



Indústria 5.0: Oportunidades e Desafios
para Arquitetura e Construção

13º Simpósio Brasileiro de Gestão e
Economia da Construção e 4º Simpósio
Brasileiro de Tecnologia da Informação
e Comunicação na Construção

ARACAJU-SE | 08 a 10 de Novembro

1º MODELO DE APRENDIZADO DE MÁQUINA PARA INSPEÇÃO AUTOMATIZADA DE FACHADAS DE PAREDES DE CONCRETO.

Machine Learning model for automated inspection of concrete wall facades.

Alisson Souza Silva

Universidade Federal da Bahia | Salvador, Bahia | alissonss@ufba.br

Leonardo Gonçalves Gonzaga

Universidade Federal da Bahia | Salvador, Bahia | leonardog.contato@gmail.com

Roseneia Rodrigues Santos de Melo

Universidade Federal da Bahia | Salvador, Bahia | roseneia.engcivil@gmail.com

Dayana Bastos Costa

Universidade Federal da Bahia | Salvador, Bahia | dayanabcosta@ufba.br

RESUMO

As fachadas protegem a edificação contra os agentes de degradação ambiental, além de garantir o conforto dos usuários no ambiente interno. As manifestações patológicas podem comprometer seu desempenho, sendo necessária inspeções periódicas e manutenções preventivas. Entretanto, essas atividades, principalmente, visuais e manuais, não são realizadas corretamente por serem consideradas demoradas, inseguras e imprecisas. No entanto, o uso de tecnologias digitais pode superar tais limitações. Diante disso, este estudo busca avaliar o uso de algoritmos de aprendizado de máquina para inspeção automatizada de fachadas. O estudo foi realizado em quatro etapas: (1) seleção das obras, dos problemas em fachadas e das tecnologias utilizadas; (2) aquisição de imagens com drone; (3) processamento de imagens no Custom Vision; e (4) análise e avaliação dos resultados através dos indicadores de desempenho. Foram coletadas 2050 imagens de fachadas, das quais 720 possuíam anomalias e foram utilizadas para criação do modelo no Custom Vision. A partir dos treinamentos o modelo atingiu o desempenho de 51,8% de precisão e 68,5% de recall. Durante os testes, o modelo previu corretamente anomalias com até 97,4%, evidenciando que o modelo pode superar as limitações em relação à análise visual. Para trabalhos futuros é necessário o aprimoramento do modelo proposto.

Palavras-chave: Fachadas; inspeção automatizada; tecnologias digitais; drones; aprendizado de máquina.

ABSTRACT

The facades protect the building against agents of environmental degradation and ensure users' comfort in the internal environment. Pathological manifestations can compromise its performance, requiring periodic inspections and preventive maintenance. However, these visual and manual activities are not performed correctly because they are time-consuming, unsafe, and inaccurate. However, the use of digital technologies can overcome such limitations. Therefore, this study seeks to evaluate the use of machine learning algorithms for the automated inspection of facades. The study was carried out in four stages: (1) selection of works, facade problems, and technologies used; (2) drone image acquisition; (3) image processing in Custom Vision; and (4) analysis and evaluation of results through performance indicators. Two thousand fifty images of facades were collected, of which 720 had anomalies, and were used to create the model in Custom Vision. The model reached a 51.8% accuracy and 68.5% recall from training. During tests, the model correctly predicted anomalies with up to 97.4%, showing that the model can overcome the limitations of visual analysis. For future work, it is necessary to improve the proposed model.

Keywords: Façade; Automated Inspection; Digital Technologies; UAS; Machine Learning.

1 INTRODUÇÃO

A fachada é considerada o subsistema construtivo mais exposto às condições ambientais externas de uma edificação, devido sua inércia desfavorável e espessura fina. Ela recebe diretamente todo o ciclo higrótérmico, causando sua deterioração e levando a redução de desempenho do edifício (LIU; YEOH; CHUA, 2020). Diante dessa importância para a edificação, a inspeção periódica e a manutenção preventiva desse subsistema são atividades essenciais para garantir a integridade física do edifício (MEDEIROS JUNIOR; LIMA; BALESTRA, 2013). Antes da ocorrência de danos graves, as fachadas podem apresentar alguns sinais iniciais de manifestações patológicas como fissuras, manchas, desprendimento e corrosão. Portanto, o diagnóstico

¹SILVA, A. S. et al. Modelo de aprendizado de máquina para inspeção automatizada de fachadas de paredes de concreto. In: SIMPÓSIO BRASILEIRO DE TECNOLOGIA DA INFORMAÇÃO E COMUNICAÇÃO NA CONSTRUÇÃO, 13., 2023, Aracaju. **Anais [...]**. Porto Alegre: ANTAC, 2023.

oportuno e o reparo de tais anomalias visíveis podem efetivamente prevenir falhas maiores nos sistemas de fachada (CHEN et al., 2021). A manutenção preventiva evita que manifestações patológicas, como fissuras, em estágio inicial se expandam, ocasionando defeitos na estrutura da edificação. Além dessas preocupações, tais anomalias também são conhecidas por terem um impacto em vários aspectos de desempenho do edifício como, por exemplo, questões térmicas, energéticas e de umidade (PAULO; BRANCO; BRITO, 2014).

Atualmente, os drones vêm sendo frequentemente usados para inspeção visual periódica de envoltórias de edifícios para detectar condições inseguras ou danos vulneráveis (DAIS et al., 2021). O uso de drones com câmera acoplada possibilita a aquisição de uma grande quantidade de ativos visuais com uma resolução relativamente alta em pouco tempo (MORGENTHAL; HALLERMANN, 2014). Comparados aos métodos tradicionais de *close-up* através de rotas de acesso, como por exemplo, elevadores, andaimes e cordas industriais, os drones podem reduzir significativamente o consumo de tempo, a intensidade do trabalho e os riscos de segurança, possibilitando a realização de inspeção mais frequentes, especialmente para edifícios que já apresentam sinais de perigo (CHEN et al., 2021).

Em relação ao diagnóstico de anomalias em fachadas de edifícios por meio de imagens coletadas por drones, ainda há necessidade de que especialistas em inspeção predial analisem as imagens de forma manual. No entanto, esse processo para digitalizar manualmente as centenas de imagens é considerado trabalhoso, demorado e sujeito a erros (JUCÁ; OLIVEIRA; ZANONI, 2022). Para superar tais limitações o uso de algoritmos de Inteligência Artificial (IA) como aprendizado de máquina, do inglês *Machine Learning* (ML) e aprendizado profundo, do inglês *Deep Learning* (DL) podem automatizar esse processo de análise, tornando-o mais célere, preciso e confiável (KUMARAPU; SHASHI; KEESARA, 2021).

Silva e Costa (2022) analisaram estudos sobre inspeções automatizadas de fachada que utilizaram drones e redes de aprendizado de máquina para inspecionar fachadas de edifícios. No entanto, os estudos encontrados utilizaram essas tecnologias para inspecionar fachadas de vidro (BOWMAN et al., 2021), fachadas de revestimentos cerâmicos (EDIS; FLORES-COLEN; DE BRITO, 2014; BAUER et al., 2016), revestimento com pedras naturais (NETO; BRTO, 2011) e inspeção de deslocamento de objetos das fachadas (CHEW, 2021). Diante disso, observou-se que, em nenhum dos trabalhos encontrados na literatura testou o uso de drones e aprendizado de máquina para reconhecimento automatizado de falhas durante a execução de fachadas de paredes de concreto, que podem causar o surgimento de manifestações patológicas. Portanto, este estudo tem o objetivo de avaliar o uso de redes de aprendizado de máquina para reconhecimento automatizado de falhas construtivas e manifestações patológicas em fachadas de parede de concreto moldadas in loco visando a melhoria no sistema de gestão da qualidade.

2 USO DE INTELIGÊNCIA ARTIFICIAL PARA ISPEÇÕES AUTOMATIZADAS

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 (MÜLLER; GUIDO, 2016). Além disso, ela pode ser compreendida em camadas ou subconjuntos como o 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 e elaboração de saídas que satisfaçam a situação problema (DAMACENO; VASCONCELOS, 2018). O DL é constituído por diversos subconjuntos ou arquiteturas, como as Redes Neurais Convolucionais, que buscam construir representações complexas, a partir de representações mais simples. Os algoritmos em DL permitem que modelos que consistem em várias camadas de processamento operem e aprendam representações de dados usando vários níveis de abstração (ILIN; WATSON; KOZMA, 2017).

Diante disso, relevantes estudos focaram no desenvolvimento de métodos para inspeções automatizadas de anomalias na construção. Alguns desses trabalhos concentraram-se no uso de ML e subconjuntos de DL para detecção de fissuras (KIM; CHO, 2018; SILVA; LUCENA; 2018; KARAASLAN; BAGCI; CATBAS, 2021; XIANG et al., 2022; CHENG et al., 2023; LI et al., 2023), detecção de armadura exposta (RUBIO et al., 2019; SANTOS et al., 2022) e detecção de corrosão em estruturas de aço (HAN; ZHAO; XU, 2021; MUNAWAR et al., 2022; LEMOS et al., 2023). Alguns estudos propuseram modelos para classificação e detecção de fissuras em fachadas usando subconjuntos de ML a partir de conjuntos de imagens variados. Kim e Cho (2018) utilizaram uma base de dados de 42.000 imagens e Silva e Lucena (2018) utilizaram 3.500 imagens para treinamento de modelos buscando classificar de forma binária a existência de fissuras nas imagens. A partir dos treinamentos dos algoritmos, os modelos propostos por esses autores apresentaram ótimos indicadores de desempenhos como 92,35% de precisão para o modelo de Kim e Cho (2018) e 92,27% de precisão para o modelo de Silva e Lucena (2018). Apesar desses modelos terem atingido quase 100% de reconhecimento

automatizado, eles focaram apenas em fissuras e existem outras manifestações patológicas em fachadas com o mesmo potencial prejudicial, necessitando da identificação imediata através de inspeções.

3 MÉTODO DE PESQUISA

A estratégia de pesquisa adotada neste trabalho foi o estudo de caso exploratório, que busca identificar questões de pesquisa ou procedimentos a serem utilizados em pesquisas futuras (YIN, 2018). Diante disso, este estudo será desenvolvido nas seguintes etapas: (1) seleção das obras, dos possíveis problemas encontrados em fachadas de paredes de concreto e das tecnologias utilizadas para aquisição e processamento de imagens; (2) aquisição de imagens com drone; (3) carregamento das imagens no Microsoft Custom Vision para treinamento e teste do algoritmo; e (4) análise dos dados e avaliação dos resultados através dos indicadores de desempenho.

3.1 Seleção das obras, dos problemas e das tecnologias utilizadas

O estudo foi realizado em três obras da Empresa X, denominadas Obra A, B e C, ambas localizadas na região metropolitana de Salvador-BA. Todas as obras são compostas por torres verticais e utilizam sistema construtivo em paredes de concreto moldadas in loco, executado por meio do uso de formas de alumínio. A Obra A é composta por duas torres, a Obra B é composta por quatro torres e a Obra C é composta por três torres. Essas obras foram selecionadas a partir de uma reunião com gestores da Empresa X em que foram levantados onze problemas encontrados em fachadas de paredes de concreto, sendo: (1) armadura exposta; (2) fissura; (3) falta de remoção das faquetas; (4) falha na calafetação das esquadrias; (5) junta fria; (6) alinhamento entre pavimentos; (7) ondulações; (8) falha a aplicação da textura e pintura final; (9) umidade e infiltração; (10) ninhos de concretagem; e (11) manchas e mudança na tonalidade da fachada.

A partir desse levantamento, foi realizada uma investigação do problema na Obra A, identificando quais das onze anomalias poderiam ser identificadas com uso de drone e algoritmos de aprendizado de máquina. Diante disso, o escopo da pesquisa foi reduzido para quatro falhas construtivas e manifestações patológicas sendo: (1) armadura exposta; (2) falta de remoção das faquetas; (3) ninhos de concretagem; e (4) fissuras (Figura 1). Este escopo foi reduzido devido às características das anomalias com características sutis que foram retiradas do estudo, pois não eram possíveis de serem vistas apenas com drone e aprendizado de máquina.



Figura 1: Manifestações da pesquisa investigadas neste estudo



Fonte: O autor.

As inspeções de fachadas realizadas neste estudo utilizaram dois drones do tipo quadricóptero (Quadro 1). Esses equipamentos foram escolhidos por serem tecnologias acessíveis e comercializadas, com características que facilitam a operação em canteiros de obras.

Quadro 1: Drones utilizados para a aquisição de imagens

Equipamento		
Marca/ Linha/ Modelo	DJI Phantom 4	DJI Air 2S
Tamanho Diagonal	350mm	302mm
Peso de decolagem	1.388 Kg	0.595 Kg
Autonomia máxima de voo	28 minutos	31 minutos
Velocidade máxima	72 Km/h	68.4 km/h
Câmera - resolução de foto	20 MP	20 MP

Fonte: O autor.

O processamento das imagens coletadas pelos drones foram realizados no software Custom Vision, da Azure Serviços Cognitivos. O Custom Vision é uma ferramenta de aprendizado de máquina baseada em nuvem que permite aos usuários criar modelos de visão computacional personalizados e treiná-los com seus próprios dados. Ele pode ser usado para classificar, detectar e localizar objetos em imagens e vídeos com até 4 MB (*megabytes*). Além disso, é possível regular o tempo de treinamento para aprendizado no próprio software. Após o treinamento, a avaliação de desempenho do software é realizada a partir da análise dos indicadores estatísticos fornecidos pela plataforma, sendo:

- **Precisão:** entre as classificações positivas do modelo, indica quantas foram acertadas;
- **Recall:** das amostras positivas existentes, indica quantas o modelo conseguiu classificar corretamente;
- **mAP:** indica a média da precisão média.

3.2 Aquisição de imagens com drone

No total, foram realizadas 20 visitas em três obras, que se iniciaram em janeiro de 2022 e finalizaram em janeiro de 2023. A partir dessas visitas foram coletadas 2050 imagens. Após a aquisição dessas imagens, elas foram analisadas manualmente e classificadas apenas as imagens que continham alguma das quatro manifestações patológicas que o estudo tem como foco. Diante disso, foram levantadas 720 imagens com manifestações patológicas em fachadas de paredes de concreto. As imagens foram coletadas em formato jpeg e a distribuição por manifestação patológica é apresentada no Quadro 2.

Quadro 2: Manifestações patológicas levantadas nas visitas

Manifestação Patológica	Número de imagens	Tamanho das imagens coletadas (MB)
Armadura exposta	139	De 6 a 8 <i>megabytes</i>
Falta de remoção das faquetas	194	De 6 a 8 <i>megabytes</i>
Fissuras	84	De 6 a 8 <i>megabytes</i>
Ninhos de concretagem	303	De 6 a 8 <i>megabytes</i>
TOTAL	720	

Fonte: O autor.

3.3 Processamento de imagens no custom vision

Após a aquisição e classificação das imagens de acordo com cada manifestação patológica presente na imagem, elas tiveram seu tamanho reduzido até 4MB a partir de um código de linguagem desenvolvido pelos pesquisadores deste trabalho. Posteriormente, foram realizados treinamentos dos algoritmos, avaliando o desempenho do software em relação aos dados obtidos. Esse processo contemplou os seguintes passos: (1) adicionar as imagens coletadas; (2) marcar as manifestações patológicas presentes nas imagens; (3) treinar o modelo criado e, por fim; (4) testar o modelo criado com novas imagens, conforme ilustrado na Figura 2.

Figura 2: Etapas do Custom Vision



Fonte: O autor.

Após os treinamentos do algoritmo é possível avaliar o desempenho do modelo criado no Custom Vision através dos indicadores **precisão**, **recall** e **mAP**. Esses indicadores são apresentados pelo próprio software e são apresentados de forma individual, ou seja, por objeto rotulado. Além dos indicadores de cada rótulo, o Custom Vision calcula uma média entre os indicadores de cada rótulo relacionando a quantidade de imagens utilizada e apresenta um valor geral para o modelo. A partir das etapas anteriores, avaliou-se quanto o modelo

conseguiu prever corretamente a partir dos testes realizados no Custom Vision. Essa avaliação foi realizada de acordo com os indicadores apresentados durante o treinamento e dos valores de probabilidade durante o teste. Os resultados desta análise são discutidos na próxima seção.

4 RESULTADOS E DISCUSSÃO

O resultado dos treinamentos e dos valores dos indicadores individuais são apresentados no Quadro 3.

Quadro 3: Modelo criado no Custom Vision (Etapa de treinamento)

Manifestação patológica rotuladas	Quantidade de imagens treinadas	Tempo de treinamento (h)	Indicadores de desempenho por rótulo		
			Precisão	Recall	mAP
Armadura exposta	139	4 horas	63,60%	73,70%	72,50%
Falta de remoção das faquetas	194	4 horas	56,30%	62,80%	55,40%
Fissuras	84	4 horas	71,40%	83,30%	77,20%
Ninhos de concretagem	303	4 horas	45,10%	69,50%	55,10%
TOTAL	720	-	-	-	-

Fonte: O autor.

Além do treinamento, nesta etapa foram realizados testes com novas imagens coletadas em campo para avaliar a probabilidade de reconhecimento automatizado em relação às falhas e manifestações patológicas treinadas na etapa anterior. Foram utilizadas 15 novas imagens de cada tag rotulada. Além disso, foi escolhido o valor limiar de 30% para a realização dos testes. O valor limiar em aprendizado de máquina é um valor definido que determina a decisão tomada pelo modelo após a realização de uma previsão/probabilística. Esse valor é usado para definir qual será a classe/resultado final atribuído a uma amostra após a análise feita pelo modelo (AZURE, 2022). As informações sobre o teste são apresentadas no Quadro 4.

Quadro 4: Teste realizado no Custom Vision

Manifestações Patológicas rotuladas	Tamanho das imagens	Valor limiar	Quantidade de imagens testadas	Média de testes (%)
Armadura exposta	4 MB	30%	15	69,86%
Falta de remoção das faquetas	4 MB	30%	15	44,55%
Fissuras	4 MB	30%	15	0%
Ninho de concretagem	4 MB	30%	15	54,81%

Fonte: O autor.


A partir do treinamento do modelo é possível avaliar o desempenho geral do modelo, bem como analisar individualmente cada item rotulado. Em relação ao desempenho individual do modelo criado no Custom Vision, a partir dos resultados apresentados no Quadro 3, observa-se que a rotulagem que atingiu melhores valores de precisão foram as fissuras, armadura exposta, falta de remoção das faquetas e ninhos de concretagem, assim sucessivamente. Observa-se que as **fissuras** atingiram valores individuais de **71,4% de precisão** e **83,3% de recall**, durante os treinamentos. No entanto, durante os testes (Quadro 4), o modelo não conseguiu prever nenhuma fissura nas imagens.

O rótulo de **armadura exposta** foi o segundo rótulo com maiores indicadores (**63,60% de precisão** e **73,70% de recall**) e durante os testes também apresentaram os maiores valores de probabilidade no reconhecimento automatizado, alcançando **69,86%** de identificação correta. Isso pode estar relacionado as características dessa falha construtiva, por ficar mais evidente nas fachadas devido a exposição de estrutura metálica nas fachadas. Comparando as características de uma armadura exposta com as fissuras, por exemplo, essa anomalia apresenta maior destaque em relação as fachadas por apresentar cores diferentes, muitas vezes as barras de aço apresentam colorações diferentes da estrutura cinza das fachadas e o formato da anomalia também auxilia na sobreposição com as paredes de concreto, como visualizado na Figura 1.

Os rótulos de **faquetas e ninhos de concretagem** apresentaram valores de indicadores próximos durante os treinamentos, no entanto, durante os testes o rótulo de **ninho de concretagem** apresentou a segunda maior probabilidade de reconhecimento, atingindo **54,81%** de reconhecimento correto dessa manifestação patológica. Já o rótulo de falta de **remoção das faquetas** atingiu **44,55%** de probabilidade de reconhecimento correto. Essa diferença pode ter sido causada pela diferença de característica das faquetas e dos ninhos de concretagem. A depender do ângulo que a câmera coletou as imagens, dificilmente o algoritmo pode identificar a faqueta. Além disso, foram utilizadas 303 imagens de ninhos de concretagem para treinamento, enquanto as faquetas foram treinadas a partir de 194 imagens.

Além dos valores para cada um dos rótulos, o Custo Vision calcula a média de desempenho do modelo, levando em consideração a quantidade de imagens treinadas e os valores de indicador de cada rótulo. Diante disso, o modelo proposto neste trabalho alcançou **51,8% de precisão, 68,5% de recall e 65% de mAP** (Figura 3). Embora o desempenho geral do modelo não tenha sido tão alto, quando comparados aos estudos da literatura, como o Kim e Cho (2018) que atingiram 92,35% de precisão e 82,28% de recall e Silva e Lucena (2018) que atingiram 92,27% de precisão. No entanto, o modelo proposto neste trabalho além de detectar a anomalia presente nas imagens, ele classificou qual anomalia estava presente na imagem entre um conjunto de quatro rótulos de anomalias e já o modelo proposto por esses autores classificou apenas uma anomalia em conjunto de imagens. Além disso, a base de dados utilizada neste trabalho foi de 720 imagens distribuídas entre as quatro manifestações patológicas, já a base de dados utilizada por Silva e Lucena (2018) foi de 3.500 imagens e a de Kim e Cho (2018) 42.000 imagens, ambas de uma única manifestação patológica, o que pode ter facilitado o entendimento do algoritmo em relação ao que detectar na imagem.

Figura 3: Indicadores de desempenho geral do modelo



Fonte: O autor.

O teste realizado com o modelo apresentou valores de probabilidade semelhantes aos de treinamento, exceto para o rótulo de fissuras. Em alguns casos, o modelo confundiu os sinais das paredes de concreto com faquetas, ninhos de concretagem e até mesmo não reconheceu algumas falhas ou manifestações patológicas, mas no geral, o Modelo alcançou um bom desempenho durante os testes acertando corretamente mais de 60% das não conformidades. As imagens escolhidas para teste foram analisadas manualmente e selecionada somente as imagens que possuíam alguma falha ou manifestação patológica. O Custom Vision reconheceu corretamente um **ninho de concretagem** com **74,3%** de probabilidade, uma **armadura exposta** com **87,2%** e um **faqueta** com **97,6%** de probabilidade de serem as manifestações patológicas identificadas (Figura 4).

Figura 4: Testes realizados no Custom Vision



Fonte: O autor.

Apesar do detector ter identificado corretamente as falhas e manifestações patológicas, apresentando bons valores de probabilidade, isso não ocorreu no reconhecimento de fissuras. Mesmo que o modelo tenha apresentado bom desempenho nos treinamentos, no teste ele não identificou a fissura presente na imagem. Isso pode ter acontecido devido as características da fissura em relação a fachada de paredes de concreto, pois, como as fachadas apresentam marcas das formas após a retirada das formas, o algoritmo pode ter se confundido em relação ao aprendizado dessa anomalia. Além das marcas das formas, a mudança da tonalidade do concreto e das concretagens podem ter contribuído na confusão do modelo em relação ao rótulo treinado (Figura 5).

Figura 5: Fachadas com marcas das formas após a concretagem



Fonte: O autor.

5 CONSIDERAÇÕES FINAIS

Este estudo teve o objetivo de avaliar o uso de redes de aprendizado de máquina para reconhecimento automatizado de falhas e manifestações patológicas em fachadas de paredes de concreto moldadas in loco. Diante disso, foi treinado um modelo de aprendizado de máquina no software Custom Vision a partir de 720 imagens coletadas por drone e este modelo foi testado utilizando 60 novas e diferentes imagens da etapa de treinamento. Mesmo o modelo não predizendo corretamente a fissura ele apresentou ótimos valores durante os testes, como por exemplo, o rótulo de **“falta de remoção das faquetas”** que atingiu **97,40%** de identificação correta. Isso também ocorreu para os demais rótulos, principalmente os que apresentaram características menos sutis em relação à fachada de parede de concreto.

Observou-se que além da quantidade, a qualidade das imagens utilizadas no modelo são fundamentais para o bom desempenho dos indicadores. Além disso, observou-se que os problemas investigados neste trabalho apresentam uma certa dificuldade para serem reconhecidos automaticamente com uso de algoritmos de aprendizado de máquina, pois todos os problemas podem ser facilmente confundidos com o objeto de estudo, neste caso, as fachadas de paredes de concreto. Outra limitação associada a esta, é que as paredes de concreto moldadas in loco apresentam marcas das formas que são deixadas após a concretagem, com isso o algoritmo tende a confundir com as falhas ou manifestações patológicas com características semelhantes. Para trabalhos futuros, os pesquisadores pretendem investigar mais obras buscando ampliar a base de dados para aprimoramento do modelo, além de incluir outras classes de falhas e manifestações patológicas.

6 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

AZURE, C. S. Como aprimorar o modelo de Visão Personalizada. 2022. Disponível em:< <https://learn.microsoft.com/pt-br/azure/cognitive-services/custom-vision-service/getting-started-improving-your-classifier>>. Acesso em 23 jan. 2023.

- BAUER, E., et al. Facades inspection with infrared thermography: cracks evaluation. **Journal of Building Pathology and Rehabilitation**, v. 1, p. 1-7, 2016.
- BHOWMICK, Sutanu; NAGARAJAIAH, Satish; VEERARAGHAVAN, Ashok. 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.
- BOWMAN, M. et al. Investigation into Application of Artificial Intelligence to Facade. In: **EASEC16: Proceedings of The 16th East Asian-Pacific Conference on Structural Engineering and Construction, 2019**. Springer Singapore, p. 1321-1331, 2021.
- CHEN, Kaiwen et al. Automated crack segmentation in close-range building façade inspection images using deep learning techniques. **Journal of Building Engineering**, v. 43, p. 102913, 2021.
- CHENG, Haodong et al. Embankment crack detection in UAV images based on efficient channel attention U2Net. In: **Structures**. Elsevier, 2023. p. 430-443.
- CHEW, Michael YL. Façade inspection for falling objects from tall buildings in Singapore. **International Journal of Building Pathology and Adaptation**, n. ahead-of-print, 2021.
- DAIS, D. et al. Automatic crack classification and segmentation on masonry surfaces using convolutional neural networks and transfer learning. **Automation in Construction**, v. 125, n. July 2020, 2021.
- DAMACENO, Siuari S. VASCONCELOS, Rafael, O. 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.
- EDIS, E.; FLORES-COLEN, I.; DE BRITO, J. Passive thermographic detection of moisture problems in façades with adhered ceramic cladding. **Construction and Building Materials**, v. 51, p. 187-197, 2014.
- ELLENBERG, A. et al. Masonry crack detection application of an unmanned aerial vehicle. In: **Computing in Civil and Building Engineering** (2014). 2014. p. 1788-1795.
- HAN, Qinghua; ZHAO, Nan; XU, Jie. Recognition and location of steel structure surface corrosion based on unmanned aerial vehicle images. **Journal of Civil Structural Health Monitoring**, v. 11, n. 5, p. 1375-1392, 2021.
- ILIN, R.; WATSON, T.; KOZMA, R. Abstraction hierarchy in deep learning neural networks. In: **2017 International Joint Conference on Neural Networks (IJCNN)**. IEEE, p. 768-774, 2017.
- JUCÁ, Tatiana Renata Pereira; OLIVEIRA, Janes Cleiton Alves de; ZANONI, Vanda Alice Garcia. Uso do drone como tecnologia disruptiva na inspeção de fachadas. In: **PATRIMÔNIO 4.0**, v. 3, 2022, Goiânia. Anais [...]. Goiânia: LASUS FAU, 2022. Disponível em: <https://www.patrimonio40.tec.br/anais>. Acesso em: 20 nov. 2022.
- KARAASLAN, Enes; BAGCI, Ulas; CATBAS, F. Necati. Attention-guided analysis of infrastructure damage with semi-supervised deep learning. **Automation in Construction**, v. 125, p. 103634, 2021.
- KIM, Byunghyun; CHO, Soojin. Automated vision-based detection of cracks on concrete surfaces using a deep learning technique. **Sensors**, v. 18, n. 10, p. 3452, 2018.
- 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.
- LEMOS, Rafael et al. Automatic Detection of Corrosion in Large-Scale Industrial Buildings Based on Artificial Intelligence and Unmanned Aerial Vehicles. **Applied Sciences**, v. 13, n. 3, p. 1386, 2023.
- LI, Ruoxian et al. Automatic bridge crack detection using Unmanned aerial vehicle and Faster R-CNN. **Construction and Building Materials**, v. 362, p. 129659, 2023.
- LIU, Yiqing; YEOH, Justin KW; CHUA, David KH. Deep learning–based enhancement of motion blurred UAV concrete crack images. **Journal of computing in civil engineering**, v. 34, n. 5, p. 04020028, 2020.

- MEDEIROS JUNIOR, Ronaldo Alves de; LIMA, Maryangela Geimba de; BALESTRA, Carlos Eduardo Tino. Identificação das Principais Manifestações Patológicas em Estruturas de Concreto Armado Pertencentes ao DCTA. In: **Congresso Internacional sobre Patologia e Reparação de Estruturas**, p. 1-9, 2013.
- MORGENTHAL, G.; HALLERMANN, N. Quality Assessment of Unmanned Aerial Vehicle (UAV) Based Visual Inspection of Structures. **Advances in Structural Engineering**, v. 17, n. 3, p. 289-302, 2014.
- MÜLLER, A. C.; GUIDO, S. **Introduction to machine learning with Python: a guide for data scientists**. " O'Reilly Media, Inc.", 2016.
- MUNAWAR, Hafiz Suliman et al. Civil infrastructure damage and corrosion detection: An application of machine learning. **Buildings**, v. 12, n. 2, p. 156, 2022.
- NETO, Natália; DE BRITO, J. Inspection and defect diagnosis system for natural stone cladding. **Journal of Materials in Civil Engineering**, v. 23, n. 10, p. 1433-1443, 2011.
- PAPADOPOULOS, Ellena; GONZALEZ, Felipe. UAV and AI application for runway foreign object debris (FOD) detection. In: **IEEE Aerospace Conference**. IEEE, p. 1-8, 2021.
- PAULO, P. V.; BRANCO, F. A.; DE BRITO, J. Using orthophotography based on Buildings. Life software to inspect building facades. **Journal of Performance of Constructed Facilities**, v. 28, n. 5, p. 04014019, 2014.
- RUBIO, Juan Jose et al. Multi-class structural damage segmentation using fully convolutional networks. **Computers in Industry**, v. 112, p. 103121, 2019.
- SANTOS, Lara Monalisa Alves et al. Deep learning applied to equipment detection on flat roofs in images captured by UAV. **Case Studies in Construction Materials**, v. 18, p. e01917, 2023.
- SILVA, Alisson Souza; COSTA, Dayana Bastos. Análise do uso de tecnologias digitais para identificação automatizada de patologias em construções. **ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO**, v. 19, p. 1-14, 2022.
- SILVA, Wilson Ricardo Leal da; LUCENA, Diogo Schwerz de. Concrete cracks detection based on deep learning image classification. In: **Proceedings**. MDPI, p. 489. 2018.
- 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.
- XIANG, Chao et al. Crack detection algorithm for concrete structures based on super-resolution reconstruction and segmentation network. **Automation in Construction**, v. 140, p. 104346, 2022.