

XIX Encontro Nacional de Tecnologia do
Ambiente Construído
ENTAC 2022

Ambiente Construído: Resiliente e Sustentável
Canela, Brasil, 9 a 11 novembro de 2022

Análise do uso de tecnologias digitais para identificação automatizada de patologias em construções

Analysis of digital technologies use for automated
identification of pathologies in construction

Alisson de Souza da Silva

Universidade Federal da Bahia | Salvador | Brasil | alissonss@ufba.com.br

Dayana Bastos Costa

Universidade Federal da Bahia | Salvador | Brasil | dayanabcosta@ufba.com.br

Resumo

Este estudo visa identificar as principais tecnologias digitais em uso para inspeções automatizadas de patologias em elementos de construção e como as informações obtidas podem apoiar na tomada de decisão gerencial nas obras. O método de pesquisa proposto foi a revisão sistemática da literatura. Foram analisados 26 artigos nas bases da Scopus, Web of Science e IEEE Xplore. Como resultados, observou-se a oportunidade de pesquisas para aperfeiçoamento e robustez nos algoritmos de inteligência artificial, bem como a necessidade de incorporação dessas informações durante a etapa de execução, apoiando a tomada de decisão no processo de controle da qualidade.

Palavras-chave: Inspeção automatizada. Tecnologias digitais. Drone. Inteligência Artificial (IA). Revisão Sistemática da Literatura (RSL).

Abstract

This study aims to identify the leading digital technologies used for automated inspection of pathologies in construction elements and how the information obtained can support managerial decision-making. The proposed research method was a systematic literature review. Twenty-six articles were analyzed in the Scopus, Web of Science, and IEEE Xplore databases. As a result, there was an opportunity for research for improvement and robustness in artificial intelligence algorithms and the need to incorporate this information during the execution stage, supporting decision-making in the quality control process.

Keywords: Automated inspection. Digital technologies. Drone. Artificial Intelligence (AI). Systematic Literature Review (SLR).



SILVA, A. S.; COSTA, D. B. Análise do uso de tecnologias digitais para identificação automatizada de patologias em construções. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 19., 2022. Anais [...]. Porto Alegre: ANTAC, 2022. Disponível em: <https://eventos.antac.org.br/index.php/entac/article/view/2162>

INTRODUÇÃO

O aumento da degradação dos elementos da construção civil pode ocorrer a partir do processo natural de envelhecimento dos materiais, de sua exposição aos agentes ambientais ou de acordo com o tempo e uso [1]. A avaliação geral desses elementos é um instrumento fundamental para que os gestores avaliem a integridade estrutural e a operabilidade, podendo assim, estimar as possíveis necessidades de manutenção ou reabilitação. Geralmente, a avaliação dessas condições é realizada com base em informações obtidas através de inspeções visuais ou manuais [2].

No entanto, essas atividades exigem a presença de inspetores experientes para avaliar diretamente a condição estrutural [3][4]. Além disso, essa técnica tradicional é considerada cara, demorada, trabalhosa e pode colocar em risco a segurança dos profissionais, principalmente em locais de difícil acesso [5][6][7][8][9].

As imagens digitais associadas as técnicas de processamento de dados têm melhorado as estratégias de inspeção, fornecendo uma avaliação automatizada das condições dos elementos construtivos [7]. Além disso, o uso de tecnologias avançadas, como drones e visão computacional, podem auxiliar os profissionais na tomada de decisão, automatizando essa atividade, tornando-a ágil, segura, confiável e eficaz [10].

Diante disso, existe a necessidade de mapear o avanço do conhecimento na área de processamento de imagens para reconhecimento automático de patologias de construções visando o desenvolvimento de futuras pesquisas. Dessa forma, este estudo visa identificar as principais tecnologias digitais em uso para inspeções automatizadas de patologias em elementos de construção e como as informações obtidas através dessa atividade podem apoiar na tomada de decisão gerencial nas obras.

INTELIGENCIA ARTIFICIAL E VISÃO COMPUTACIONAL

A Inteligência Artificial (IA) é um conceito amplo cujo objetivo é o desenvolvimento de sistemas que exibem características que estão associadas à inteligência no comportamento humano [11]. Ela pode resolver problemas que são considerados de extrema complexidade para os seres humanos, porém de forma trivial para os computadores ou máquinas [12].

A IA pode ser compreendida em camadas ou em partes que a compõe (Figura 1), introduzindo dessa forma os conceitos de Aprendizado de Máquina (*Machine Learning-ML*) e Aprendizado Profundo (*Deep Learning-DL*). O ML é o processo de aprendizado contínuo de máquina, consistindo em fornecer dados de entrada visando o aprendizado da máquina com esses dados e elaboração de saídas que satisfaçam a situação problema [13].

Por outro lado, o DL é constituído por diversos subconjuntos ou arquiteturas, como as Redes Neurais Convolucionais, que abordam o desafio de construir representações complexas, a partir de representações mais simples e tendo várias camadas de abstração. O algoritmo em aprendizado profundo permite que modelos que

consistem em várias camadas de processamento operem e aprendam representações de dados usando vários níveis de abstração [14].

Figura 1 – Subconjuntos de IA



Fonte: Adaptado de Mondal (2020).

Outro campo que trabalha em conjunto com a IA é a visão computacional, que pode ser definida como a área de estudo que busca reproduzir a visão humana quanto a capacidade de extrair das imagens suas características, permitindo interpretar e descrever essas imagens e os elementos nelas presentes [15][16]. Segundo Szeliski (2010) [15], essa área é composta por subáreas como processamento, segmentação, detecção e reconhecimento ou classificação, em que cada uma delas possui um conjunto de técnicas utilizadas por sistemas cuja entrada seja uma imagem, um conjunto de imagens ou vídeo.

O processamento de imagem é responsável por “melhorar” a imagem, isto é, retirar ruídos, realçar bordas e suavizar a imagem. A segmentação é responsável por particionar a imagem em regiões de interesse, ou seja, caracteriza-se por agrupar os pixels que possuem características semelhantes, criando diversos segmentos deles [16]. Os algoritmos de detecção são bastante utilizados para localizar e delimitar o elemento foco de análise, para então, realizar as operações desejadas sobre o ponto ou área detectada [15]. O reconhecimento de padrões é responsável por classificar ou agrupar as imagens com base em seus conjuntos de características [16].

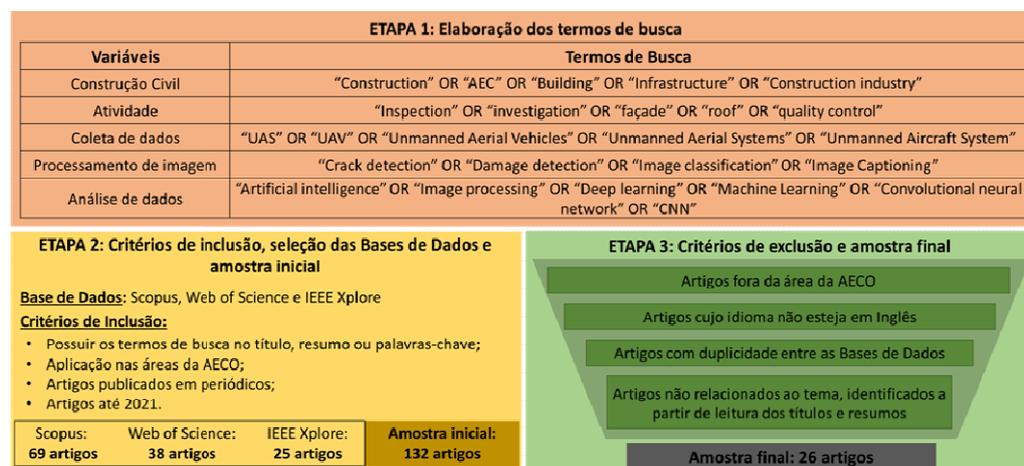
METODOLOGIA

Este estudo apresenta uma Revisão Sistemática da Literatura (RSL) caracterizada pela formulação e revisão de uma pergunta utilizando métodos sistemáticos para selecionar, identificar e analisar pesquisas sobre determinado assunto [17][18][19]. Sendo assim, este estudo busca responder as seguintes questões de pesquisa: (1) “Quais tecnologias digitais estão sendo utilizadas para a identificação automatizada de patologias em construções?”; (2) “Como essas tecnologias auxiliam os gestores na tomada de decisão?”; e (3) “Quais as tendências futuras para uso dessas tecnologias?”.

Conforme Figura 2, na etapa 1, foram elaborados os termos de busca, após isso, foram estabelecidos critérios de inclusão e exclusão para análise dos artigos. Os critérios de inclusão foram: (1) possuir os termos de busca no título, resumo ou palavras-chave; (2) aplicações na área da Arquitetura, Engenharia, Construção e Operação-AECO; e (3) publicações em periódicos. Os critérios de exclusão foram: (1) artigos fora da área da AECO; (2) artigos fora do idioma inglês; (3) artigos com

duplicidade entre as bases de dados; e (4) publicações não relacionadas ao tema após a leitura dos títulos e resumos. A amostra final é composta por 26 artigos.

Figura 2: Etapas da RSL

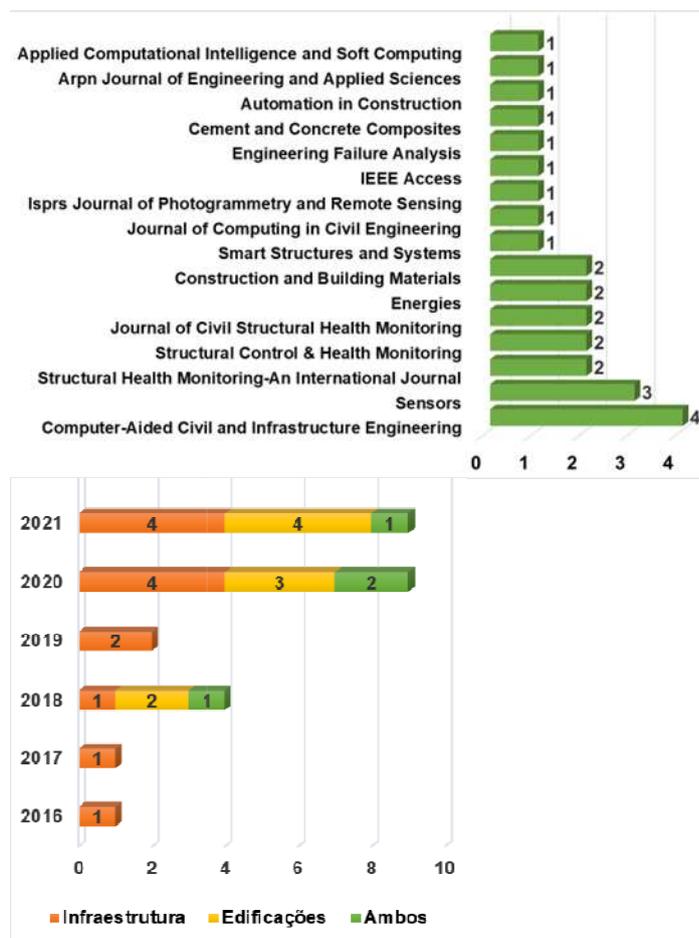


Fonte: o autor.

RESULTADOS

Os 26 artigos selecionados na amostra estão distribuídos em 16 periódicos (Figura 3a). O periódico com maior número de publicações é o *Computer-Aided Civil and Infrastructure Engineering*, com quatro publicações. O número de publicações variou entre 2016 e 2021 (Figura 3b), em que o maior número de publicações da amostra foi nos anos de 2020 e 2021, com nove publicações. Os artigos também foram agrupados de acordo com tipos de construções em que os estudos foram realizados. Treze publicações (50% da amostra) realizaram estudos em construções de infraestrutura como pontes, estradas e estruturas de aço e concreto; nove publicações (34,6%) usaram as tecnologias digitais em elementos de edificações como paredes, telhados e fachada e, por fim, quatro publicações (15,4%) foram consideradas como “ambos”, por utilizar as duas tipologias nos estudos.

Figura 3: Distribuição das publicações: (a) por periódicos; e (b) por ano e tipo de construção



Fonte: o autor.

As tecnologias utilizadas para identificação automatizada de patologias na construção são apresentadas nas seções a seguir. Inicialmente é apresentado o Quadro 1 contendo a relação entre as tecnologias utilizadas para aquisição de dados e as tipologias estudadas. Em seguida é apresentado o Quadro 2, contendo as tecnologias utilizadas para processamento de dados, bem como as técnicas e métodos utilizados, e, por fim, são apresentadas as tendências para novas pesquisas.

TECNOLOGIAS DIGITAIS UTILIZADAS PARA AQUISIÇÃO DE DADOS

O Quadro 1 apresenta a relação entre as tecnologias utilizadas para aquisição de dados, as diferentes tipologias em que os estudos foram aplicados e os referidos estudos encontrados na RSL.

Quadro 1- Tecnologias utilizadas para aquisição de dados

Tecnologias utilizadas para aquisição de dados	Tipologias construtivas analisadas	Autores/Trabalhos
Drones com câmera acoplada	Pontes	[3], [20], [10], [4], [21]
	Paredes e fachadas	[22], [1], [23]
	Estruturas de concreto, aço ou de concreto armado	[24], [25], [26], [27]
	Estradas, ferrovias e túneis	[28], [29]
Câmera manual	Estrutura de concreto	[7]
	Fachadas	[2]
Dados da Literatura	Estrutura de concreto	[30], [31], [32]
	Fachadas	[33]
Integração entre drones, câmeras, lasers, imagens de satélite e outras tecnologias	Pontes	[34]
	Telhados e fachada	[35], [36], [11]
	Estruturas de concreto, aço ou de concreto armado	[12], [37]

Fonte: o autor.

A amostra apresenta que as principais tecnologias digitais para aquisição de dados foram drones com câmeras acopladas (Figura 4). A maioria deles eram drones comerciais da Da-Jiang Innovations-DJI como o DJI Phantom com GoPro Hero 3 acoplada [38], o DJI F550 [3], o DJI Matrice 100 [39], o DJI Matrice 600 Pro [7][34], o DJI Quadricóptero F450 [27], o DJI Ryze Tello [37], entre outros modelos [1][26][4]. Além disso, foram propostos modelos próprios, como drones de escalada [40][6].

Figura 4: Exemplos dos drones utilizados.



Fonte: Adaptado de: a) Kang e Cha (2018); b) Jiang e Zhang (2019); c) Ayele et al. (2020); d) Oh et al. (2021);

Além da integração entre câmera e drone para coleta de dados, alguns autores utilizaram imagens coletadas por drones, fotografias terrestres e varreduras a laser [30]. Assim como esses autores, [41] e [37] utilizaram imagens georreferenciadas de satélites e nuvens de pontos a partir de voos de drones equipados com aparelhos *Light Detection and Ranging*-LiDAR. Os autores [20] utilizaram câmeras manuais de alta resolução para obter imagens com informações de profundidade e RGB.

Alguns autores utilizaram imagens de bancos de dados da literatura, disponibilizados na internet, devido à praticidade, quantidade e qualidade das imagens disponíveis para treinamento, visto que esses são fatores cruciais para a eficiência durante o treinamento e processamento digital [42][43][1][21].

TECNOLOGIAS DIGITAIS USADAS PARA PROCESSAMENTO DE DADOS

O Quadro 2 apresenta as técnicas de visão computacional e os métodos de IA utilizado nos estudos.

Quadro 2 – Aplicação de visão computacional e subconjuntos de IA

Técnica utilizada	Autores/Trabalhos	Método utilizado
Classificação	[41]; [36]; [1]; [42]; [20]; [23]	Resnet50, Inceptionv3 e Inception-ResNet; Generative Adversarial Network-GAN; DL; Algoritmo de fusão de sensores; PADENet
Detecção	[30]; [3]; [31]; [44]; [43]; [40]; [29]; [7]; [4]; [27]; [37]; [34]; [25]; [35]	Algoritmo ISODATA; DCNN; CNN; AlexNet; Faster RCNN; CNN; DEEP; MATLAB; VGG-16; Sobel, Laplacian e Canny; HCNNFP; VGG-16; RBGNet LWLC + ME
Segmentação	[38]; [6]; [39]; [22]	Algoritmo K-means; MaDnet; Mask R-CNN; U-Net

Fonte: o autor.

TÉCNICAS DE CLASSIFICAÇÃO

Os autores [41] propuseram um método de classificação de telhados utilizando modelos baseados em CNN. Foram escolhidas as arquiteturas Resnet50, Inceptionv3 e Inception-ResNet. O Resnet foi o modelo que apresentou melhor desempenho para entrada de dados com uso do LiDAR, alcançando 83,3% de precisão, superando o Inceptionv3 que obteve 88,1%. A diferença de precisão é estatisticamente insignificante, porém a diferença na complexidade em termos de memória e computação é significativa.

O estudo de [36] utilizou a arquitetura AlexNet para localizar e classificar regiões de interesse em estruturas de aço e concreto, permitindo uma avaliação estrutural automatizada. O modelo alcançou 94,13% de precisão. Já os autores [42] propuseram um modelo CNN para classificar os tipos de fissuras em pontes de concreto. O modelo alcançou alto desempenho na tarefa de multi classificação, excedendo 97% de precisão.

No estudo de [1] foi proposto um modelo baseado em DL para classificar e restaurar borrões de imagens embaraçadas. Para isso, foi utilizado arquiteturas Generative Adversarial Network-GAN, apresentando resultados significativamente eficientes ao restaurar características detalhadas de imagens com fissura, eliminando efeitos de desfocagem. Os autores [20] propuseram uma estratégia de identificação de fissuras combinando câmeras digitais RGB-D e câmeras de alta resolução para medir as rachaduras a partir de algoritmos de fusão de sensores. Nessa abordagem, as rachaduras em superfícies de concreto foram identificadas com alta precisão, independentemente do ângulo de visão.

O método de [23] propôs a classificação de quatro tipos de corrosão em superfícies metálicas. Foi realizado uma comparação entre o desempenho do algoritmo PADENet e dos métodos Faster R-CNN, YOLO e SSD. O estudo demonstrou que o PADENet apresentou maior desempenho na classificação de corrosão da barra,

corrosão do fixador, corrosão saliente e esfoliação, apresentando precisão de 80,78%, 92,41%, 87,81% e 88,36%, respectivamente.

TÉCNICAS DE DETECÇÃO

No método proposto por [30], o processamento das imagens consistiu na detecção e quantificação de fissuras através da aplicação do algoritmo ISODATA. Comparado aos métodos tradicionais, o processamento automático das informações resultou em maior velocidade, eficiência e confiabilidade, além da quantidade e qualidade dos dados. [3] utilizou uma Deep Convolutional Neural Network- DCNN para detectar danos estruturais. Esse método foi validado com alta precisão na identificação de fissuras em concreto, apresentando valores satisfatórios de precisão (96,6%), sensibilidade (91,9%) e especificidade (97,9%).

O estudo de [31] utilizou uma estrutura para detectar regiões danificadas por terremotos, através de imagens de telhados. Foram treinados modelos supervisionados com base em recursos da CNN, combinando recursos de nuvem de pontos 3D. Essa integração produziu uma melhoria extra em termos de precisão, aumentando de 91% para 94%.

O estudo de [44] comparou os algoritmos de bordas comum Roberts, Prewitt, Sobel, LoG, Butterworth e Gaussian com o modelo AlexNet (DCNN) para detecção de fissuras em estruturas de concreto. O melhor modelo de algoritmos foi o LoG, apresentando 79% de precisão na detecção de fissuras mais grossas que 0,1mm. Já o método DCNN apresentou 86% de precisão, além de detectar fissuras mais com até 0,004mm. Já os autores [27] comparam o desempenho dos algoritmos Sobel, Laplacian e Canny na detecção de contorno para encontrar qual a melhor solução. O algoritmo Canny apresentou maior desempenho, além de baixa sobrecarga computacional.

O estudo de [43] utilizou redes Faster RCNN com a técnica de detecção para identificar danos em edifícios de concreto armado. Foram utilizadas as arquiteturas Inception v2, ResNet-50, ResNet-101 e Inception-ResNet-V2. Os autores consideraram como danos trincas, fragmentação, fragmentação com vergalhões expostos e vergalhões severamente flambados. Após a análise comparativa entre as quatro arquiteturas, a Inception-ResNet-v2 superou as demais redes, atingindo 60,8% de mAP, indicador este que avalia o desempenho geral do detector de objetos.

O estudo de [29] propôs um método de inspeção automatizada de ponte comparando com inspeções tradicionais, utilizando o software DEEP para identificar e quantificar defeitos superficiais como ausência de tinta, eflorescência e vegetação em elementos estruturais. A proposta foi validada através da comparação entre os dois métodos, evidenciando uma redução significativa de tempo humano para análise de imagens. Semelhante a esse estudo, o método proposto por [7] utilizou algoritmos de MATLAB para identificação de colônias biológicas, vergalhões de aço expostos e eflorescências. A utilização dessa metodologia demonstrou robustez e eficiência, além de evidenciar a ausência de na estrutura de concreto armado.

O estudo de [4] propôs um modelo de CNN para detecção automatizada de patologias como eflorescência, fragmentação, fissuras e desfiguração. Utilizando um classificador VGG-16 pré-treinado, esse modelo mapeou a ativação de classe para localização de objetos. Os resultados indicaram que o modelo teve alta acurácia e recall, com taxas respectivas de 91% e 80% para eflorescência, 76% e 100% para fragmentação, 86% e 86% para trincas e 98% e 78% para desfiguração.

Utilizando redes de CNN, o estudo de [37] mostrou que, em relação a profundidade da fissura, mancha de ferrugem e a patologias de eflorescência, o algoritmo Random Forests apresentou valores com aproximadamente 70% de precisão para cada patologia detectada. Referente a patologia de reforço, os algoritmos Decision Trees e Random Forests apresentaram valores de aproximadamente 50% de precisão.

Os autores [34] propuseram uma abordagem de DL usando Hierarchical Convolutional Neural Networks with Feature Preservation- HCNNFP para obter um mapa de probabilidade de defeitos superficiais. Como resultado, a estrutura desenvolvida detectou com sucesso rachaduras na superfície de cinco conjuntos de dados diferentes para estradas, pavimentos e pontes sujeitos a vários níveis de textura.

No estudo de [25] foi proposto um framework para detectar trincas em estruturas de concreto. A arquitetura VGG-16 foi usada para detectar eventuais rachaduras na imagem que foi dividida em várias seções para rotular rachaduras em várias regiões da imagem. Mesmo os autores não apresentando os valores de precisão do modelo, eles concluíram que o modelo forneceu resultados precisos para detecção de trincas. Os autores [40] também propuseram um método de detecção de fissuras em tempo real utilizando dispositivos móveis e CNNs. A validação do método proposto foi realizada através de uma inspeção real de fissuras em uma edificação, em que o resultado alcançou 94,48% de precisão na detecção de fissuras.

O sistema proposto por [35] integrou o RBGNet para segmentação de imagens e um modelo baseado em LWLC+ME para detecção de defeitos em trilhos ferroviários. Os autores concluíram que o modelo RBG-Net LWLC + ME foi capaz de detectar defeitos de forma eficiente, no entanto apresentou uma velocidade de processamento razoável.

Os autores [21] desenvolveram um modelo de DL para a classificação de imagens com e sem fissuras, capturadas em superfícies de concreto. O modelo obteve excelente desempenho de classificação para o conjunto de dados de treinamento, nos quais a precisão, recall, especificidade, F1-score e acurácia alcançaram 99,5%, 99,8%, 99,5%, 99,7% e 99,7%, respectivamente; enquanto para o conjunto de dados de teste, a precisão, recall, especificidade, F1-score e acurácia foram 96,5%, 98,8%, 96,6%, 97,7% e 97,7%, respectivamente.

TÉCNICAS DE SEGMENTAÇÃO

No estudo de [38], o processamento das imagens foi realizado através do algoritmo K-means. Utilizando a técnica de segmentação, os algoritmos extraíram características das imagens, como ruídos e sombras, localizando fissuras em

estruturas de pontes. Apesar do método ter identificado as fissuras corretamente, outros recursos na imagem também foram identificados como fissuras.

Os autores [6] treinaram o modelo Multi-task Network, também conhecido como MaDnet, para identificar simultaneamente o tipo de material inspecionado e os problemas identificados. Nessa abordagem, a técnica de segmentação é empregada onde a interdependência entre o material e o dano foi incorporada por meio de filtros compartilhados aprendidos através de otimização multi objeto. Os resultados mostraram que o MaDnet apresentou uma precisão média de 91,7% e uma redução de 58,3% no tempo computacional para processamento.

Os autores [39] propuseram um modelo para melhorar a precisão na identificação de defeitos em estruturas de pontes utilizando algoritmos de CNN para a segmentação automática de fissuras. A arquitetura Mask R-CNN foi utilizado na segmentação das imagens e alcançou 90% de precisão na distinção de ameaças e anomalias presentes nas estruturas analisadas.

No estudo de [22] foi feito o treinamento de uma arquitetura de segmentação de imagens de uma CNN chamada U-Net, utilizando um número bem pequeno de imagens. O artigo valida experimentalmente a eficácia e robustez da estrutura proposta, uma vez que rastreia a propagação de trincas em sua superfície, detectando com sucesso múltiplas trincas em uma viga de concreto.

OPORTUNIDADE DE PESQUISAS FUTURAS

Acompanhando as tendências da aplicação dos métodos de visão computacional e inteligência artificial, visualiza-se que os algoritmos de aprendizado profundo substituirão os métodos convencionais de detecção de fissuras e outros problemas na construção civil [33]. Embora a aplicação desses métodos venha crescendo cada vez mais, ainda há a necessidade de melhorar em alguns aspectos. Portanto, o desafio de pesquisas a serem consideradas para trabalhos futuros, com base nos estudos dessa RSL, são descritos como:

- 1) Algoritmos de segmentação: embora alguns métodos de detecção de fissuras apresentaram alto desempenho, os algoritmos de segmentação de imagem podem ser usados para extrair características específicas, medindo o tamanho e direção das fissuras, determinando assim, a gravidade do problema e fornecendo informações essenciais para manutenção.
- 2) Base de dados: o desempenho dos algoritmos baseados em ML depende muito das características e da quantidade dos dados coletados para treinamento. Futuras pesquisas para reduzir a necessidade de grandes quantidades de dados de entrada podem reduzir o esforço humano nessa rotulagem, tornando o processo de treinamento mais célere.
- 3) Capacidade de equipamentos: estudos que explorem novos equipamentos de ponta como câmeras de alta resolução, drones com maior autonomia de voo e computadores com processadores mais robustos podem aumentar a eficiência na identificação automática de patologias. Além disso, pacotes de

softwares personalizados com baixo custo, baixa complexidade computacional, baixo consumo de RAM e alta precisão podem melhorar os resultados de desempenho do processamento digital.

- 4) Aplicações em tipologias diferentes: as sistemáticas utilizadas para tipologias específicas, como ponte, pavimento ou fachada, podem ser testadas em outras estruturas, avaliando o desempenho dessa aplicação.
- 5) Detecção em tempo real: métodos de detecção de patologias em elementos da construção a partir do processamento digital apresentaram métricas satisfatórias, como precisão, recall e acurácia. No entanto, pesquisas que façam a detecção de patologias em tempo real podem apresentar grande avanço nessa área.
- 6) Integração de tecnologias: assim como foi realizado em muitos estudos, a integração de várias tecnologias para coleta e processamento de dados pode ampliar a área de estudos e melhorar a identificação de patologias.
- 7) Incorporação de informações: a automatização do processo de inspeção traz inúmeras vantagens quando comparadas a forma tradicional. No entanto, estudos que incorporem as informações obtidas através dessa atividade principalmente na etapa de execução, apoiando a tomada de decisão no sistema de gestão da qualidade, são fundamentais.

CONSIDERAÇÕES FINAIS

Este artigo apresentou uma revisão sistemática da literatura para identificar tendências e capacidades das tecnologias de coleta e processamento de dados digitais utilizadas para a identificação automatizada de patologias em construções. Entretanto, a presente investigação aponta como limitação que estudos importantes possam ter ficado de fora da amostra.

Os resultados mostraram que os drones com câmeras acopladas foram as tecnologias digitais mais utilizadas para aquisição de dados devido à rapidez e segurança desse processo. Subconjuntos de ML, principalmente as CNN e seus subconjuntos, foram as tecnologias digitais mais utilizadas para processamento de dados por apresentarem alto desempenho, exatidão, apresentando resultados de precisão acima de 90% nos estudos analisados.

Ao analisar os artigos, observou-se a oportunidade para pesquisas nas áreas tecnológica e gerencial. Pesquisas para melhorar a robustez dos algoritmos de processamento que busquem além de identificar problemas, mas classificar, diferenciar ou extrair características que possam auxiliar os tomadores de decisão. Além disso, a RSL mostrou que todos os estudos foram realizados em edificações durante a fase de uso e ocupação, surgindo oportunidades para pesquisas durante a fase de execução, uma vez que muitas patologias surgem durante essa etapa.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado da Bahia (FAPESB) e à Empresa Parceira pelo apoio financeiro ao projeto.

REFERÊNCIAS

- [1] LIU, Y.; YEOH, J. K.; CHUA, D. K. Deep learning–based enhancement of motion blurred UAV concrete crack images. **Journal of Computing in Civil Engineering**, v. 34, n. 5, p. 04020028, 2020.
- [2] STOCHINO, F.; FADDA, M. L.; MISTRETTA, F. Low cost condition assessment method for existing RC bridges. **Engineering Failure Analysis**, v. 86, p. 56-71, 2018.
- [3] KANG, D.; CHA, Y. J. Autonomous UAVs for structural health monitoring using deep learning and an ultrasonic beacon system with geo-tagging. **Computer-Aided Civil and Infrastructure Engineering**, v. 33, n.10, p. 885-902, 2018.
- [4] KUNG, R. Y.; PAN, N. H.; WANG, C. C.; LEE, P. C. Application of Deep Learning and Unmanned Aerial Vehicle on Building Maintenance. **Advances in Civil Engineering**, v. 2021, 2021.
- [5] HOANG, N. D. Image Processing-Based Recognition of Wall Defects Using Machine Learning Approaches and Steerable Filters. **Computational Intelligence and Neuroscience**, v. 2018, 2018.
- [6] HOSKERE, V.; NARAZAKI, Y.; HOANG, T. A.; SPENCER JR, B. F. MaDnet: multi-task semantic segmentation of multiple types of structural materials and damage in images of civil infrastructure. **Journal of Civil Structural Health Monitoring**, v. 10, n.5, p. 757-773, 2020.
- [7] RIBEIRO, D.; SANTOS, R.; SHIBASAKI, A.; MONTENEGRO, P.; CARVALHO, H.; CALÇADA, R. Remote inspection of RC structures using unmanned aerial vehicles and heuristic image processing. **Engineering Failure Analysis**, v. 117, p. 104813, 2020.
- [8] DAIS, D.; BAL, I. E.; SMYROU, E.; SARHOSIS, V. Automatic crack classification and segmentation on masonry surfaces using convolutional neural networks and transfer learning. **Automation in Construction**, v. 125, p. 103606, 2021.
- [9] GUO, J.; WANG, Q.; LI, Y. Evaluation-oriented façade defects detection using rule-based deep learning method. **Automation in Construction**, v. 131, p. 103910, 2021.
- [10] KUMARAPU, K.; SHASHI, M.; KEESARA, V. R. UAV in Construction Site Monitoring and Concrete Strength Estimation. **Journal of the Indian Society of Remote Sensing**, v. 49, n. 3, p. 619-627, 2021.
- [11] MÜLLER, A. C.; GUIDO, S. Introduction to machine learning with Python: a guide for data scientists. " **O'Reilly Media, Inc.**", 2016.
- [12] ROCHA, R. L. Redes neurais convolucionais aplicadas à inspeção de componentes do vagão ferroviário. **Dissertação** (Mestrado em Computação Aplicada do Núcleo de Desenvolvimento Amazônico em Engenharia) - Universidade Federal do Pará, Tucuruí-Pará, 2020.
- [13] DAMACENO, S. S. Inteligência artificial: uma breve abordagem sobre seu conceito real e o conhecimento popular. **Caderno de Graduação-Ciências Exatas e Tecnológicas-UNIT-SERGIPE**, v. 5, n. 1, p. 11-11, 2018.
- [14] ILIN, R.; WATSON, T.; KOZMA, R. Abstraction hierarchy in deep learning neural networks. **International Joint Conference on Neural Networks (IJCNN)**, p. 768-774, 2017.
- [15] SZELISKI, R. Computer vision: algorithms and applications. **Springer Science & Business Media**, 2010.

- [16] BACKES, A. R.; JUNIOR, J. J. D. M. S. Introdução à visão computacional usando Matlab. **Alta Books Editora**, 2019.
- [17] KITCHENHAM, B. Procedures for performing systematic reviews. **Keele, UK, Keele University**, v. 33, p. 1-26, 2004.
- [18] MOHER, D.; LIBERATI, A.; TETZLAFF, J.; ALTMAN, D. G.; PRISMA GROUP. Reprint—preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *Physical therapy*, v. 89, n. 9, p. 873-880, 2009.
- [19] DRESCH, A.; LACERDA, D. P.; JÚNIOR, J. A. V. A. Design Science Research: método de pesquisa para avanço da ciência e tecnologia. **Bookman Editora**, 2015.
- [20] KIM, H.; LEE, S.; AHN, E.; SHIN, M.; SIM, S. H. Crack identification method for concrete structures considering angle of view using RGB-D camera-based sensor fusion. **Structural Health Monitoring**, v. 20, n.2, p. 500-512, 2021.
- [21] LE, T. T.; NGUYEN, V. H.; LE, M. V. Development of deep learning model for the recognition of cracks on concrete surfaces. **Applied Computational Intelligence and Soft Computing**, v. 2021, 2021.
- [22] BHOWMICK, S.; NAGARAJAIAH, S.; VEERARAGHAVAN, A. Vision and deep learning-based algorithms to detect and quantify cracks on concrete surfaces from UAV videos. **Sensors**, v. 20, n.21, p. 6299, 2020.
- [23] LUO, C.; YU, L.; YAN, J.; LI, Z.; REN, P.; BAI, X.; LIU, Y. Autonomous detection of damage to multiple steel surfaces from 360° panoramas using deep neural networks. **Computer-Aided Civil and Infrastructure Engineering**, v. 36, n. 12, p. 1585-1599, 2021.
- [24] CHA, Y. J.; CHOI, W.; BÜYÜKÖZTÜRK, O. Deep learning-based crack damage detection using convolutional neural networks, *Computer-Aided Civil and Infrastructure Engineering*, v. 32, n. 5, p. 361– 378, 2017.
- [25] CHOI, D.; BELL, W.; KIM, D.; KIM, J. UAV-Driven Structural Crack Detection and Location Determination Using Convolutional Neural Networks. **Sensors**, v. 21, n. 8, p. 2650, 2021.
- [26] MORGENTHAL, G.; HALLERMANN, N.; KERSTEN, J.; TARABEN, J.; DEBUS, P.; HELMRICH, M.; & RODEHORST, V. Framework for automated UAS-based structural condition assessment of bridges. **Automation in Construction**, v. 97, p. 77-95, 2019.
- [27] OH, S.; HAM, S.; LEE, S. Drone-Assisted Image Processing Scheme using Frame-Based Location Identification for Crack and Energy Loss Detection in Building Envelopes. **Energies**, v. 14, n. 19, p. 6359, 2021.
- [28] PERRY, B. J.; GUO, Y.; MAHMOUD, H. N. Automated site-specific assessment of steel structures through integrating machine learning and fracture mechanics. **Automation in Construction**, v. 133, p. 104022, 2022.
- [29] POTENZA, F.; RINALDI, C.; OTTAVIANO, E.; GATTULLI, V. A robotics and computer-aided procedure for defect evaluation in bridge inspection. **Journal of Civil Structural Health Monitoring**, v. 10, n. 3, p. 471-484, 2020.
- [30] VALENÇA, J.; PUENTE, I.; JÚLIO, E. N. B. S.; GONZÁLEZ-JORGE, H.; ARIAS-SÁNCHEZ, P. Assessment of cracks on concrete bridges using image processing supported by laser scanning survey. **Construction and Building Materials**, v. 146, p. 668-678, 2017.
- [31] VETRIVEL, A.; GERKE, M.; KERLE, N.; NEX, F.; VOSELMAN, G. Disaster damage detection through synergistic use of deep learning and 3D point cloud features derived from very high resolution oblique aerial images, and multiple-kernel-learning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 140, p. 45-59, 2018.
- [32] VIJAYANANDH, R.; SENTHIL KUMAR, M.; VASANTHARAJ, C.; RAJ KUMAR, G.; SOUNDARYA, S. Numerical study on structural health monitoring for unmanned aerial

vehicle. **Journal of Advanced Research in Dynamical and Control Systems**, v. 9, n. 6, p. 1937-1958, 2017.

- [33] ALI, R.; CHUAH, J. H.; TALIP, M. S. A.; MOKHTAR, N., & SHOAIB, M. A. Structural crack detection using deep convolutional neural networks. **Automation in Construction**, v. 133, p. 103989, 2022.
- [34] ZHU, Q.; DINH, T. H.; PHUNG, M. D.; HA, Q. P. Hierarchical convolutional neural network with feature preservation and autotuned thresholding for crack detection. **IEEE Access**, v. 9, p. 60201-60214, 2021.
- [35] WU, Y.; QIN, Y.; QIAN, Y.; GUO, F.; WANG, Z.; JIA, L. Hybrid deep learning architecture for rail surface segmentation and surface defect detection. **Computer-Aided Civil and Infrastructure Engineering**, v. 37, n. 2, p. 227-244, 2021.
- [36] YEUM, C. M.; CHOI, J.; DYKE, S. J. Automated region-of-interest localization and classification for vision-based visual assessment of civil infrastructure. **Structural Health Monitoring**, v. 18, v. 3, p. 675-689, 2019.
- [37] BOUZAN, G. B.; FAZZIONI, P. F.; FAISCA, R. G.; SOARES, C. A. Building facade inspection: A system based on automated data acquisition, machine learning, and deep learning image classification methods. **ARPN Journal of Engineering and Applied Sciences**, v. 16, n. 14, p. 1516, 2021.
- [38] ELLENBERG, A.; KONTOSOS, A.; MOON, F.; BARTOLI, I. Bridge related damage quantification using unmanned aerial vehicle imagery. **Structural Control and Health Monitoring**, v. 23, n. 9, p. 1168-1179, 2016.
- [39] AYELE, Y. Z.; ALIYARI, M.; GRIFFITHS, D.; DROGUETT, E. L. Automatic crack segmentation for UAV-assisted bridge inspection. **Energies**, v. 13, n. 23, p. 6250, 2020.
- [40] JIANG, S.; ZHANG, J. Real-time crack assessment using deep neural networks with wall-climbing unmanned aerial system. **Computer-Aided Civil and Infrastructure Engineering**, v. 35, n. 6, p. 549-564, 2020.
- [41] CASTAGNO, J.; ATKINS, E. Roof shape classification from LiDAR and satellite image data fusion using supervised learning. **Sensors**, v. 18, n.11, p. 3960, 2018.
- [42] FLAH, M.; SULEIMAN, A. R.; NEHDI, M. L. Classification and quantification of cracks in concrete structures using deep learning image-based techniques. **Cement and Concrete Composites**, v. 114, p. 103781, 2020.
- [43] GHOSH MONDAL T.; JAHANSHAH, M. R.; WU, R. T.; WU, Z. Y. Deep learning-based multi-class damage detection for autonomous post-disaster reconnaissance. **Structural Control and Health Monitoring**, v. 27, n. 4, p. 2507, 2020.
- [44] DORAFSHAN, S.; THOMAS, R. J.; MAGUIRE, M. Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete. **Construction and Building Materials**, v. 186, p. 1031-1045, 2018.