras. Nesse sentido, o presente estudo tem como objetivo identificar as principais tecnologias digitais utilizadas em inspeções automatizadas de falhas e manifestações patológicas em elementos construtivos, bem como compreender de que forma as informações obtidas por meio dessas ferramentas podem subsidiar a tomada de decisão gerencial em obras.

Outro aspecto fundamental para a solução e prevenção de manifestações patológicas em edificações é o investimento em inovações tecnológicas. Nesse sentido, destaca-se o uso de novas tecnologias e materiais avançados como o concreto auto reparável, sensores de monitoramento e técnicas de reparo não destrutivas que contribuem significativamente para identificar, prevenir e corrigir essas manifestações patológicas de forma mais eficaz (Barros e Silva, 2024).

2 OBJETIVOS

Este estudo tem como objetivo investigar e apresentar soluções tecnológicas inovadoras aplicadas à inspeção automatizada de edificações, com foco na detecção

precoce de manifestações patológicas por meio de segmentação e processamento de imagens.

2.1 Objetivos específicos

- Implementar uma Rede Neural Convolucional (CNN) para identificar 5 classes de manifestações patológicas;
- Comparar os gráficos de perdas e acurácias;
- Analisar a matriz de confusão;
- Analisar a presença de *Overfitting*;
- Integrar a Inteligência Artificial (IA) em aplicação *web*.

3 MANIFESTAÇÕES PATOLÓGICAS E REDES NEURAIS ARTIFICIAIS

A relevância desse artigo reside na sua capacidade de tornar os processos de manutenção predial mais eficientes, seguros e econômicos, ao reduzir a dependência exclusiva de inspeções manuais, frequentemente onerosas, demoradas e sujeitas a erros humanos. Ao integrar ferramentas digitais, como drones e IA, busca-se aprimorar a tomada de decisão técnica e gerencial, promovendo maior durabilidade das estruturas.

4 PRINCIPAIS MANIFESTAÇÕES PATOLÓGICAS EM EDIFICAÇÕES E SEUS IMPACTOS

As manifestações patológicas em edificações são falhas ou anomalias que comprometem a integridade, o desempenho e a durabilidade das construções. Elas podem surgir devido a uma série de fatores, como erros de projeto, falhas de execução, uso inadequado de materiais, ausência de manutenção ou exposição a condições ambientais agressivas. Quando não tratadas de forma adequada e tempestiva, essas manifestações patológicas podem evoluir, causando danos estruturais, perda de funcionalidade, prejuízos financeiros e, em casos extremos, colocando em risco a segurança dos usuários (Barros e Silva, 2024).

O reconhecimento e o tratamento adequado das manifestações patológicas são essenciais para garantir a segurança, o conforto e a vida útil das edificações. A engenharia diagnóstica, por meio de inspeções técnicas e uso de tecnologias avançadas, permite a identificação precoce desses problemas e a adoção de medidas corretivas eficazes. Além disso, a manutenção preventiva e o uso de materiais e

técnicas adequadas durante a construção são fundamentais para evitar o surgimento precoce destas manifestações patológicas (Dutra, 2023).

4.1 Conceito e funcionamento das redes neurais artificiais

Uma plataforma baseada em aprendizado de máquina foi utilizada para treinar redes neurais, com o intuito de automatizar os processos e facilitar os diagnósticos. Assim é possível fazer uma recuperação, tratando cada manifestação patológica corretamente, aumentando a vida útil das fachadas das edificações, estendendo o tempo para fazer uma nova manutenção. *Machine Learning* (aprendizado de máquina) procura otimizar um critério de desempenho usando dados de exemplo ou experiências anteriores. Foi criado um modelo definido com alguns parâmetros, e aprendizagem é a execução de um *software* para otimizar os parâmetros do modelo usando os dados de treinamento ou experiência (Ludermir, 2021). O modelo pode ser preditivo para fazer previsões no futuro, ou descritivo para obter conhecimento dos dados, ou ambos. O aprendizado de máquina usa a teoria da estatística na construção de modelos matemáticos, porque a tarefa principal é fazer inferências a partir de uma amostra (Velozo et al 2024).

4.2 Aplicação das redes neurais convolucionais (cnns) na análise de imagens

São um tipo especializado de rede neural para processamento de dados com uma topologia conhecida, como uma grade. Os exemplos incluem dados de série temporal, que podem ser considerados como uma grade 1D que coleta amostras em intervalos de 24 tempo regulares, e dados de imagem, que podem ser considerados como uma grade 2D de pixels. As redes convolucionais têm sido extremamente bem-sucedidas em aplicações práticas. A Figura 1 ilustra o esquema da leitura de pixels pela rede neural.

Figura 1. Matriz Confusão do *Dataset* 1

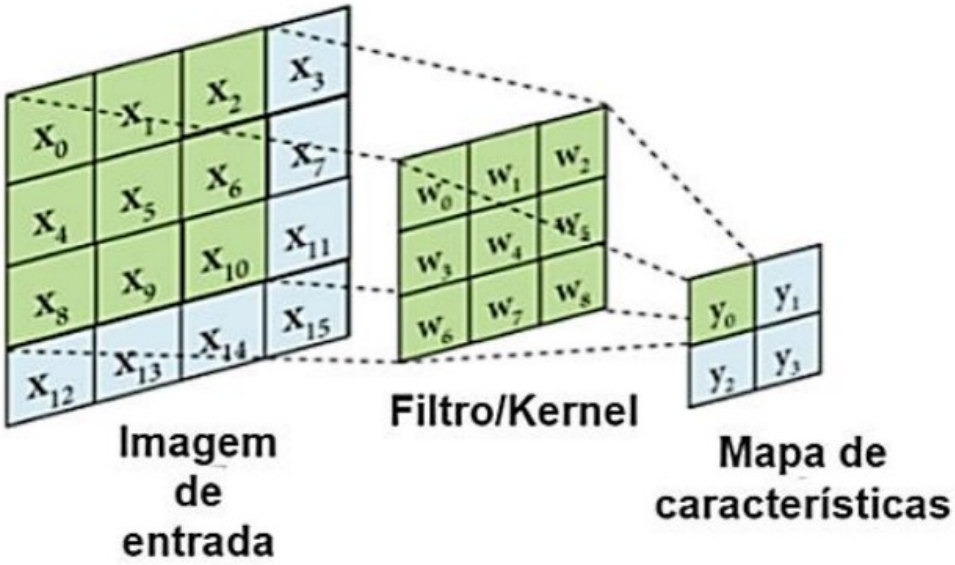

Fonte: Autoria Própria.

O nome “rede neural convolucional” indica que a rede emprega uma operação matemática chamada convolução. A convolução é um tipo especializado de operação linear. As redes convolucionais são simplesmente redes neurais que usam convolução no lugar da multiplicação geral da matriz em pelo menos uma de suas camadas, no contexto de imagens, esse processo pode ser associado como um filtro (também chamado de kernel nesse caso), que transforma uma imagem de entrada, onde esses filtros são representados por uma matriz a qual é utilizada numa operação entre as matrizes (Velozo et al 2024).

5 METODOLOGIA

Foi possível criar 3 etapas para a metodologia, que visa cada passo para coletar e processar dados, treinar a rede neural convolucional e desenvolver um aplicativo móvel para a identificação das manifestações patológicas nas fachadas de edifícios.

5.1 Coleta e processamento de dados

Para montagem do dataset várias imagens pesquisadas e separadas manualmente agrupadas em pastas dentro do *dataset*, tendo pastas de Treino e Validação com as classes. O primeiro dataset Velozo et al (2024) foi composto por 1.475 imagens, das quais 1.250 foram destinadas ao treinamento (cerca de 80%) e 225 à validação (cerca de 20%. Para ambas as etapas, as imagens foram igualmente

distribuídas em cinco subclasses, de acordo com a manifestação patológica presente: Bolor, Corrosão, Fissura, Umidade e Vegetação. No entanto, esse dataset não produziu resultados satisfatórios no *software*, uma vez que as imagens possuíam resoluções distintas e formatos desiguais, comprometendo a eficácia do modelo de aprendizado profundo. Essa limitação evidenciou a necessidade de aprimorar o processo de coleta e padronização das imagens para melhorar o desempenho do sistema.

Para solucionar as falhas identificadas no primeiro dataset, foi elaborado um segundo banco de dados contendo imagens com a mesma resolução (400x400px) e formatação. Este novo *dataset* é composto por 250 imagens, sendo 200 destinadas ao treinamento e 50 à validação, igualmente distribuídas entre as cinco subclasses de manifestações patológicas: Bolor, Corrosão, Fissura, Umidade e Vegetação.

Apesar da menor quantidade de imagens em comparação ao primeiro *dataset*, a padronização das imagens demonstrou ser uma abordagem eficaz. Os resultados obtidos com o novo banco de dados foram significativamente superiores, evidenciando que a uniformidade na resolução e formatação das imagens é mais relevante para o desempenho do modelo do que a quantidade total de dados disponíveis. Embora ainda sejam observados erros de identificação de manifestações patológicas relacionadas à quantidade limitada de imagens, este problema pode ser facilmente resolvido por meio do aumento do tamanho do conjunto de dados.

No entanto, esse *dataset* não produziu resultados satisfatórios no *software*, uma vez que as imagens possuíam resoluções distintas e formatos desiguais, comprometendo a eficácia do modelo de aprendizado profundo. Essa limitação evidenciou a necessidade de aprimorar o processo de coleta e padronização das imagens para melhorar o desempenho do sistema.

No que diz respeito ao código, técnicas como *Data Augmentation*, *Transfer Learning* e *Fine-Tuning* desempenham papéis cruciais na melhoria da performance do modelo. Data Augmentation aumenta a diversidade do conjunto de treinamento sem a necessidade de adquirir mais dados, simulando diferentes condições de iluminação, rotação, zoom, deslocamento e reflexo, o que pode aumentar a robustez do modelo frente a variações reais dos dados. *Transfer Learning* utiliza modelos pré-treinados em grandes bases de dados e adapta-os a um novo conjunto de dados, acelerando o processo de treinamento e melhorando a acurácia, especialmente quando o conjunto de dados é limitado.

5.2 *Treinamento e validação do modelo*

A Figura 2 apresenta a matriz de confusão gerada durante o treinamento do modelo, ilustrando a precisão e os erros de classificação para cada subclasse de manifestação patológica analisada. A Figura 3 exibe os gráficos relacionados ao treinamento, detalhando o comportamento do modelo ao longo das épocas, como a evolução da acurácia e a redução da perda nos conjuntos de treinamento e validação. Representações que são fundamentais para avaliar o desempenho do modelo e identificar possíveis ajustes necessários.

Figura 2. Matriz Confusão do *Dataset* 1

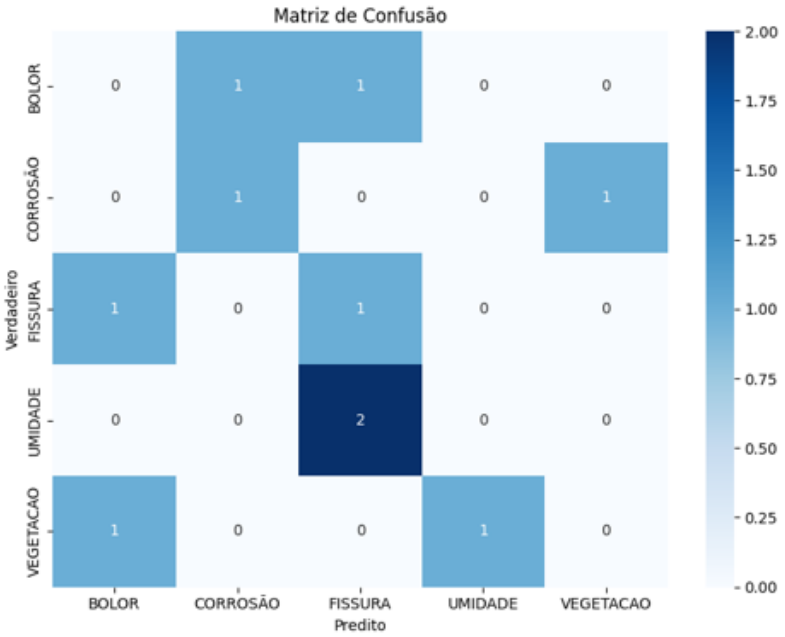

Fonte: Autoria Própria.

Figura 3. Representação gráfica de treinamento do Dataset 1

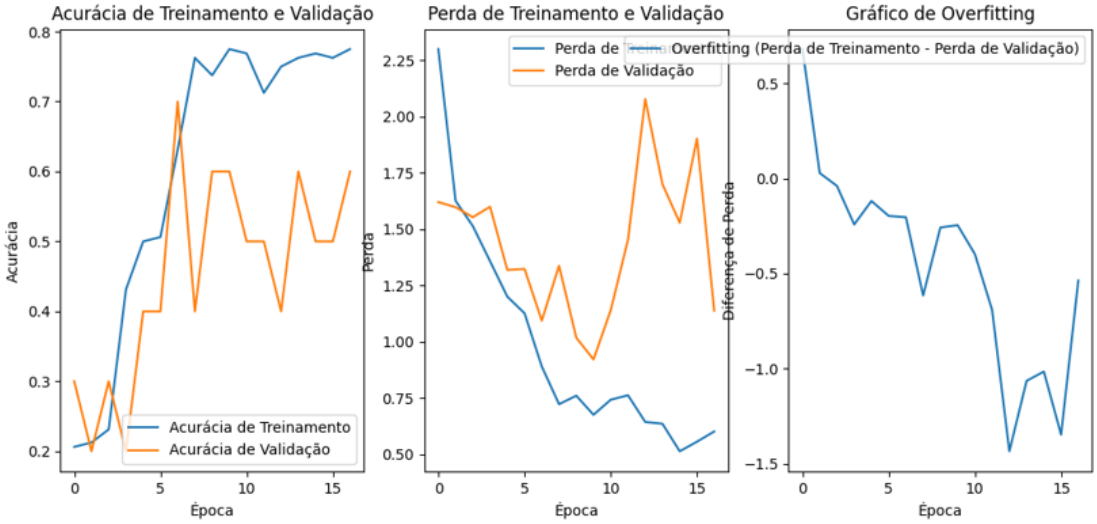

Fonte: Autoria própria.

Apesar da menor quantidade de imagens em comparação ao primeiro *dataset*, a padronização das imagens demonstrou ser uma abordagem eficaz. Os resultados obtidos com o novo banco de dados foram significativamente superior, evidenciando que a uniformidade na resolução e formatação das imagens é mais relevante para o desempenho do modelo do que a quantidade total de dados disponíveis. Embora ainda sejam observados erros de identificação de manifestações patológicas relacionadas à quantidade limitada de imagens, este problema pode ser facilmente resolvido por meio do aumento do tamanho do conjunto de dados.

A seguir, são apresentadas a Figura 4, contendo a matriz de confusão do *dataset* 2, e a Figura 5, com os gráficos de treinamento.

Figura 4. Matriz confusão do Dataset 2

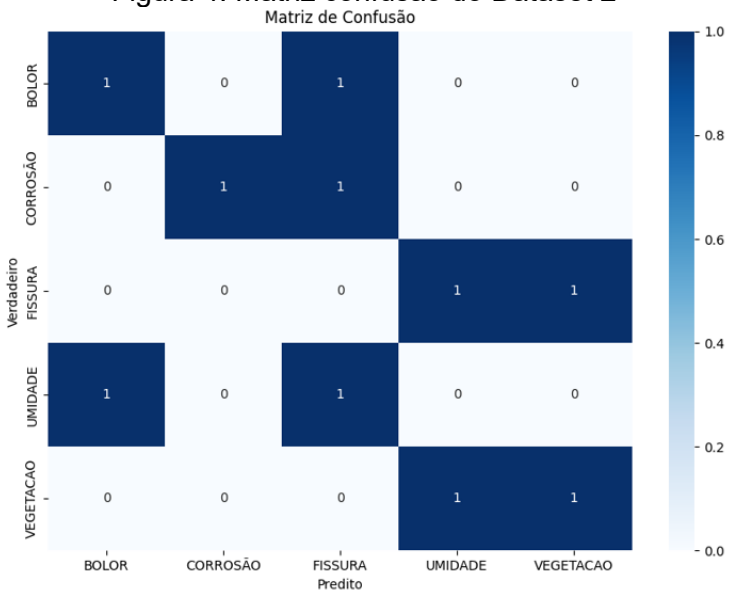

Fonte: Autoria própria.

Figura 5. Representação gráfica de treinamento do Dataset 2

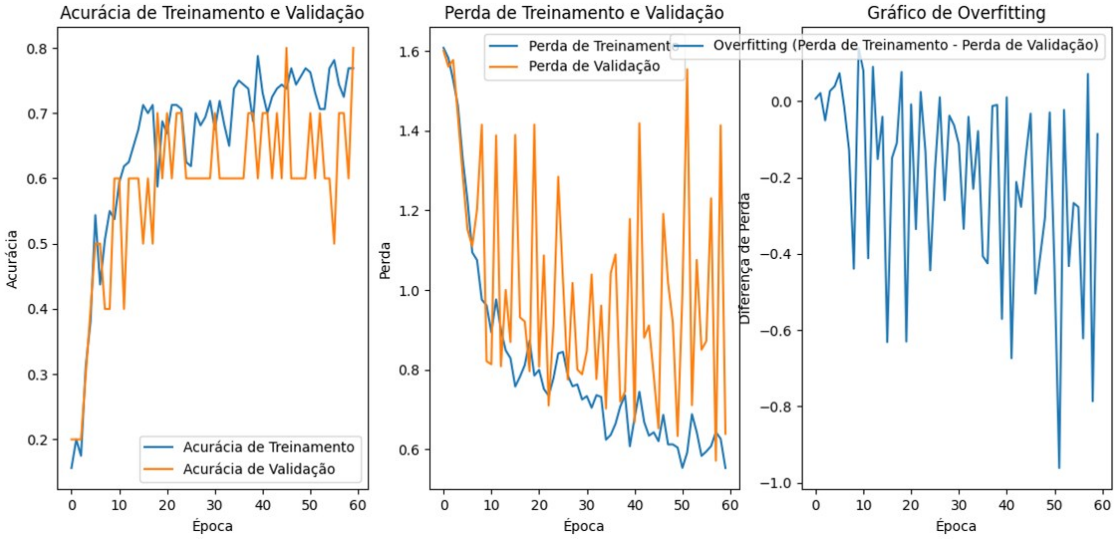

Fonte: Autoria própria.

Durante a criação dos conjuntos de dados, observou-se que as imagens que apresentam a manifestação patológica centralizada são as mais eficazes. Além disso, constatou-se que conjuntos de dados compostos por imagens com formatação e resolução uniformes também se mostram mais eficientes.

5.3 Desenvolvimento do software

Durante o desenvolvimento do projeto, foram utilizadas IA's para auxiliar na criação de códigos, otimização do aprendizado e aprofundamento nos estudos teóricos. As principais ferramentas empregadas foram *ChatGPT*, *Google Gemini e GitHub Copilot, React e Python.*

Essas ferramentas foram fundamentais para superar desafios técnicos, explorar novos conceitos e melhorar a qualidade das implementações realizadas ao longo do projeto.

6 RESULTADOS E DISCUSSÃO

Embora os resultados obtidos até o momento indicam avanços no desempenho do modelo, é importante destacar que, devido ao tamanho limitado do *dataset*, tanto o processo de treinamento quanto os índices de acurácia ainda não atingiram o nível ideal desejado. A busca é por resultados mais precisos e refinados, o que demanda ajustes contínuos e, possivelmente, uma base de dados mais robusta.

6.1 Resultados da rede neural

Nas Figuras 6 e 7, são apresentados os gráficos e as matrizes de confusão que comparam os primeiros testes com os resultados mais recentes. Essa comparação evidencia a evolução do modelo e permite identificar pontos de melhoria para futuras iterações.

Os três primeiros gráficos (superiores) ilustram o desempenho inicial do modelo nos primeiros dias de desenvolvimento, evidenciando a evolução da qualidade de treinamento e aprendizado. Em contraste, os três gráficos inferiores apresentam os resultados dos treinamentos mais recentes, demonstrando melhorias no desempenho e na capacidade de generalização do modelo.

Figura 6: Comparação dos gráficos de treinamento do modelo de inteligência artificial

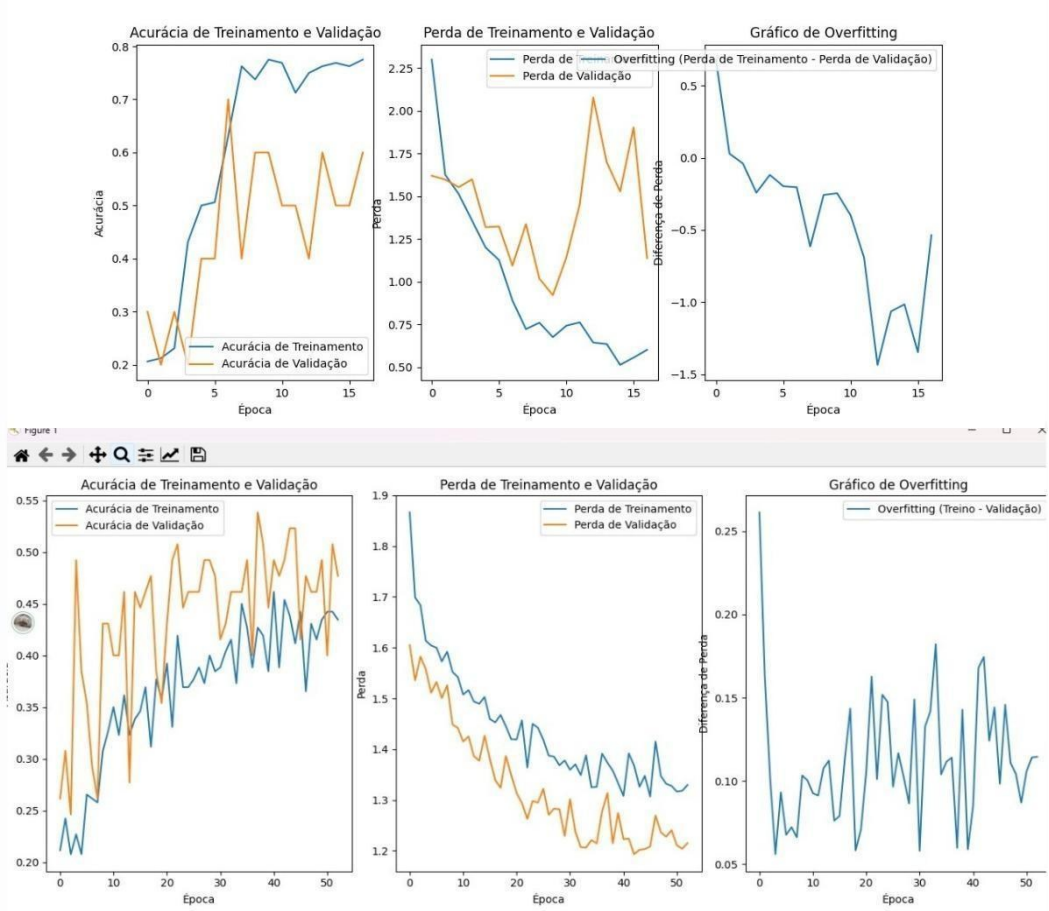

Fonte: Autoria própria.

Figura 7: Representação das matrizes de confusão do modelo de inteligência artificial

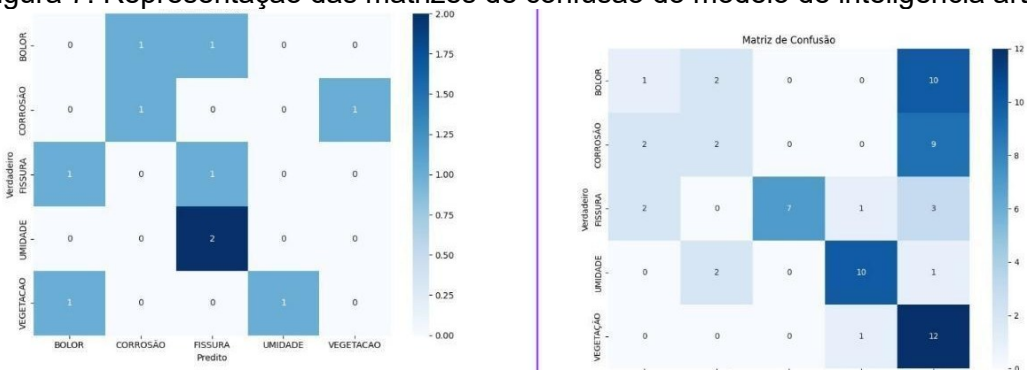

Fonte: Autoria própria.

A matriz à esquerda corresponde aos primeiros dias de desenvolvimento, refletindo o desempenho inicial do modelo. Já a matriz à direita mostra o resultado mais recente, evidenciando a evolução na capacidade de classificação e a melhoria na performance ao longo do processo de treinamento.

6.2 *Criação da aplicação*

A aplicação foi cuidadosamente implementada com o objetivo de integrar a IA ao processo de detecção e tratamento de manifestações patológicas. Utilizando o modelo previamente treinado, a interface permite que os usuários acessem os resultados de forma prática e visual. O *front-end*, desenvolvido com foco em usabilidade e clareza, está hospedado na plataforma Vercel, o que assegura fácil acesso à aplicação por meio da *web*.

Na Figura 8 e 9, serão apresentadas imagens ilustrativas da interface da aplicação:

Figura 8: Exemplo da aplicação em execução, demonstrando seu funcionamento e a interface operacional já implementada

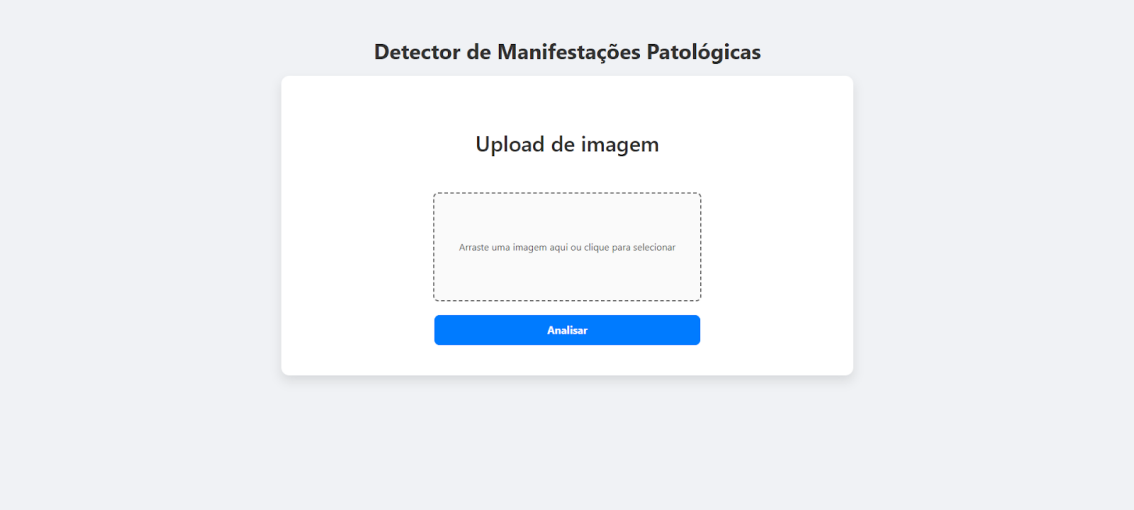

Fonte: Autoria própria.

Figura 9: Demonstração da utilização atual do modelo de inteligência artificial

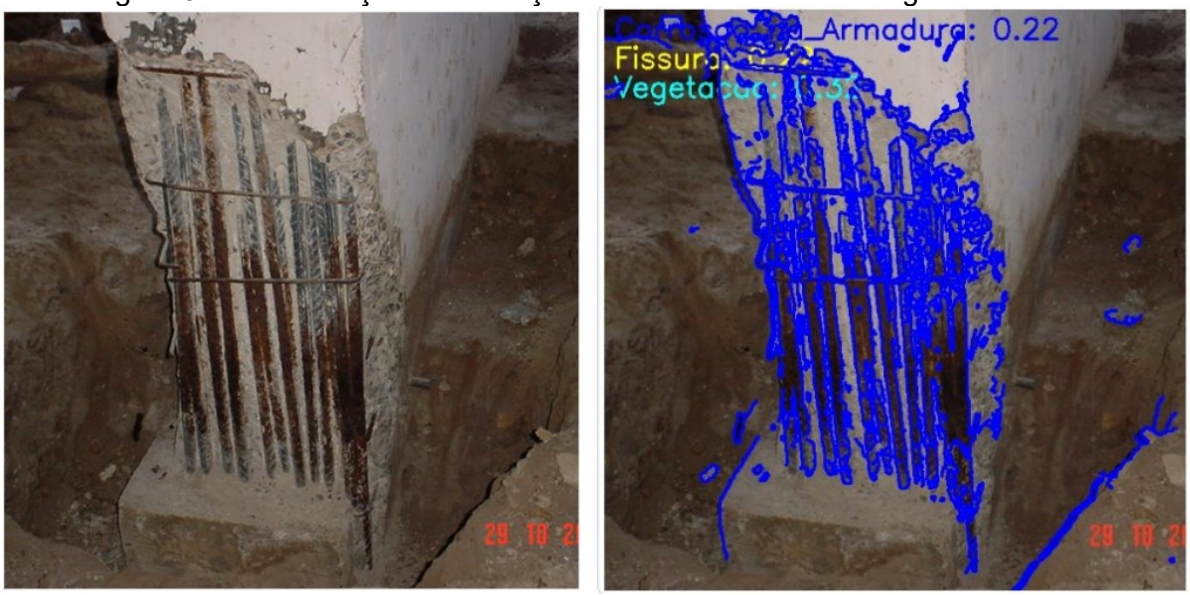

Fonte: Autoria própria.

A demonstração foi testada com uma imagem inédita, que não estava presente no conjunto de treinamento, o que foi possível para avaliar sua capacidade de generalização e desempenho em dados não vistos anteriormente.

7 CONCLUSÕES

Este artigo demonstrou o potencial da IA, especificamente por meio de redes neurais convolucionais, na detecção automatizada de manifestações patológicas em edificações, como bolores, fissuras, corrosão, umidade e presença de vegetação. A aplicação desenvolvida integra técnicas modernas de segmentação de imagem e aprendizado de máquina, resultando em uma ferramenta prática, acessível e eficiente para diagnósticos visuais no contexto da engenharia civil.

Apesar das limitações impostas pelo tamanho do *dataset*, os resultados obtidos mostram uma evolução significativa na acurácia do modelo ao longo das iterações. A implementação de uma interface funcional e intuitiva, com hospedagem via plataforma Vercel, permitiu o acesso simplificado à aplicação, evidenciando sua viabilidade como solução tecnológica para apoio à inspeção predial.

A proposta contribui para a modernização dos métodos de monitoramento de edificações, promovendo práticas mais seguras e sustentáveis, e abre caminho para futuras melhorias, como a ampliação da base de dados, a integração com sistemas de drones e o refinamento contínuo dos modelos de IA. Assim, a iniciativa representa um avanço relevante no uso de tecnologias inteligentes aplicadas à manutenção e durabilidade das construções civis.

REFERÊNCIAS BIBLIOGRÁFICAS

BARROS, G. A.; SILVA, A. A. P. **Inovações na correção de manifestações patológicas em edifícios: revisão de literatura.** Revista cientifica: semana academica, Fortaleza-ce. edição 251. v.12. ano 2024. DOI: http://dx.doi.org/10.35265/2236-6717-252-13071.

COSTA, L. S.; SILVA, W. A. **Manifestações patológicas em fachadas de construções históricas: estudo de caso da Igreja de Nossa Senhora do Carmo em São Luís – MA.** Research, Society and Development, v. 11, n. 2, e24011225819, 2022 (CC BY 4.0) | ISSN 2525-3409 | DOI: http://dx.doi.org/10.33448/rsd-v11i2.25819.

DUTRA, A. P.; ALBUQUERQUE, E. S. AZEVEDO, P. I. P. FREIRE, M. M. *et al.* **Diagnóstico sobre la Fachada de la Iglesia de São José.** XVII Congreso Latinoamericano de Patología de Construcción y XVIX Congreso de Control de

Calidad en la Construcción Santa Cruz de la Sierra, Bolivia realizado del 28 al 30 de septiembre de 2023.

DUTRA, A. P.; ALBUQUERQUE, E. S.; VELOZO, J. H. P. *et al.* **Estudo de caso: recuperação estrutural das fachadas.** ANAIS DO 64 CONGRESSO BRASILEIRO DO CONCRETO, 2023. ISSN 2175-8182.

LUDERMIR, T. B. **Inteligência artificial e aprendizado de máquina: estado atual e tendências**. Universidade Federal de Pernambuco, Centro de Informática, Recife, Estudos avançados 35 (101), 2021. DOI: 10.1590/s0103-4014.2021.35101.007.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. **Objetivo 9. Construir infraestruturas resilientes, promover a industrialização inclusiva e sustentável e fomentar a inovação**. Brasília: Nações Unidas, 2025. Disponível em: https://brasil.un.org/pt-br/sdgs/9. Acesso em: 01/06/2025.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS. **Objetivo 11. Tornar as cidades e os assentamentos humanos inclusivos, seguros, resilientes e sustentáveis**. Brasília: Nações Unidas, 2025. Disponível em: https://brasil.un.org/pt-br/sdgs/11. Acesso em: 01/06/2025.

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

SILVA, I. S. V. *et al.* **Study of the pathological manifestations of the São Pedro and São Paulo Apóstolos Church.** Research, Society and Development, v. 13, n. 10, e149131047257, 2024 (CC BY 4.0) | ISSN 2525-3409 | DOI: http://dx.doi.org/10.33448/rsd-v13i10.47257.

VELOZO, J. H. P.; ALBUQUERQUE, E. S. *et al.* **Uso de redes neurais para detecção de manifestações patológicas utilizando imagens capturadas por aeronaves remotamente pilotadas.** ANAIS DO 65 CONGRESSO BRASILEIRO DO CONCRETO, 2024. ISSN 2175-8182.