CLASSIFICAÇÃO AUTOMATIZADA DE MANIFESTAÇÕES PATOLÓGICAS EM PAREDES DE CONCRETO POR REDES NEURAIS CONVOLUCIONAIS

Jéfiter Soares Gonçalves[1], Brenner dos Santos de Araújo[1], Fernanda Nepomuceno Costa[1], Luã Melo Sobral Lopes[1], Thiago de Oliveira Ribeiro[1].

Universidade Federal do Recôncavo da Bahia/ Centro de Ciências Exatas e Tecnológicas, Rua Rui Barbosa, 710, Centro – 44380-000 – Cruz das Almas-BA, Brasil, jefgoncalves@outlook.com, brenner_sa@hotmail.com, fernandacosta@ufrb.edu.br, lualmsl98@gmail.com, thiagoribeiro@aluno.ufrb.edu.br.

Resumo
As paredes de concreto moldadas no local destacam-se pela produtividade e padronização, porém podem apresentar manifestações patológicas que comprometem seu desempenho. Este trabalho avaliou o uso de Redes Neurais Convolucionais (CNN) na classificação automatizada dessas manifestações por meio de Deep Learning e processamento digital de imagens. Foi utilizado um banco de 1.713 imagens, distribuídas em quatro classes: ninhos de concretagem, fissuras, manchas de desmoldante e vesículas e bexigas. Foram avaliadas cinco arquiteturas de CNN: EfficientNetB0, ResNet50, InceptionV3, Xception e VGG16. Todas apresentaram acurácia superior a 90%, com destaque para EfficientNetB0 e ResNet50, que alcançaram 97%. A análise das matrizes de confusão indicou maior facilidade na classificação de fissuras e maior ocorrência de erros na classe ninhos de concretagem. Os resultados demonstram o potencial das CNN para auxiliar na classificação automatizada de manifestações patológicas, contribuindo para inspeções mais ágeis e padronizadas.
Palavras-chave: Inteligência Artificial, Visão Computacional, Redes Neurais Convolucionais, Paredes de concreto, Manifestações patológicas.

Área do Conhecimento: Engenharias.

Introdução

O sistema construtivo de paredes de concreto moldadas no local tem se destacado na construção civil brasileira, especialmente em empreendimentos habitacionais de larga escala, devido à elevada produtividade, padronização e racionalização dos processos executivos. Entretanto, essas edificações estão sujeitas a manifestações patológicas decorrentes de falhas de projeto, execução, controle tecnológico e manutenção, podendo comprometer seu desempenho, durabilidade e vida útil (Helene, 1992; Santana, 2025).

A identificação precoce dessas manifestações é fundamental para a manutenção da qualidade e segurança das edificações. Contudo, as inspeções convencionais dependem da avaliação visual de profissionais especializados, podendo apresentar limitações relacionadas à subjetividade, ao tempo de execução e à ocorrência de falhas humanas.

Com o avanço da Indústria 4.0 e das tecnologias computacionais, a Inteligência Artificial vem ampliando suas aplicações na Engenharia Civil, especialmente na inspeção e no monitoramento de estruturas. Nesse contexto, o processamento digital de imagens associado às Redes Neurais Convolucionais (CNN) possibilita a identificação automatizada de padrões e manifestações patológicas em superfícies de concreto, apresentando resultados promissores em estudos anteriores (Cha; Choi; Büyüköztürk, 2017; Mohan; Poobal, 2018).

As CNN, particularmente por meio de técnicas de Deep Learning, são capazes de extrair automaticamente características relevantes das imagens, tornando-se adequadas para tarefas de classificação e reconhecimento visual (Goodfellow; Bengio; Courville, 2016). Dessa forma, sua aplicação pode contribuir para tornar as inspeções mais rápidas, padronizadas e eficientes, reduzindo a subjetividade dos métodos convencionais.

Diante desse contexto, este trabalho teve como objetivo desenvolver e avaliar um sistema baseado em Redes Neurais Convolucionais para a classificação automática de manifestações patológicas em paredes de concreto moldadas no local, utilizando processamento digital de imagens e um banco de

dados próprio, contribuindo para o avanço da aplicação da Inteligência Artificial na inspeção de edificações.

Metodologia

A pesquisa caracteriza-se como aplicada, experimental e predominantemente quantitativa, com caráter exploratório e descritivo, voltada ao desenvolvimento e avaliação de modelos de Inteligência Artificial para a classificação automática de manifestações patológicas em paredes de concreto *in loco*. Foram coletadas e catalogadas imagens em campo, posteriormente organizadas em quatro classes — fissuras, ninhos de concretagem, manchas de desmoldante e vesículas ou bexigas. Após o pré-processamento e a divisão dos dados, diferentes arquiteturas de Redes Neurais Convolucionais (CNN) foram avaliadas por meio de *transfer learning*, utilizando métricas de classificação para comparar seu desempenho.

O empreendimento estudado está localizado na Bahia, possui 38 blocos residenciais, contendo 600 unidades habitacionais e, edificação de quatro pavimentos, executados em paredes de concreto moldadas in loco. As paredes possuem 10 cm de espessura, sendo utilizados concreto superfluido com f_{ck} de 25 MPa e abatimento de 220 ± 30 mm. O empreendimento apresenta 15 blocos com fundação em radier e 23 em radier estaqueado, com estacas entre 8 e 11 m de profundidade. Dos 38 blocos apenas 79% participou do estudo pois o restante ainda não estava na etapa de concretagem das paredes.

A coleta das imagens foi realizada diretamente em campo, por meio de inspeções visuais, contemplando diferentes condições de iluminação, ângulos, distâncias de captura e níveis de severidade das manifestações patológicas. O banco de dados foi composto por quatro classes: ninhos de concretagem, fissuras, manchas decorrentes do excesso de desmoldante e vesículas e bexigas. Para ampliar a variabilidade dos padrões de fissuração e reduzir o risco de *overfitting*, foram incorporadas 630 imagens provenientes de um banco de dados público “Concrete Crack Images for Classification” (ÖZGENEL, 2019). Posteriormente, todas as imagens foram catalogadas, rotuladas e organizadas de acordo com suas respectivas classes, considerando o desbalanceamento do conjunto de dados para as etapas de treinamento e avaliação das Redes Neurais Convolucionais, conforme Erro: Origem da referência não encontrada e demonstrado na Figura 1.

Figura 1 –Manifestações patológicas: (A) Manchas de desmoldante; (B)Fissuras; (C)Ninhos de concretagem; (D) Vesículas ou Bexigas.



(A)



(B)



(C)



(D)

Fonte: Autor.

Tabela 1 – Distribuição de imagens entre classes de manifestações patológicas.

Classe de manifestações patológicas	**Quantidade de Imagens coletadas *in loco***	**Quantidade de imagens provenientes de base externas**	**Total**
Ninhos de concretagem	125	-	125
Fissuras	139	630	769
Manchas por excesso de desmoldante	272	-	272
Vesículas e bexigas	547	-	547
Total	1.083	630	1.713

Fonte: Autores.

Após a preparação dos dados, foram avaliadas cinco arquiteturas de CNN — VGG16, ResNet50, InceptionV3, Xception e EfficientNetB0 — utilizando *transfer learning* com pesos pré-treinados no ImageNet. As arquiteturas foram selecionadas por suas diferentes estratégias de extração de características e níveis de complexidade, permitindo uma comparação abrangente. Para a classificação das quatro classes, as camadas finais foram adaptadas com Softmax, utilizando Categorical Cross-Entropy como função de perda e Adam como otimizador. Após o treinamento das arquiteturas, foram definidas métricas para avaliar o desempenho dos modelos, considerando o caráter multiclasse e o desbalanceamento do conjunto de dados.

Foram utilizadas acurácia (*accuracy*), precisão (*precision*), revocação (*recall*), F1-Score e matriz de confusão, permitindo analisar tanto o desempenho geral quanto a capacidade de classificação de cada manifestação patológica. A acurácia representa a proporção de classificações corretas; a precisão indica a confiabilidade das previsões positivas; o recall corresponde à capacidade de identificar corretamente as amostras de cada classe; e o F1-Score estabelece um equilíbrio entre precisão e *recall*.

O Verdadeiro Positivo (VP) corresponde aos casos em que o modelo classifica corretamente uma imagem como pertencente à manifestação patológica analisada. O Verdadeiro Negativo (VN) ocorre quando o modelo identifica corretamente que a imagem não pertence à classe em avaliação. O Falso Positivo (FP) representa as situações em que uma imagem é classificada incorretamente como pertencente à manifestação patológica analisada, quando, na realidade, pertence a outra classe. Por fim, o Falso Negativo (FN) ocorre quando o modelo deixa de reconhecer uma imagem pertencente à manifestação patológica em questão, classificando-a equivocadamente como integrante de outra categoria. A matriz de confusão, por sua vez, permite visualizar os acertos e erros entre as classes.

Para a avaliação multiclasse, foi adotada a abordagem One-vs-Rest (OvR), considerando cada manifestação como classe positiva e as demais como negativas. Dessa forma, as métricas permitiram comparar as arquiteturas e identificar o modelo com melhor desempenho na classificação automática das manifestações patológicas, como resumido na Tabela 2.

Tabela 2 – Métricas utilizadas na avaliação dos modelos desenvolvidos.

Métrica	Objetivo	Justificativa	Fórmulas
Acurácia	Avaliar a proporção total de classificações corretas	Fornece uma medida global do desempenho do modelo	$ac = \frac{VP + VN}{VP + FN + VN + FP}$
Precisão	Avaliar a confiabilidade das classificações positivas	Reduzir a ocorrência de falsos positivos	$Precisão = \frac{VP}{VP + FP}$
Recall	Avaliar a capacidade de identificação das classes reais	Reduzir a ocorrência de falsos negativos	$Recall = \frac{VP}{VP + FN}$
F1-score	Mensurar o equilíbrio entre precisão e *Recall*	Indicada para classes desbalanceadas por combinar precisão e R*ecall*	$F1_{Sc} = \frac{2 * precisão + recall}{precisão + recall}$
Matriz de confusão	Identificar padrões de erros e acertos entre as classes	Permitir análise detalhada do comportamento dos modelos	-

Fonte: Autores.

Resultados

Ao realizar os testes para o desempenho global das arquiteturas foram obtidos os resultados demonstrados na Tabela 3. Observa-se que todos os modelos alcançaram acurácia igual ou superior a 90%, com destaque para a EfficientNetB0, que apresentou o melhor desempenho geral, enquanto a VGG16 obteve os menores resultados. Os resultados obtidos corroboram aqueles apresentados por Arafin et al. (2022), que compararam cinco arquiteturas convolucionais (VGG19, ResNet50, InceptionV3, Xception e MobileNetV2) para a classificação automática de defeitos em concreto. Embora nem todas as arquiteturas avaliadas naquele estudo tenham sido empregadas nesta pesquisa, uma vez que o presente trabalho avaliou EfficientNetB0, ResNet50, InceptionV3, Xception e VGG16, ambos os estudos evidenciam o elevado potencial das redes neurais convolucionais para aplicações voltadas à identificação automática de manifestações patológicas em concreto.

Tabela 3 – Desempenho global das arquiteturas convolucionais no conjunto de validação.

Arquitetura	Acurácia	Precisão	*Recall*	F1-score	Parâmetros
EfficientNetB0	0,97	0,97	0,97	0,97	5,3 milhões
ResNet50	0,97	0,97	0,97	0,96	25,6 milhões
InceptionV3	0,94	0,95	0,94	0,94	23,9 milhões
Xception	0,93	0,94	0,93	0,94	22,9 milhões
VGG16	0,90	0,89	0,90	0,88	138,4 milhões

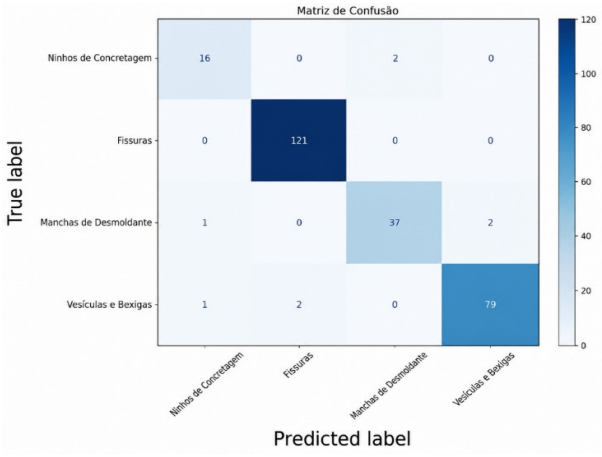
Fonte: Autores.

As matrizes de confusão evidenciaram predominância de classificações corretas nas arquiteturas analisadas, embora tenham sido observadas diferenças na distribuição dos erros entre as classes. Para a EfficientNetB0, que apresentou o melhor desempenho, verificou-se maior concentração das classificações na diagonal principal, indicando elevada capacidade de discriminação entre as manifestações patológicas. Em contrapartida, a VGG16 apresentou maior dispersão das classificações incorretas, caracterizando o pior desempenho entre as arquiteturas avaliadas.

De modo geral, a classe fissuras apresentou elevada taxa de classificações corretas, enquanto ninhos de concretagem concentrou a maior quantidade de erros. As classes manchas de desmoldante e vesículas e bexigas apresentaram comportamento intermediário, com menor ocorrência de

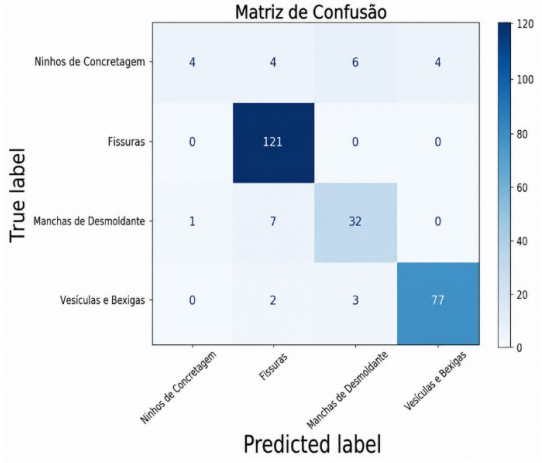
classificações equivocadas. A Figura 2 e a Figura 3 apresentam os resultados das matrizes de confusão das arquiteturas EfficienteNetB0 e da VGG16.

Figura 2 – Matriz de confusão EfficienteNetB0.



Fonte: Autores.

Figura 3 – Matriz de confusão VGG16.



Fonte: Autores.

Discussão

Os resultados apresentados na Tabela 3 demonstraram que todas as arquiteturas apresentaram desempenho satisfatório, com acurácia igual ou superior a 90%. A EfficientNetB0 e a ResNet50 obtiveram os melhores resultados, ambas com 97% de acurácia, destacando-se a EfficientNetB0 pelo maior equilíbrio entre as métricas. InceptionV3 e Xception alcançaram 94% e 93%, respectivamente, enquanto a VGG16 apresentou 90%. A proximidade entre os resultados das principais arquiteturas evidencia a viabilidade das CNN para a classificação multiclasse de manifestações patológicas em paredes de concreto, reforçando seu potencial como ferramenta de apoio à inspeção automatizada na Engenharia Civil. Ao analisar a quantidade de parâmetros (quantos cálculos a arquitetura faz para dar um resultado) evidenciou mais uma vez a eficiência da arquitetura EfficienteNetB0, pois tem o menor parâmetro enquanto a VGG16 tem o maior parâmetro, ou seja, uma arquitetura mais eficiente e com menor custo computacional.

Ao analisar as matrizes de confusão mostrou que maior quantidade de classificações corretas observada para fissuras pode estar relacionada à presença de padrões lineares e visualmente definidos, características que favorecem sua identificação pelas redes neurais convolucionais. Por

outro lado, os erros associados aos ninhos de concretagem podem ser explicados pela maior variabilidade visual dessa manifestação, que pode apresentar diferentes formas, tamanhos, texturas e níveis de profundidade, além de eventualmente coexistir com outras irregularidades superficiais.

A diferença entre EfficientNetB0 e VGG16 evidencia a influência da arquitetura na capacidade de discriminação das manifestações patológicas. A maior concentração de resultados na diagonal principal da EfficientNetB0 indica maior robustez na classificação, enquanto a maior dispersão observada na VGG16 sugere maior dificuldade em distinguir classes visualmente semelhantes.

Esses resultados reforçam que a avaliação das matrizes de confusão é relevante não apenas para quantificar os acertos e erros, mas também para identificar quais manifestações apresentam maior dificuldade de reconhecimento. Entretanto, como essa análise não permite compreender diretamente os aspectos visuais associados às decisões dos modelos, torna-se pertinente complementar a avaliação por meio de uma análise qualitativa das imagens classificadas.

Conclusão

Com base nos resultados obtidos, conclui-se que as Redes Neurais Convolucionais apresentaram desempenho satisfatório, com acurácia superior a 90% em todas as arquiteturas avaliadas, destacando-se a EfficientNetB0, com 97% de acurácia. As fissuras apresentaram maior taxa de acerto, enquanto os ninhos de concretagem demonstraram maior dificuldade de classificação devido à variabilidade visual. A VGG16 apresentou maior quantidade de classificações incorretas. Dessa forma, os resultados evidenciam o potencial das CNNs como ferramenta de apoio à identificação automatizada de manifestações patológicas em paredes de concreto moldadas no local.

Cabe ressaltar, entretanto, que a ferramenta desenvolvida atua como sistema de suporte à decisão e triagem preliminar, não devendo ser utilizada de forma isolada. A identificação automatizada de manifestações superficiais não substitui a vistoria técnica in loco nem o diagnóstico causal realizado por engenheiro especialista, etapas indispensáveis para avaliar a segurança estrutural e definir as diretrizes de recuperação.

Como trabalhos futuros, recomenda-se ampliar e diversificar o banco de imagens, contemplando diferentes condições de iluminação, ângulos de captura e níveis de severidade, visando aumentar a capacidade de generalização dos modelos.

Referências

ARAFIN, P.; ISSA, A.; BILLAH, A. H. M. M. Performance comparison of multiple convolutional neural networks for concrete defects classification. Sensors, Basel, v. 22, n. 22, p. 8714, 2022. DOI: https://doi.org/10.3390/s22228714.

CHA, Y. J.; CHOI, W.; BÜYÜKÖZTÜRK, O. Deep learning-based crack damage detection using convolutional neural networks. Computer-Aided Civil and Infrastructure Engineering, 2017.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep Learning. Cambridge: MIT Press, 2016.

HELENE, P. Manual para reparo, reforço e proteção de estruturas de concreto. São Paulo: Pini, 1992.

MOHAN, A.; POOBAL, S. Crack detection using image processing: A critical review and analysis. Alexandria Engineering Journal, v. 57, n. 2, p. 787–798, 2018.

ÖZGENEL, C. F. Concrete Crack Images for Classification. Mendeley Data, v. 2, 2019. Disponível em: <https://data.mendeley.com/datasets/5y9wdsg2zt/2>. Acesso em: 01 jul. 2026.

SANTANA, LUIS F. D. Manifestações patológicas em paredes de concreto moldadas in loco: análise das principais causas em uma obra de 551 unidades habitacionais unifamiliares. 2025. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) – Universidade Federal do Recôncavo da Bahia, Centro de Ciências Exatas e Tecnológicas, Cruz das Almas, 2025.

Agradecimentos

Ao Grupo de Pesquisa VALORA Civil, pela oportunidade de aprendizado e desenvolvimento científico, e aos grupos GEOPAVE e ICT, especialmente ao Brenner, pelo apoio e contribuição na realização dos testes das arquiteturas de Redes Neurais Convolucionais.