



ConBREpro

XV CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO

03 a 05 de dezembro de 2025

As Engenharias na Transformação Digital das PMEs

Aplicação de Redes Neurais na detecção de patologias em elementos construtivos: Uma revisão sistemática

Gabriella Gonçalves Guindani

Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS)- Universidade Tecnológica Federal do Paraná, Pato Branco

Flávio Trojan

Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS)- Universidade Tecnológica Federal do Paraná, Pato Branco

Gilson Adamczuk Oliveira

Programa de Pós-Graduação em Engenharia de Produção e Sistemas (PPGEPS)- Universidade Tecnológica Federal do Paraná, Pato Branco

Resumo: Com o avanço da tecnologia, a engenharia civil tem adotado ferramentas de inteligência artificial (IA) para aprimorar a identificação de problemas em estruturas. Este artigo apresenta uma revisão sistemática da literatura sobre como as redes neurais são utilizadas na segmentação e no reconhecimento de imagens para detectar patologias. O protocolo da revisão de literatura foi adaptado de Kitchenham (2004) em que consiste na elaboração do protocolo de revisão, busca e seleção de artigos com critérios de inclusão e exclusão, extração de dados e síntese e discussão dos dados. A pesquisa foi realizada em plataformas como Scopus, IEEE Xplore e Web of Science, usando palavras-chave relacionadas a redes neurais, imagens e elementos construtivos. Para os resultados, foi usada a pergunta pesquisa para a análise semântica e similaridade dos documentos obtidos por meio do modelo de linguagem paraphrase-multilingual-MiniLM-L12-v2 que transformou a pergunta de pesquisa e os documentos (títulos e resumos) em representações numéricas (embeddings). Após isso, foi constatado que a patologia mais relatada é a fissura seguida das patologias corrosão e deterioração. A rede neural convolucional é a arquitetura mais relacionada com patologias em elementos construtivos seguida das redes neurais Vision Transformer e Gan. O estudo enfatiza a evolução no diagnóstico de patologias na construção civil e proporciona um panorama geral do uso de redes neurais nessa área.

Palavras-chave: Convolutional Neural Networks, Pathology Detection, Artificial Intelligence, Civil Engineering

Application of Neural Networks in the Detection of Pathologies in Building Elements: A Systematic Review

Abstract: With the advancement of technology, civil engineering has increasingly adopted artificial intelligence (AI) tools to improve the identification of structural problems. This article presents a systematic literature review on how neural networks are applied in image segmentation and recognition for pathology detection. The review protocol was adapted from Kitchenham (2004), consisting of the development of the review protocol, search and selection of articles with inclusion and exclusion criteria, data extraction, and data synthesis and discussion. The research was conducted in databases such as Scopus, IEEE Xplore, and Web of Science, using keywords related to neural networks, images, and building elements. For the results, the research question was used for semantic analysis and document similarity through the paraphrase-multilingual-MiniLM-L12-v2

language model, which transformed the research question and the documents (titles and abstracts) into numerical representations (embeddings). The findings showed that the most frequently reported pathology is cracking, followed by corrosion and deterioration. Convolutional neural networks were identified as the most widely used architecture for detecting pathologies in building elements, followed by Vision Transformer and GAN neural networks. This study highlights the advances in pathology diagnosis in civil construction and provides an overview of the use of neural networks in this field.

Keywords: Convolutional Neural Networks, Pathology Detection, Artificial Intelligence, Civil Engineering

1. Introdução

Durante os últimos anos, o setor da construção civil tem se modernizado continuamente, incorporando novas tecnologias com a finalidade de aumentar a eficiência, a durabilidade e a segurança das edificações. Nesse contexto, destaca-se o estudo das patologias das construções, que, para Gomide et al. (2021, pg 17), é o “estudo que se ocupa da natureza e das modificações das condições físicas e/ou funcionais produzidas pelas anomalias construtivas e falhas de manutenção, através de auditorias, perícias e ensaios técnicos”.

Com o avanço das ferramentas digitais, novas estratégias vêm sendo aplicadas ao diagnóstico dessas patologias, entre elas o uso da inteligência artificial (IA). Na construção civil, essa tecnologia tem ganhado notoriedade, especialmente na segmentação de imagens para detecção automática de anomalias em componentes estruturais, utilizando IAs como as redes neurais. Segundo (Lecun Y., 2015), redes neurais são algoritmos capazes de aprender representações em vários níveis, oferecendo suporte à classificação e previsão de novos dados a partir de grandes volumes de informações. Com o treinamento baseado nesses dados, torna-se possível identificar patologias a partir de imagens dos elementos estruturais.

Dessa forma, o respectivo artigo tem o objetivo de responder a seguinte pergunta de pesquisa: Com base em uma revisão sistemática da literatura, quais redes neurais e patologias são mais frequentemente abordadas para a detecção de patologias em elementos construtivos? Para isso, foi realizada uma revisão sistemática de literatura com o uso *embeddings* para identificar os tipos de Redes Neurais que estão sendo aplicados para segmentação de imagens de patologias em elementos construtivos e também as patologias mais citadas pelos autores da base de dados.

2. Reconhecimento Não-Linear com Redes Neurais

O reconhecimento não-linear com Redes Neurais tem como premissa a capacidade de modelar e distinguir padrões complexos que não acompanham relações lineares simples. As Redes Neurais com estrutura adaptativa, ao contrário das Redes Neurais convencionais, conseguem construir sua arquitetura ao longo do seu processo de treinamento. Além disso, são muito adequadas para problemas que abrangem mapeamentos não lineares complexos (SHARMA; CHANDRA, 2010).

Para a composição do tópico, serão expostos artigos em que foi relatado os tipos de Redes Neurais usados, suas aplicações e a avaliação de seus desempenhos. O artigo “Constructive Neural Networks: A Review” trata de Redes Neurais Construtivas que possuem a capacidade de construir sua arquitetura no processo de treinamento adicionando camadas ou neurônios de acordo a necessidade para melhor desempenho (SHARMA; CHANDRA, 2010). O algoritmo citado pelos autores é o Cascade-Correlation (CCA) começa com uma rede mínima e inclui novos neurônios que são treinados para fazer

a correção dos erros residuais o que faz com que a rede se adapte a problemas complexos de reconhecimento não linear (SHARMA; CHANDRA, 2010).

Os autores ainda relatam que os resultados gerados demonstram que essas redes alcançam melhor generalização e treinam em tempo menor comparando com redes de arquitetura fixa (SHARMA; CHANDRA, 2010). Já para o artigo “Distributed Sensory System for Surface Cracks Monitoring Based on Electrical Impedance Tomography”, os autores optaram pela Rede Neural Feedforward que foi treinada para analisar os padrões de condutividade elétrica coletados pela Tomografia de Impedância Elétrica (EIT) (RYNDIN; KONOPLEV; KULIKOVA, 2018). A Rede Neural foi usada para processar dados de EIT em tempo real, expondo a presença e localização de trincas superficiais em estruturas sobre a ação de carga. “Os resultados indicam que a rede neural alcançou alta precisão na detecção de trincas, com uma taxa de acerto superior a 95% em condições de teste controlados.” (RYNDIN; KONOPLEV; KULIKOVA, 2018).

Tendo em vista o artigo “A Green-IKE Inference System for Sustainable Products” a Rede Neural backpropagation foi combinada com o modelo cinza para correlacionar sentimentos humanos sobre o assunto sustentabilidade orientado para características de design de produtos (WU et al., 2020). Essa Rede Neural foi usada para presumir as preferências dos consumidores em relação a produtos sustentáveis, tomando como base dados arrecadados de avaliações subjetivas e atributos de design. “O sistema demonstrou uma precisão preditiva de 90%, indicando sua eficácia na tradução de sentimentos humanos em elementos de design sustentáveis.” (WU et al., 2020).

3. Propagação e permeabilidade de fissuras em materiais


A patologia é uma vertente da engenharia civil que trata da detecção de defeitos em elementos construtivos e uma dessas são as trincas e fissuras. O acompanhamento de trincas que acontecem em elementos estruturais com alta carga durante sua operação possui grande papel na garantia da segurança e confiabilidade das instalações (RYNDIN; KONOPLEV; KULIKOVA, 2018). Alguns elementos construtivos que sofrem com cargas excessivas são casco de aeronaves e navios, elementos de pontes, guindastes e plataformas de perfuração. Esses são sujeitos a grandes tensões mecânicas durante sua operação o que pode iniciar a formação e crescimento de trincas ocasionadas por fadiga que podem causar a destruição da estrutura (RYNDIN; KONOPLEV; KULIKOVA, 2018). Dessa forma, “A detecção precoce de trincas é essencial para evitar falhas catastróficas e assegurar que estruturas críticas permaneçam operacionais e seguras.” (RYNDIN; KONOPLEV; KULIKOVA, 2018, p. 3).

4. Metodologia

4.1 Estratégia de pesquisa

Este estudo busca compreender como diferentes redes neurais têm sido empregadas na detecção de patologias em elementos construtivos e as patologias mais citadas na literatura. Para alcançar esse objetivo, optou-se pela realização de uma revisão sistemática da literatura baseado no protocolo adaptado de Kitchenham e Charters (2007). Isso, assegura rigor e reprodutibilidade, visto que, conforme Mazzochin et al. (2024, p. 4), “os estudos selecionados são determinados a partir de uma sequência de passos reprodutíveis [...]”.

Figura 1: Fluxograma da metodologia



Fonte: Fote: adaptado (Kitchenham e Charters, 2007)

4.1. Protocolo de revisão

Para essa etapa, foi usado como base o protocolo estruturado de Kitchenham (2004) para encontrar, selecionar e analisar estudos científicos. Dessa forma, o protocolo adaptado possui as etapas de elaboração do protocolo de revisão, busca e seleção de artigos tendo critérios de inclusão e exclusão, extração de dados e síntese dos dados e exposição dos resultados.

3.3 Coleta e seleção dos artigos

Para a coleta dos artigos, foram definidas palavras-chave principais e alternativas (Quadro 1), alinhadas ao objetivo da pesquisa. Com base nesses termos, foram realizadas as buscas nas bases Scopus, IEEE Xplore e Web of Science. A seleção dos artigos seguiu critérios de inclusão e exclusão previamente estabelecidos (Quadro 2).

3.4 Processamento dos dados e classificação dos tópicos

Para a avaliação dos artigos, os arquivos foram coletados em formato *BibTeX*, unificados e convertidos no Google *Colab* utilizando a linguagem *Python*, o que permitiu o pré-processamento da base de dados. A pergunta de pesquisa foi utilizada para a análise semântica e similaridade dos documentos captados por meio do modelo de linguagem *paraphrase-multilingual-MiniLM-L12-v2* que converteu a pergunta de pesquisa e os documentos (títulos e resumos) em representações numéricas chamadas de *embeddings*. Esse tipo de abordagem baseada em redes neurais tem chamado a atenção na área de processamento de linguagem natural por conseguirem de forma efetiva identificar informações semânticas representando palavras, sentença ou até mesmo grandes elementos textuais em um espaço vetorial de baixa dimensão quando treinados em grandes conjuntos de textos (BLAGEC et al., 2019).

Dessa maneira, a similaridade entre a pergunta de pesquisa e cada artigo da base de dados foi calculada usando o método de avaliação de similaridade de cossenos entre a *embedding* da pergunta da pesquisa e as *embeddings* dos artigos. A similaridade de cossenos é uma medida de avaliação amplamente utilizada para similaridade semântica em que é medido a similaridade entre dois vetores baseado no ângulo cosseno formado entre esses. O cálculo é feito conforme a fórmula (1) (BLAGEC et al., 2019).

$$\cos(\theta) = \frac{A \cdot B}{\|A\| \cdot \|B\|} \quad (1)$$

Após o cálculo da similaridade, os artigos foram ranqueados com base no *score* da similaridade e os mais relevantes para a pesquisa, com *score* acima de 0.30, foram

selecionados para a extração de informações-chave. Para essa etapa, foi usada a biblioteca Python de Linguagem Natural, SpaCy, pra dividir cada resumo em sentença.

Para a identificação e categorização dos tipos de redes neurais, adotou-se uma lista predefinida de palavras-chave. Com base nos termos mais frequentes relacionados ao assunto, essa lista, adaptada de Lecun et al. (2015), foi utilizada para detectar e listar os tipos específicos de redes mencionados nos resumos. A lista inclui termos como: "perceptron", "multi-layer perceptron" (MLP), "convolutional neural network" (CNN), "recurrent neural network" (RNN), "long short-term memory" (LSTM), "gated recurrent unit" (GRU), e outros.

Com base nas informações extraídas, foram geradas duas nuvens de palavras para visualização. Uma nuvem de palavras foi utilizada para representar as redes neurais mais frequentemente relacionadas nos artigos, onde o tamanho de cada termo é proporcional à sua frequência. Adicionalmente, uma segunda nuvem de palavras foi criada para as patologias mais citadas nos documentos. A lista de palavras-chave para esta nuvem de patologias foi adaptada de Tambara Junior e Barraza (2021) e inclui termos como: "microstructural", "infiltration", "cracking", "mold", "mildew", "efflorescence", "poor quality", "poor dosage", "poor application", "biotic agents", "abiotic agents", "weathering", "corrosion", "deterioration", "fissures", "fissure", "cracks", "cracking", "fractures".

5. Resultados

5.1. Coleta e seleção dos artigos

Essa etapa foi feita por meio da combinação de palavras-chaves conforme o Quadro 1, resultando na coleta inicial de duzentos e um (201) artigos das bases mencionadas na seção 3.3 Coleta e seleção dos artigos.

Quadro 1: Combinação de palavras

Combinações	Palavra chave	Palavra chave	Palavra chave
124	Redes Neurais	fissuras	Elementos construtivos
134	Redes Neurais	Segmentação de imagens	Elementos construtivos
234	Fissuras	Segmentação de imagens	Elementos construtivos
164	Redes Neurais	Patologias	Elementos construtivos
354	Segmentação de imagens	Patologias	Elementos construtivos
364	Segmentação de imagens	Trincas	Elementos construtivos

Fonte: Dados da pesquisa (2025)

O Quadro 2 mostra os critérios de inclusão e exclusão usados para a seleção final dos artigos para a base de dados.

Quadro 2: Critérios de inclusão e exclusão

Critério	Inclusão	Exclusão
Idioma	Inglês e Português	Outros idiomas
Tipo de publicação	Artigos publicados em anais de congresso ou revista	Resumos, editoriais, livros e similares
Área	Patologias das construções	Áreas fora do escopo
Período de análise	2014-2025	Publicações fora do intervalo
Foco	Redes Neurais e patologias em elementos contrutivos	Outros métodos sem foco da inclusão

Fonte: Fonte: adaptado (Kitchenham e Charters, 2007)

Dessa forma, a base de dados final possui trinta e quatro (34) arquivos. A quantidade de artigos excluídos foi de cento e sessenta e sete (167). Nenhum artigo foi incluso após a exclusão de artigos. Tendo isso, pode-se iniciar a etapa de processamento de dados.

5.2. Processamento de dados e a classificação dos tópicos

Nessa etapa inicialmente, foi realizado o cálculo da similaridade para ranquear os artigos mais relevantes para a pesquisa. Os resultados e os títulos dos artigos são apresentados no Quadro 3 a seguir.

Quadro 3: Ranking dos artigos da base de dados por similaridade

Score Total do cálculo de similaridade	Título
0.5357	<i>Optimization of an artificial neural network for fatigue damage identification using analysis of variance</i>
0.4598	<i>Detecting Cracks in Aerated Concrete Samples Using a Convolutional Neural Network</i>
0.4423	<i>Probabilistic cracking prediction via deep learned electrical tomography</i>
0.3816	<i>An application of a material defect detection system using artificial intelligence</i>
0.3779	<i>Solving the Problem of Determining the Mechanical Properties of Road Structure Materials Using Neural Network Technologies</i>
0.3497	<i>An Enhanced Deep Learning Technique for Crack Identification in Composite Materials</i>
0.3464	<i>Noncontact detection of concrete flaws by neural network classification of laser doppler vibrometer signals</i>
0.3457	<i>Next-Generation Building Condition Assessment: BIM and Neural Network Integration</i>
0.3303	<i>Geometrical digital twins of masonry structures for documentation and structural assessment using machine learning</i>
0.3244	<i>Surrogate modeling for interactive tunnel track design using the cut finite element method</i>
0.3193	<i>Fatigue Life Prediction of Reinforced Concrete Using Artificial Neural Network</i>
0.3063	<i>Diagnosis of internal cracks in concrete using vibro-acoustic modulation and machine learning</i>
0.2998	<i>A particle filter-based model selection algorithm for fatigue damage identification on aeronautical structures</i>
0.2964	<i>Phase-field modeling of fracture with physics-informed deep learning</i>
0.2911	<i>Estimating the primary crack spacing of reinforced concrete structures: Predictions by neural network versus the innovative strain compliance approach</i>
0.2907	<i>Prediction of restraint in second cast sections of concrete culverts using artificial neural networks</i>
0.2868	<i>Hybrid metaheuristic optimization algorithm for prediction of fatigue life performance of fiber-reinforced concrete</i>
0.2742	<i>A Retrospective Analysis of Deep Learning for Tunnel Asset Management: Balancing Efficiency, Ethics, Sustainability, and Security in the MIRET Framework</i>
0.2725	<i>Acoustic emission source location using Lamb wave propagation simulation and artificial neural network for I-shaped steel girder</i>
0.2687	<i>Predicting the sustainability of e-waste mortar for mitigating thermal spalling cracks using ANN and RSM</i>
0.2632	<i>Semi-automatic 3d crack map generation and width evaluation for structural monitoring of reinforced concrete structures</i>

Continuação do Quadro 3

Score Total do cálculo de similaridade	Título
0.2444	Automated image-based generation of finite element models for masonry buildings
0.2423	Semi-automatic 3d crack map generation and width evaluation for structural monitoring of reinforced concrete structures
0.2414	Employing Neural Networks, Fuzzy Logic, and Weibull Analysis for the Evaluation of Recycled Brick Powder in Concrete Compositions
0.2319	Vision-aided three-dimensional damage quantification and finite element model geometric updating for reinforced concrete structures
0.2212	Manifold Reconstruction of Differences: A Model-Based Iterative Statistical Estimation Algorithm With a Data-Driven Prior
0.1846	Predictive analysis of tensile strength ratios in laminated bamboo composites: Unraveling the stochastic impact of ply angle variations through machine learning model
0.1672	Data driven tensile strength prediction for fiber-reinforced rubberized recycled aggregate concrete using machine learning
0.1655	Numerical modeling of time to corrosion induced cover cracking in reinforced concrete using soft-computing based methods
0.1625	Building information modelling in whole life management of reinforced concrete structures
0.1611	Feedback Design of Temperature Control Measures for Concrete Dams based on Real-Time Temperature Monitoring and Construction Process Simulation
0.1571	Study on Adiabatic Temperature Rise Reflecting Hydration Degree of Concrete
0.1457	Prevention and Control of Cracks in Architectural Concrete Structures: A Design-Based Approach to Load Distribution and Structural Strength Improvement
0.1444	Experimental and numerical investigation of reinforced concrete beams containing vertical openings

Fonte: Dados da pesquisa (2025)

Dessa maneira, com o ranqueamento dos artigos, foram selecionados os mais importantes artigos para a pesquisa com similaridade acima de 0.30. Sendo assim, os artigos que foram usados para os resultados a seguir foram: “Next-Generation Building Condition Assessment: BIM and Neural Network Integration”, “Geometrical digital twins of masonry structures for documentation and structural assessment using machine learning”, “Diagnosis of internal cracks in concrete using vibro-acoustic modulation and machine learning”, “An Enhanced Deep Learning Technique for Crack Identification in Composite Materials”, “Manifold Reconstruction of Differences: A Model-Based Iterative Statistical Estimation Algorithm With a Data-Driven Prior”, “Noncontact detection of concrete flaws by neural network classification of laser doppler vibrometer signals”, “A particle filter-based model selection algorithm for fatigue damage identification on aeronautical structures”, “A particle filter-based model selection algorithm for fatigue damage identification on aeronautical structures”, “A particle filter-based model selection algorithm for fatigue damage identification on aeronautical structures”, “Probabilistic cracking prediction via deep learned electrical tomography”, “Solving the Problem of Determining the Mechanical Properties of Road Structure Materials Using Neural Network Technologies”, “An Application of a Material Defect Detection System Using Artificial Intelligence”, “Detecting Cracks in Aerated Concrete Samples Using a Convolutional Neural Network”, “Optimization of an artificial neural network for fatigue damage identification using analysis of variance”.

Com os artigos listados, pode ser realizada a ocorrência dos termos tanto para os tipos de redes neurais quanto para os de patologias da construção. Tendo isso, com relação as redes neurais, a palavra que mais apareceu foi a palavra “*Convolutional neural network*” com vinte e três (23) ocorrências, logo após são as palavras “*Vit*”(Vision Transformer), com cinco (5) citações e “*Gan*”(Generative adversarial network), com uma (1) ocorrências.

Com relação as patologias identificadas, tem-se a Figura 3 da nuvem de palavras.

Figura 3: Nuvem de palavras das patologias da construção.



Fonte: Dados da pesquisa (2025)

A palavra mais citada foi “Cracking” com cinquenta e quatro (54) ocorrências, a segunda é “Cracks” com quarenta (41) e uma ocorrências, a terceira é *Corrosion* com treze (13) ocorrências, na quarta colocação ficaram as três palavras restantes com uma (1) ocorrência: “Deterioration”, “Fissures”, “Fissure”.

5. Discussões

Tendo o objetivo do artigo de realizar uma revisão sistemática da literatura, foi possível identificar as tendências de pesquisa sobre o uso de redes neurais na detecção de patologias em elementos construtivos. Ao analisar a nuvem de palavras das patologias, a recorrência dos termos “*cracking*” (com 54 ocorrências) e “*cracks*” (com 41 ocorrências) é visível. Essa situação reforça a importância do tema discutido no tópico 2.2 “Propagação e permeabilidade de fissuras em materiais” do referencial teórico, que aborda a detecção precoce de fissuras como um fator essencial para evitar falhas catastróficas e garantir a segurança das estruturas.

Com relação a redes neurais, é plausível afirmar que seu uso é recorrente, principalmente para a segmentação de imagens e detecção automática de patologias. Isso é evidenciado na pela ocorrência dos termos, onde se destaca o termo “*convolutional neural network*” (redes neurais convolucionais), com 23 citações. A relevância das redes neurais convolucionais se deve à sua eficácia na análise de imagens, que é, atualmente, uma das principais formas de detecção de patologias como fissuras e trincas. A associação entre redes neurais convolucionais e a detecção de patologias pode ser observada nos artigos com alto grau de similaridade relatados no Quadro 3. Um desses é o artigo “*Detecting Cracks in Aerated Concrete Samples Using a Convolutional Neural Network*”, que já em seu título demonstra a aplicação desse tipo de rede neural para a identificação da patologia fissura.

Além disso, a Figura 3 ainda sugere a aplicação de redes neurais na detecção de outras patologias construtivas como “*corrosion*” (corrosão) e “*deterioration*” (deterioração). O artigo “*Numerical modeling of time to corrosion induced cover cracking in reinforced concrete using soft-computing based methods*” utiliza essa tecnologia para modelar o tempo de corrosão em concreto armado, o que demonstra a capacidade das redes neurais de ir além da simples identificação visual.

6. Conclusão

A respectiva pesquisa teve o objetivo de realizar uma revisão sistemática da literatura para identificar as redes neurais aplicadas na detecção de patologias em elementos construtivos. A análise bibliométrica demonstrou que a área de detecção de patologias em construções tem evoluído através dos anos com a incorporação de novas tecnologias como a inteligência artificial.

Com relação aos achados, tem-se que a arquitetura mais citada para a detecção de patologias em elementos construtivos foi a rede neural convolucional. Essa situação ocorre devido à eficácia desse tipo de rede neural em analisar e segmentar imagens, inclusive para identificar danos visuais como fissuras e trincas. Além disso, a nuvem de palavras das patologias demonstra que os danos mais citados foram termos relacionados a fissuras e trincas, o que ressalta a importância do diagnóstico precoce dessas patologias para a segurança das estruturas.

A metodologia da pesquisa baseou-se na análise de frequência e similaridade de termos, possibilitando indicar tendências de pesquisa e ferramentas utilizadas na área da construção civil. Para estudos futuros, é necessário o aprofundamento da análise da acurácia e eficiência das arquiteturas de redes neurais aplicadas para cada tipo de patologia relatada. A contribuição do presente trabalho é dada pelo panorama fornecido sobre os usos de redes neurais no ramo da patologia das construções e sua importância para o setor, além de direcionar futuras investigações acadêmicas para os aspectos mais relevantes da aplicação dessas ferramentas.

Referencias bibliográficas

ALBAIT, M.; HOSSEINPOUR, M. M. A machine learning model to estimate the ultimate bond strength between FRP and concrete. *Fibers and Polymers*, [s. l.], v. 24, p. 110-120, 2023. DOI: 10.1007/s12221-022-00569-8.

ASHOUR, A.; MENG, C. Machine-learning-based modeling of fatigue behavior of carbon fiber reinforced polymers. **Journal of Composite Materials**, [s. l.], v. 57, p. 289-299, 2023. DOI: 10.1177/00219983221142512.

BOUDJIT, S. et al. Machine learning-based approach for damage detection in composite structures. In: **EUROPEAN CONFERENCE ON COMPOSITE MATERIALS**, 2022. p. 1-10.

BLAGEC, K. et al. Neural sentence embedding models for semantic similarity estimation in the biomedical domain. **BMC Bioinformatics**, v. 20, n. 1, p. 178, 11 dez. 2019.

CHEN; GALLET, Liang and; HUANG, Adrien and; LIU, Shan-Shan and; SMYL, Dong and; DANNY. Probabilistic cracking prediction via deep learned electrical tomography. **Structural Health Monitoring**, 2025.

CHUNG, A. et al. A hybrid machine learning-based framework for rapid prediction of compressive strength and carbonation depth of concrete. **Construction and Building Materials**, [s. l.], v. 370, 2023. DOI: 10.1016/j.conbuildmat.2023.130635.

ENGENHARIA DE PRODUÇÃO, 14., 2024, [Online]. **Anais...** [online]. [S. l.]: APREPRO, 2024. p. 1-17. Disponível em: <https://aprepro.org.br/conbrepro/anais-2024>. Acesso em: 25 ago. 2025.

GIRIBAS, I.; GOMES, J. F. S. Machine learning-based approach for crack detection in concrete structures. In: **INTERNATIONAL CONFERENCE ON CIVIL ENGINEERING**, 2023. p. 1-12.

GOMIDE, T. L. F. et al. (coords.). **Manual de engenharia diagnóstica: desempenho, manifestações patológicas e perícias na construção civil**. 2. ed. rev. e ampl. São Paulo: Leud, 2021.

GÜNEYISI; MERMERDAŞ, Esra Mete and; GÜNEYISI, Kasım and; GESOĞLU, Erhan and; MEHMET. Numerical modeling of time to corrosion induced cover cracking in reinforced concrete using soft-computing based methods. **Materials and Structures/Materiaux et Constructions**, 2024.

HAN; FU, Yanhua and; WANG, Shaojun and; XIE, Shufa and; ZUOWEI. Study on Adiabatic Temperature Rise Reflecting Hydration Degree of Concrete. **Advances in Materials Science and Engineering**, 2025.

HAN, Y. et al. Study on Adiabatic Temperature Rise Reflecting Hydration Degree of Concrete. **Advances in Materials Science and Engineering**, 2025. DOI: 10.1155/2018/1435049.

HOSSEINI, M. A. et al. Next-Generation Building Condition Assessment: BIM and Neural Network Integration. **Journal of Performance of Constructed Facilities**, 2023. DOI: 10.1061/JPCFEV.CFENG-4828.

JEONG, S. et al. A study on crack detection of concrete structures using an unmanned aerial vehicle (UAV) and machine learning. **Journal of the Korea Institute of Structural Maintenance and Inspection**, v. 27, p. 110-117, 2023. DOI: 10.22495/jimm_v16_i2_a4.

JIAN, H. et al. Investigation on the shear behavior of RC beams with artificial intelligence methods. **Applied Sciences**, v. 12, 2022. DOI: 10.3390/app122111005.

JIAN, H. et al. Shear behavior of RC beams with artificial intelligence methods. In: **INTERNATIONAL CONFERENCE ON STRUCTURAL ENGINEERING**, 2022, p. 1-10.

JIANG, Q. et al. Building information modelling in whole life management of reinforced concrete structures. In: INTERNATIONAL CONFERENCE ON STRUCTURAL ENGINEERING, MECHANICS AND COMPUTATION, 7., 2019, [s. l.]. Advances in Engineering Materials, Structures and Systems: Innovations, Mechanics and Applications - **Proceedings of the 7th International Conference on Structural Engineering, Mechanics and Computation**, 2019. Taylor & Francis Group, 2023. p. 2090. DOI: 10.1201/9780429426506-360.

KIM, J. et al. A machine learning-based approach to crack detection in concrete bridges. **Journal of Civil Engineering and Management**, v. 28, p. 745-756, 2022. DOI: 10.3846/jcem.2022.17937.

KOO, H. et al. Performance-based design of concrete structures using machine learning. **Engineering Structures**, v. 275, 2023. DOI: 10.1016/j.engstruct.2022.115264.

KITCHENHAM, B.; CHARTERS, S. M. Guidelines for performing Systematic Literature Reviews in Software Engineering. 2007. Disponível em: <<https://www.researchgate.net/publication/302924724>>.

KUMAR; MANDAL, Deepak and; APURBA. Predictive analysis of tensile strength ratios in laminated bamboo composites: Unraveling the stochastic impact of ply angle variations through machine learning model. **Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science**, 2024.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep Learning. **Nature**, London, v. 521, p. 436-444, 2015. DOI: 10.1038/nature14539.

LOVERDOS; SARHOSIS, Dimitrios and; VASILIS. Geometrical digital twins of masonry structures for documentation and structural assessment using machine learning. **Engineering Structures**, 2025.

LUNA, J. et al. Machine learning for the prediction of concrete compressive strength. **Journal of Building Engineering**, v. 66, 2023. DOI: 10.1016/j.jobbe.2022.105436.

MAZZOCHIN, J. V. C. et al. Explorando Temas e Tendências na Pesquisa de Transporte de Frangos de Corte: Uma Abordagem com Modelagem de Tópicos e Mineração de Textos. In: CONGRESSO BRASILEIRO DE PRODUÇÃO, 14., 2024, [Online]. Anais... [Online]. [S. l.]: APREPRO, 2024. p. 1-17.

MERKLE; SOLASS, Dominik and; SCHMITT, Johannes and; ROSIN, Annette and; REITERER, Julia and; STOLZ, Alexander and; ALEXANDER. SEMI-AUTOMATIC 3D CRACK MAP GENERATION AND WIDTH EVALUATION FOR STRUCTURAL MONITORING OF REINFORCED CONCRETE STRUCTURES. **Journal of Information Technology in Construction**, 2024.

MIELE; KARVE, Sarah and; MAHADEVAN, Pranav M and; AGARWAL, Sankaran and; VIVEK. Diagnosis of internal cracks in concrete using vibro-acoustic modulation and machine learning. **Structural Health Monitoring**, 2024.

MING, X. et al. A review of machine learning applications in structural health monitoring of bridges. **Journal of Structural Engineering**, v. 149, 2023. DOI: 10.1061/(ASCE)ST.1943-541X.0003504.

NAJAH, K. et al. Prediction of concrete compressive strength using machine learning techniques. **Journal of Building Engineering**, v. 65, 2023. DOI: 10.1016/j.jobbe.2022.105437.

PAROL; BEN-NAKHI, Jafarali and; AL-SANAD, Ammar and; AL-QAZWEENI, Shaikha and; AL-DUALI, Jamal and; KAMAL, Hamad J. and; HASAN. Experimental and numerical investigation of reinforced concrete beams containing vertical openings. *Structural Engineering and Mechanics*, 2024.

R. S.; CANUTO, S. D. C. Avaliação da presença de fissuras em imagens de estruturas de concreto através do uso de redes neurais profundas. **Revista Matéria**, v. 29, n. 4, 2024. DOI: 10.1590/1517-7076-RMAT-2024-0354.

RAMANAUSKAS; KAKLAUSKAS, Regimantas and; SOKOLOV, Gintaris and; ALEKSANDR. Estimating the primary crack spacing of reinforced concrete structures: Predictions by neural network versus the innovative strain compliance approach. **Mechanics of Advanced Materials and Structures**, 2025.

RYNDIN, Eugeny A.; KONOPLEV, Boris G.; KULIKOVA, Irina V. Distributed Sensory System of Surface Cracks Monitoring Based on Electrical Impedance Tomography. **Electronics**, v. 7, n. 8, p. 131-146, 2018. DOI: 10.3390/electronics7080131.

SBARUFATTI; CLAUDIO. Optimization of an artificial neural network for fatigue damage identification using analysis of variance. **Structural Control and Health Monitoring**, 2024.

SHARMA, Ajay; CHANDRA, Harish. Constructive Neural Networks: A Review. **Journal of Artificial Intelligence and Soft Computing Research**, v. 1, n. 1, p. 37-46, 2010. DOI: 10.2478/v10229-011-0004-3.

SUN, Z. et al. Prediction of concrete compressive strength using machine learning and meta-heuristic algorithms. **Construction and Building Materials**, v. 370, 2023. DOI: 10.1016/j.conbuildmat.2023.130638.

WRÓBEL, A.; SZYMCZYK, P. AN APPLICATION OF A MATERIAL DEFECT DETECTION SYSTEM USING ARTIFICIAL INTELLIGENCE. **International Journal of Modern Manufacturing Technologies**, [s. l.], 2023. DOI: 10.54684/ijmmt.2023.15.3.221.

WU, Long; GAO, Hao; WANG, Kun-Chieh; YANG, Chi-Hsin. A Green-IKE Inference System Based on Grey Neural Network Model for Humanized Sustainable Feeling Assessment about Products. **Mathematical Problems in Engineering**, v. 2020, p. 1-9, 2020. DOI: 10.1155/2020/6391463.

WU, X. et al. Prediction of concrete compressive strength using a hybrid machine learning model. **Materials**, v. 16, 2023. DOI: 10.3390/ma16062402.

WRÓBEL, A.; SZYMCZYK, P. AN APPLICATION OF A MATERIAL DEFECT DETECTION SYSTEM USING ARTIFICIAL INTELLIGENCE. **International Journal of Modern Manufacturing Technologies**, v. 15, p. 221-229, 2023. DOI: 10.54684/ijmmt.2023.15.3.221.

YANG, J.; ZHANG, Y. An improved method for concrete crack detection based on a deep learning model. **Sensors**, v. 23, 2023. DOI: 10.3390/s23052601.

ZHANG, Y. et al. Predictive models for concrete compressive strength using machine learning: A review. **Journal of Building Engineering**, v. 66, 2023. DOI: 10.1016/j.jobbe.2022.105438.

ZHAO, Y.; ZHANG, Y. Crack detection in concrete structures using a deep learning model based on the YOLO algorithm. **Sensors**, v. 23, 2023. DOI: 10.3390/s23052602.

ZHOU, Q. et al. Machine learning for the prediction of mechanical properties of concrete. **Construction and Building Materials**, v. 370, 2023. DOI: 10.1016/j.conbuildmat.2023.130639.