



# ENTAC 2024

XX ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO  
Maceió, Brasil, 9 a 11 de outubro de 2024



## Uso de Data Augmentation para reconhecimento automatizado de anomalias em fachada

Using Data Augmentation for automated recognition of facade anomalies

### Walisson Santos Oliveira

Universidade Federal da Bahia | Salvador | Brasil | [walissonoliveira@ufba.br](mailto:walissonoliveira@ufba.br)

### Alisson Souza Silva

Universidade Federal da Bahia | Salvador | Brasil | [so\\_alisson@hotmail.com](mailto:so_alisson@hotmail.com)

### Roseneia Rodrigues Santos de Melo

Universidade Federal da Bahia | Salvador | Brasil | [roseneia.engcivil@gmail.com](mailto:roseneia.engcivil@gmail.com)

### Pedro Afonso Vieira Fernandes Braga

Universidade Federal da Bahia | Salvador | Brasil | [pedrofernandes@ufba.br](mailto:pedrofernandes@ufba.br)

### Dayana Bastos Costa

Universidade Federal da Bahia | Salvador | Brasil | [dayanabcosta@ufba.br](mailto:dayanabcosta@ufba.br)

### Resumo

Nos últimos anos, observa-se um crescimento no uso de Inteligência Artificial (IA) para análise automatizada de imagens. Entretanto, existem algumas limitações em relação a pequenos conjuntos de dados. Visando minimizar essa limitação, este estudo avalia o uso de técnicas de *Data Augmentation* (DA) para criar novos modelos de reconhecimento automatizado de imagens. A estratégia de pesquisa utilizada foi uma simulação experimental, a partir do (i) refinamento da base de dados de imagens de fachadas de concreto; (ii) desenvolvimento de um código de DA para expandir a base de dados; (iii) treinamento e teste das imagens utilizando plataformas web com redes pré-treinadas; e (iv) análise dos resultados por meio de indicadores de desempenho. Os resultados indicaram que o “Modelo com método de contraste”, utilizando algoritmos ResNet e AlexNet, atingiu 67,3% de precisão e 94,6% de Recall.

Palavras-chave: Inspeção automatizada. Ativos visuais. Base desbalanceada. Aprendizado de Máquina.

### Abstract

*In recent years, there has been an increase in the use of Artificial Intelligence (AI) for automated image analysis. However, there are some limitations regarding small data sets. Aiming to minimize this limitation, this study evaluates using Data Augmentation (DA) techniques to create new automated image recognition models. The research strategy used was an experimental simulation based on (i) refinement of the database of images of concrete facades, (ii) development of a DA code to expand the database, (iii) training and testing images using web platforms with pre-trained networks; and (iv) analysis of results through performance indicators. The results indicated that the “Model with contrast method,” using ResNet and AlexNet algorithms, achieved 67.3% precision and 94.6% Recall.*

*Keywords: Automated inspection. Visual assets. Unbalanced base. Machine Learning.*



Como citar:

OLIVEIRA, W.; SILVA, A.; MELO, R.; BRAGA, P.; COSTA, D. Uso de Data Augmentation para reconhecimento automatizado de anomalias em fachada. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 20., 2024, Maceió. *Anais...* Maceió: ANTAC, 2024.

## INTRODUÇÃO

Na construção civil, especialmente no âmbito da engenharia diagnóstica, a identificação de falhas construtivas e manifestações patológicas é uma atividade fundamental para auxiliar os profissionais nas atividades de manutenção [1]. Geralmente, a avaliação dessas condições é realizada baseado em informações obtidas através de inspeções visuais ou manuais [2]. Entretanto, com o avanço tecnológico e a crescente preocupação pela conservação e segurança dos profissionais da construção civil, surge a necessidade de substituir os métodos tradicionais de inspeção por métodos mais automatizados e seguros [3].

Nesse sentido, diversos estudos têm avançado utilizando algoritmos de Inteligência Artificial (IA) e seus subconjuntos como o Aprendizado de Máquina (AM), Aprendizado por Transferência (AT) e Aprendizado Profundo (AP). [4] e [5] utilizaram redes de AT para detecção de fissuras alcançando altas precisões, como 99,58% e 99,9%, respectivamente. [6] apresenta uma arquitetura baseada em Redes Neurais Convolucionais (RNC) para detecção de fissuras em superfícies de concreto atingindo uma precisão máxima de 99,8%. Entretanto, existe um grande desafio para que modelos de IA alcance altos indicadores de precisão, como a necessidade de grandes conjuntos de dados [7].

Nesse contexto, as técnicas de aumento de dados, do inglês *Data Augmentation* (DA), apresentam-se como uma possível estratégia para minimizar os impactos negativos causados pela ausência de dados [8]. Assim, recentemente, muitos estudos dedicaram-se ao uso de algoritmos de AP para detecção de objetos em inspeções prediais. Dessa maneira, observa-se na literatura diversas aplicações que contribuem para esse avanço, tais como, a construção de modelos de detecção de trincas, rachaduras e fissuras baseados em AP [9][5][6], reconhecimento de manifestações biológicas [10][11] e classificação e detecção de defeitos [12][13].

Apesar desses avanços, na maioria dos estudos, o uso de AM e AP é enfatizado, mas há uma carência considerável de pesquisas sobre a detecção de uma maior quantidade de anomalias construtivas, além de trincas, fissuras e rachaduras em fachadas de concreto. Portanto, há uma necessidade de investigar como os subconjuntos de IA podem detectar e classificar outros defeitos em fachadas de concreto. Além disso, devido a diversidade de redes de ML disponíveis, existe a necessidade de avaliar o desempenho de modelos de reconhecimento automatizado de anomalias de fachadas de concreto em diferentes arquiteturas utilizando técnicas de DA para aprimorar bases de dados desbalanceadas. Assim, esse estudo investiga e analisa os impactos do uso de técnicas de DA para aprimoramento de modelos de reconhecimento de anomalias construtivas em fachadas de paredes de concreto, bem como testa redes de AP distintas como ResNet, AlexNet e YOLO a partir das plataformas Custom Vision® e Roboflow®.

## REVISÃO DA LITERATURA

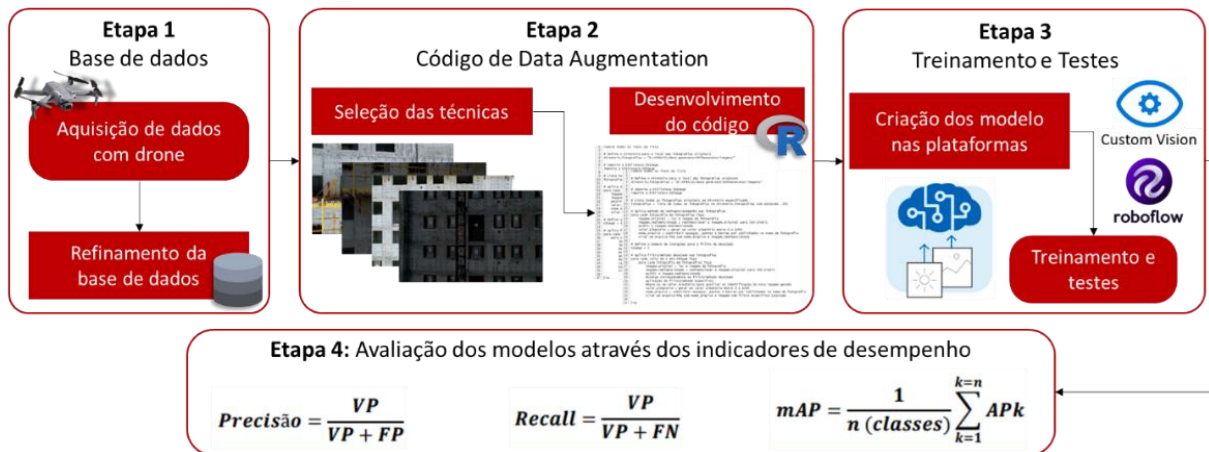
O *Data Augmentation* (DA) é uma técnica empregada na fase de treinamento de modelos de Aprendizado de Máquina (AM) para ampliar a diversidade e quantidade de dados disponíveis para o treinamento [14]. Essa abordagem envolve várias alterações aos dados existentes, resultando na criação de novos exemplos que representam variações dos dados originais. De acordo com [15], tais modificações podem englobar rotações, redimensionamentos, translações, ajustes de cores e distorções geométricas, adaptando-se ao tipo de dados e ao contexto da aplicação. Essas alterações possibilitam que os modelos de AM apresentem melhores indicadores de desempenho, tendo em vista que os dados desempenham um papel importante nas tarefas de Aprendizado Profundo (AP).

Diante da versatilidade das aplicações das técnicas de DA, alguns estudos utilizaram algumas delas para melhorar o reconhecimento automatizado de anomalias em inspeções automatizadas de fachadas. O estudo de [9] avaliou o uso de seis técnicas de DA para aprimoramento do reconhecimento automatizado de um modelo treinado e testado usando algoritmos ResNet e AlexNet. Por sua vez, segundo os autores, o modelo que atingiu melhores indicadores atingiu 78,7% de recall durante os testes, entretanto, obtiveram baixos indicadores de precisão e mAP (28,9% e 61,9%, respectivamente). Observa-se no estudo desses autores que as técnicas de DA utilizadas fizeram apenas rotações nas imagens, aumentando a base de dados de uma forma muito sutil, já que os problemas presentes nas imagens também eram sutis. Diferente dessa pesquisa, [16] avaliou algumas técnicas de DA envolvendo rotações que apresentaram bons resultados, entretanto, as imagens utilizadas por ele incluíam equipamentos de infraestrutura como escavadeiras, caminhões, betoneiras e demais imagens com os elementos mais bem definidos nas imagens, diferentes da base de dados de [9]. Entretanto, existem outras técnicas que podem ser avaliadas utilizando imagens com problemas sutis, como avaliação de cores, contraste e brilho e redimensionamento das imagens.

## MÉTODO DE PESQUISA

Este estudo adotou como estratégia de pesquisa uma simulação experimental, desenvolvida em quatro etapas (Figura 1), sendo: (1) refinamento da base de dados de imagens de fachadas de concreto; (2) desenvolvimento de um código de DA para expandir a base de dados; (3) treinamento e teste das imagens utilizando plataformas web com redes pré-treinadas; e (4) análise dos resultados por meio de indicadores de desempenho.

**Figura 1- Delineamento da Pesquisa**




Fonte: Os autores.

Os testes realizados nesta pesquisa foram desenvolvidos nas Plataformas Web conhecidas como Custom Vision® e Roboflow®. O Custom Vision é um serviço de desenvolvimento de modelo de IA entre os Serviços Cognitivos do Microsoft Azure, e, portanto, é especialista em análise visual, que categoriza imagens armazenadas e define tags dentro das imagens em conjunto com o Microsoft Azure [17]. Os algoritmos do Custom Vision utilizam redes pré-treinadas para o aprendizado e classificação de imagens, tais como [18]. O Roboflow é um software web de visão computacional que fornece funções para carregar, rotular, aumentar, exportar, treinar e testar modelos [19]. O Roboflow suporta diversas redes pré-treinadas para o aprendizado de máquina, principalmente as do tipo YOLO [20].

## Base de Dados

A base de dados utilizada neste estudo foi coletada por [21] por meio de um drone do tipo quadricóptero, do modelo DJI Air 2S, com uma câmera de 12 megapixels. Os autores coletaram 1725 imagens em cinco edifícios diferentes, durante dez meses de inspeção seguindo protocolos específicos de voo. A partir dessas imagens, foi realizado um refinamento na base de dados, selecionando as imagens que apresentavam melhores características, selecionando imagens capturadas em até dois pavimentos de cada edificação. Dessa forma, foram selecionadas 26 imagens divididas em quatro anomalias (Figura 2) para avaliar os modelos e técnicas de DA propostos.

**Figura 2 - Anomalias em fachadas de parede de concreto**



Fonte: Os autores.

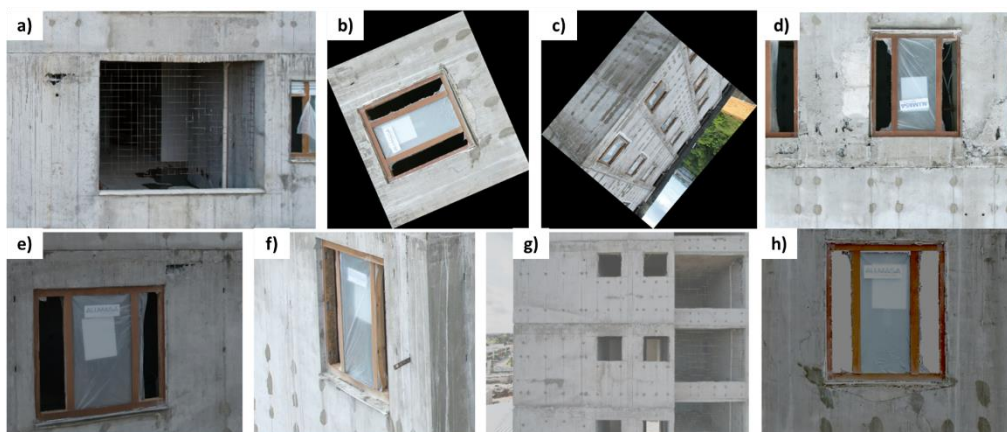
## Desenvolvimento do código de DA para ampliação dos *dataset*

Os métodos para ampliação da base de dados foram aplicados a partir da biblioteca *EImage*, no ambiente de desenvolvimento integrado (IDE) *RStudio*, por meio da utilização da linguagem R na elaboração dos respectivos algoritmos. Nesse sentido, aplicou-se combinações de técnicas de aumento de imagem baseadas em transformações geométricas e fotométricas para a ampliação desses dados, apresentadas na Figura 3.

As seguintes transformações foram aplicadas para o aumento de dados:

- Redimensionar: Segundo Ottoni *et al.* [16], a técnica “Redimensionar (Resize)” trata-se da alteração do tamanho da imagem, ou seja, uma transformação do tipo geométrica (Figura 3a). Nesse trabalho, essa técnica foi aplicada para reduzir o processamento das imagens.
- Rotação: Consoante a [22], a técnica de “Rotação (Rotation)” é um movimento circular em torno do próprio eixo da imagem (Figura 3b e 3c).
- Espelhamento Horizontal e Vertical: Conforme [15], as técnicas de “Espelhamento Horizontal (Flip)” e “Espelhamento Vertical (Flop)” diz respeito ao espelhamento horizontal e vertical aleatório da imagem, respectivamente (Figura 3c e 3d).
- Brilho: Segundo [23], a técnica de “Brilho” diz respeito a alteração da claridade global da imagem (Figura 3f, 3g e 3h). Para alterar o brilho de uma imagem, soma-se aos pixels de RGB um fator aleatório. Quanto mais próximo de 1 é esse fator, mas próximo essa imagem está da cor branca.
- Contraste: De acordo com [23], diferentemente do “Brilho”, a técnica de “Contraste” se configura por um fator aleatório que multiplica os pixels de RGB da imagem (Figura 3e e 3g). Caso esse fator seja menor que 1, o contraste será diminuído. Por outro lado, o contraste será aumentado se esse fator for maior que 1.
- Correção Gamma: Segundo [23], a técnica de “Correção Gamma” é uma transformação que aplica mais ênfase às cores em destaque da imagem, geralmente a cor preta (Figura 3h).

**Figura 3 – Exemplos de imagens e suas técnicas de DA**



Fonte: Os autores.

O algoritmo *Data Generator* foi elaborado por [23] e outros trabalhos correlatos de mesma autoria. Para este artigo, o algoritmo apresenta algumas adaptações e mudanças de parâmetros, em razão das características específicas do respectivo banco de dados e contexto do respectivo trabalho. Os algoritmos utilizados durante o presente estudo estão disponíveis no link da web (<https://github.com/Paper-Data-Aug/Data-Generator>). Para execução dos algoritmos foi utilizado uma máquina Intel(R) Core (TM) i3-5005U e 12GB de memória RAM.

## Treinamento e teste nas plataformas

Ambas as plataformas Roboflow® e Custom Vision® permitem manipular os dados com eficiência, possibilitando utilizar assistência IA para a anotações de imagens. No caso do Custom Vision, há o recurso chamado *Smart Labeler*, em que gera *tags* sugeridas por um modelo já treinado na plataforma. Cada respectivo modelo gerado representa o conjunto de dados em que se aplicou um método de DA, exceto o modelo que contém o *dataset* original. Ao todo, foram gerados oito modelos no Roboflow e seis modelos no Custom Vision. Uma vez estabelecido o conjunto de dados de 532 imagens aumentadas e originais para criação de um respectivo modelo, as imagens foram anotadas, e posteriormente os modelos foram treinados. A Tabela 1 demonstra a organização do banco de dados para cada modelo.

**Tabela 1: Organização do conjunto de dados para realização dos modelos**

Modelos	Número de imagens por modelo	Divisão do banco de dados
Modelo com imagens originais (1)	26	
Modelo com método de Brilho (2)	80	
Modelo com método de Contraste (3)	80	
Modelo com método de Brilho + Contraste (4)	80	Treinamento: 70%
Modelo com método de Brilho + Contraste + C. Gamma (5)	80	Validação: 20%
Modelo com método de Rotate (6)	80	Testes: 10%
Modelo com método de Resize + Flip + Flop (7)	80	
Modelo com método de Flip + Flop (8)	26	

Fonte: Os autores.

## Avaliação das plataformas por meio dos indicadores de desempenho

A **precisão**, o **recall** e a **mAP** são os métodos de avaliação utilizados para avaliar os modelos criados nas plataformas Custom Vision e Roboflow. A **Precisão** representa o número de casos corretos entre todos os casos disponíveis. Uma alta precisão indica que a anomalia está sendo identificada de maneira correta. O **Recall**, conseqüentemente, é o número de casos corretos entre todos os casos positivos. O modelo que apresenta um elevado recall está a identificar efetivamente o maior número de anomalias corretas. De mesmo modo, o **mAP** é o valor médio da precisão

média, ou seja, é a precisão obtida em vários níveis de recall em todas as classes (anomalias). As fórmulas dos indicadores de desempenho foram apresentadas na etapa 4 da Figura 2.

## RESULTADOS E DISCUSSÕES

As métricas fornecidas pelas plataformas Roboflow e Custom Vision apenas se restringiam à precisão, recall e mAP (Tabela 2). No Custom Vision, foi apresentado uma interface gráfica onde possibilitou definir o limite de probabilidade e de sobreposição, respectivamente definidos como 50% e 30%, conforme sugestão da plataforma. Os resultados da tabela 2 obedecem a esses hiperparâmetros.

O modelo que obteve o melhor resultado de precisão foi o “*Modelo com método de Flip + Flop (8)*” treinado com Yolo, alcançando 98,2 % de precisão (Figura 4). No entanto, apresentou probabilidade de reconhecimento de somente 25,0% na etapa de teste (Figura 6), evidenciando confusões de ninhos de concretagem e faquetas (Figura 8). Ao analisar o “*Modelo com método de contraste (3)*” com o treinamento a partir das redes ResNet e AlexNet, é visualizado o melhor desempenho de Recall entre todos os modelos, com 94,6% (Figura 5). De mesmo modo, examinando o mAP, o “*Modelo com método de Brilho + Contraste (4)*” treinado a partir das redes ResNet e AlexNet apresenta o melhor desempenho desse indicador, com 92,7% (Figura 5).

**Tabela 2: Resultados de treinamento dos modelos no Roboflow e Custom Vision**

Modelos	Roboflow (Yolo)			Custom Vision (AlexNet e ResNet)		
	Precisão	Recall	mAP	Precisão	Recall	mAP
Modelo com imagens originais (1)	35,0%	3,0%	4,0%	-	-	-
Modelo com método de Brilho (2)	62,0%	82,6%	78,1%	70,7%	76,3%	77,7%
Modelo com método de Contraste (3)	88,4%	48,3%	70,1%	67,3%	94,6%	91,5%
Modelo com método de Brilho + Contraste (4)	56,7%	64,1%	62,8%	63,8%	92,5%	92,7%
Modelo com método de Brilho + Contraste + C. Gamma (5)	87,3%	59,2%	67,8%	69,0%	74,1%	66,7%
Modelo com método de Rotate (6)	51,5%	37,8%	36,7%	48,1%	69,4%	59,5%
Modelo com método de Rotate + Flip + Flop (7)	32,5%	21,9%	18,3%	44,7%	51,5%	42,6%
Modelo com método de Flip + Flop (8)	98,2%	12,5%	19,5%	-	-	-

Fonte: Os autores.

Observa-se que os dados correspondentes à precisão e ao recall das redes AlexNet e ResNet são ligeiramente mais uniformes, quando comparados à Yolo. Em


contrapartida, visualiza-se da Figura 4 e Figura 5 uma tendência de decréscimo da performasse dos indicadores de recall e mAP a partir do modelo “Modelo com método de Brilho (2)” independentemente das redes analisadas, porém com a Resnet e AlexNet, no Custom Vision, apresentando melhores indicadores.

Durante a realização dos modelos, não foi possível o treinamento dos respectivos modelos nas redes AlexNet e ResNet: “Modelo com imagens originais (1)” e “Modelo com método de Flip + Flop (8)”. Algumas razões abaixo justificam essa dificuldade:

- O conjunto de dados original possui cerca de 26 imagens, sendo um número muito deficitário para a etapa de treinamento.
- O Custom Vision limita a etapa de treinamento com um pré-requisito de 15 imagens por tag. Devido às poucas variabilidades no conjunto de dados original e no dataset com imagens em que se aplicou as técnicas Flip + Flop, não foi possível gerar esse modelo.


Em termos gerais, os modelos em que se aplicou as técnicas de aumento de dados obtiveram resultados de indicadores mais expressivos, quando comparado ao modelo original treinado com Yolo. Essa constatação se dá não só devido às razões apresentadas acima, mas também aos resultados dos indicadores e probabilidade de reconhecimento.

**Figura 4 – Desempenho dos indicadores no Roboflow**



Fonte: Os autores.

**Figura 5 – Desempenho dos indicadores no Custom Vision**




Fonte: Os autores.

Os testes foram realizados utilizando um *dataset* correspondente a 10% do conjunto de dados do modelo respectivo. Entre os testes realizados, o modelo que obteve melhor probabilidade de reconhecimento foi o “Modelo com método de contraste (3)”



treinado a partir das redes ResNet e AlexNet, uma vez que conseguiu identificar corretamente pelo menos uma anomalia presente em cada imagem do conjunto teste (Figura 7). Observa-se também que o “Modelo com método de Brilho + Contraste + C. Gamma (5)” e o “Modelo com método de Brilho + Contraste (4)”, ambos treinado com Yolo, apresentaram probabilidade reconhecimento de 87,5% e 75,0%, respectivamente, demonstrando que o método de contraste possibilita um melhor reconhecimento das anomalias presente no conjunto de dados, seja aplicado individualmente ou não. Além disso, confusões a respeito de ninhos de concretagem sendo identificadas como armadura exposta e vice-versa, são possíveis causas para uma menor taxa de reconhecimento desses últimos modelos.

**Figura 6 – Probabilidade Reconhecimento dos modelos**




Fonte: Os autores.

**Figura 7 – Testes com o “Modelo com método de contraste (3)” treinado com ResNet e AlexNet**



Fonte: Os autores.

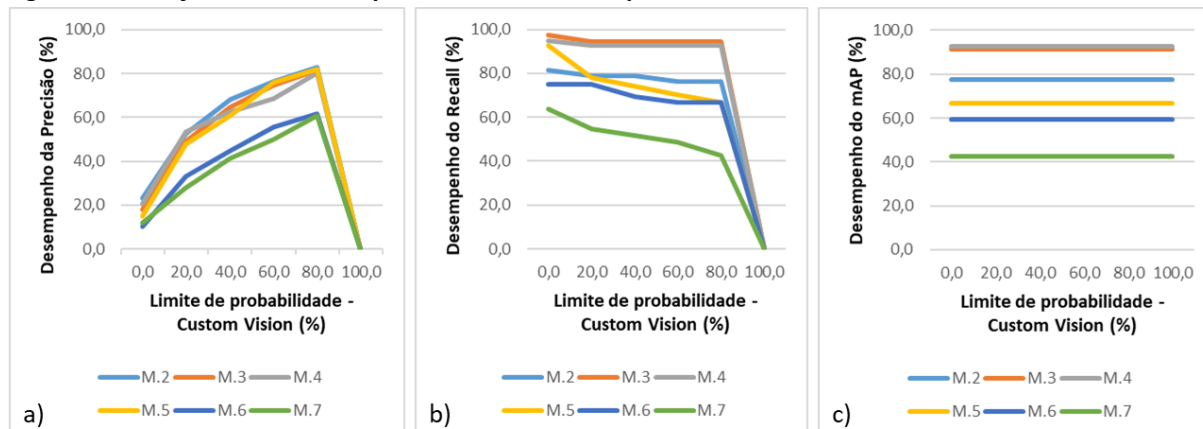
**Figura 8 – Testes com o “Modelo com método de Flip + Flop (8)” treinado com Yolo**



Fonte: Os autores.

Devido às diferenças entre as plataformas não foi possível controlar os hiperparâmetros do Roboflow. No entanto, no Custom Vision foi possível variar o limite de probabilidade e, portanto, visualizar como se deu o desempenho dos indicadores. Averiguando a Precisão, observou-se nos modelos um crescimento de desempenho que atingiu o seu valor máximo em 80% do limite de probabilidade e uma redução acentuada posteriormente (Figura 9a). Por outro lado, o recall teve seu valor máximo em 0% do hiperparâmetro, tendo uma leve queda do índice nos primeiros 20% de variação, mantendo-se ligeiramente constante até os 80%, quando também apresentou uma queda acentuada de desempenho (Figura 9b). Já o mAP, manteve-se constante para qualquer valor de variação do hiperparâmetro (Figura 9c).

**Figura 9 – Variações do limite de probabilidade e desempenho dos modelos no Custom Vision**



Fonte: Os autores.

Analisando as contribuições deste estudo, observa-se que houve um avanço no uso e desenvolvimento de tecnologias voltadas a inspeção, sobretudo no que se refere ao reconhecimento automatizado de anomalias em paredes de fachadas. [11] concentrou-se na construção de uma metodologia de ajuste de hiperparâmetros de aumento de dados em AP para classificação de imagens de construção civil, como reconhecimento de vegetação em análise de fachadas e estruturas de telhados, obtendo um resultado de 95,6% de precisão logo na etapa teste do primeiro estudo de caso para uma determinada configuração recomendada. Embora apresente um conjunto de dados com características e qualidades distintas, a presente pesquisa corrobora com o estudo no que se refere à necessidade de uma análise mais criteriosa

a respeito das transformações, uma vez que se constata que nem todas as técnicas utilizadas, independente das redes treinadas, apresentaram resultados satisfatórios. Diferentemente de [6], no qual apresenta o desenvolvimento de uma arquitetura baseada em CNN para detecção de fissuras em superfícies de concreto com precisão máxima de 99,8%, [5] apresenta uma abordagem de Aprendizado por Transferência proposta para o modelo de arquitetura de AlexNet aplicado na detecção de rachaduras na superfície do concreto com 99,9% de precisão. Este trabalho apresenta em seu melhor modelo 67,3% de precisão, evidenciando a necessidade de um conjunto de dados mais extenso no treinamento dos modelos. No entanto, quando comparado ao trabalho de [9], que buscou identificar e classificar quatro defeitos construtivos em fachadas e obteve em seu melhor modelo 51,8% de precisão, o modelo proposto neste trabalho teve um considerável avanço de 15,5%, muito possivelmente devido a utilização de um número maior de técnicas de DA no treinamento.

## CONCLUSÃO

Esse trabalho teve como objetivo principal analisar os impactos do uso de técnicas de DA para o aprimoramento de modelos de AM, capazes de auxiliar no reconhecimento de anomalias construtivas em fachadas de parede de concreto. Para isso, utilizou duas plataformas com redes neurais distintas, como Roboflow e Custom Vision. O modelo que obteve melhor probabilidade de reconhecimento foi o “*Modelo com método de contraste (3)*” treinado com AlexNet e ResNet, apresentando 67,3% de precisão, 94,6% de Recall e 91,5% de mAP. Os resultados possibilitam chegar nas seguintes conclusões:

- As técnicas de aumento de dados são capazes de contribuir com o aumento de indicadores de desempenho na realização dos modelos de AM, especialmente quando se faz uma análise a respeito de quais técnicas e combinações utilizar;
- Para o treinamento dos modelos ML, conjunto de dados mais extensos possibilitam melhores resultados de indicadores de desempenho;
- Para imagens que possuem muitas informações, como é o caso do conjunto de dados utilizado, pode haver influência negativa nos indicadores dos modelos criados. Por isso, plataformas como Roboflow, em que permite mais recursos na anotação dos objetos quando comparada ao Custom Vision, possui melhores indicadores de precisão;
- Anomalias construtivas do tipo fissura é um enorme desafio para a detecção automatizada para os modelos ML, uma vez que necessitam ter imagens muito próximas do objeto alvo. Além disso, podem ser facilmente confundidas com manchas superficiais nas fachadas dos edifícios;

Espera-se, futuramente, que se possa utilizar novas técnicas de DA para verificar se há uma manutenção na melhora dos indicadores de desempenho dos modelos AM, bem como um conjunto de dados mais extenso, com objetos mais evidentes nas imagens, a fim de se ter uma melhor comparação a respeito dos modelos aumentados com relação ao modelo treinado com imagens originais.

## AGRADECIMENTOS

Os autores agradecem as agências de fomento FAPESB, CAPES e CNPq.

## REFERÊNCIAS

- [1] SILVA, A.S.; COSTA, D. B. **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.
- [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] BARBOSA, R. L. de B.. **Sistema de Deep Learning para detecção de trincas em concreto**. [s.l.] Universidade de Pernambuco, 2023.
- [4] ALI, S. B. *et al.* **Wall crack detection using transfer learning-based CNN models**. In: 2020 IEEE 17th India Council International Conference (INDICON). IEEE, 2020. p. 1-7.
- [5] ISLAM, M. M. *et al.* **CNN based on transfer learning models using data augmentation and transformation for detection of concrete crack**. Algorithms, v. 15, n. 8, p. 287, 2022.
- [6] KIM, B. *et al.* **Surface crack detection using deep learning with shallow CNN architecture for enhanced computation**. Neural Computing and Applications, v. 33, p. 9289-9305, 2021.
- [7] KAUFMAN, D. **A inteligência artificial irá suplantará a inteligência humana?**. ESTAÇÃO DAS LETRAS E CORES EDI, 2019.
- [8] SHORTEN, C.; KHOSHGOFTAAR, T. M.; FURHT, B. **Text data augmentation for deep learning**. Journal of big Data, v. 8, p. 1-34, 2021.
- [9] SILVA, A. S.; MELO, Roseneia Rodrigues Santos; COSTA, Dayana Bastos. **Automated facade inspection: Application and challenge in using Artificial Intelligence for construction defect recognition**. In: XX International Conference on Building Pathology and Constructions Repair (CINPAR), p. XXXX, 2024.
- [10] OTTONI, A. L. C. *et al.* **Métodos para recomendação de hiperparâmetros de aprendizado de máquina na classificação de imagens da construção civil**. 2022.
- [11] OTTONI, A. L. C.; NOVO, M. S. **A deep learning approach to vegetation images recognition in buildings: a hyperparameter tuning case study**. IEEE Latin America Transactions, v. 19, n. 12, p. 2062-2070, 2021.
- [12] GUO, J. *et al.* **Façade defects classification from imbalanced dataset using meta learning-based convolutional neural network**. Computer-Aided Civil and Infrastructure Engineering, v. 35, n. 12, p. 1403-1418, 2020.
- [13] CHENG, J.C. AND WANG, M. **Automated detection of sewer pipe defects in closed-circuit television images using deep learning techniques**. Automation in Construction, 95, p.155-171, 2018.
- [14] LEE, K., LEE, S., & KIM, H. Y. (2022). **Bounding-box object augmentation with random transformations for automated defect detection in residential building façades**. Automation in Construction, 135, 104138. <https://doi.org/10.1016/j.autcon.2022.104138>
- [15] MAHARANA, K.; MONDAL, Surajit; NEMADE, Bhushankumar. **A review: Data pre-processing and data augmentation techniques**. Global Transitions Proceedings, v. 3, n. 1, p. 91-99, 2022.
- [16] OTTONI, A.L.C., DE AMORIM, R.M., NOVO, M.S. *et al.* **Tuning of data augmentation hyperparameters in deep learning to building construction image classification with small datasets**. Int. J. Mach. Learn. & Cyber. 14, 171–186 (2022). <https://doi.org/10.1007/s13042-022-01555-1>.
- [17] KIM, D.; CHOE, S.; ZHANG, S. **Recognition of adherent polychaetes on oysters and scallops using Microsoft Azure Custom Vision**. Electronic Research Archive, v. 31, n. 3, p. 1691-1709, 2023.

- [18] LIAKHOVICH, Olga; MBEMBA, Claudius. **Food classification with custom vision service**. 2017.
- [19] DANIEL, E. R. **Wildfire smoke detection with computer vision**. arXiv preprint arXiv:2301.05070, 2023.
- [20] SHANDILYA, Shishir Kumar *et al.* **YOLO-based segmented dataset for drone vs. bird detection for deep and machine learning algorithms**. Data in Brief, v. 50, p. 109355, 2023.
- [21] SILVA, A. S. GONZAGA, L.G., MELO, R.R.S, COSTA, D.B. Modelo de aprendizado de máquina para inspeção automatizada de fachadas de paredes de concreto. **SIMPÓSIO BRASILEIRO DE GESTÃO E ECONOMIA DA CONSTRUÇÃO**, v. 13, p. 1-9, 2023.
- [22] TAYLOR, L.; NITSCHKE, G. **Improving deep learning with generic data augmentation**. In: 2018 IEEE symposium series on computational intelligence (SSCI). IEEE, 2018. p. 1542-1547.
- [23] MEDEIROS, L. C. **Aplicação de Aprendizado Profundo Na Classificação de Imagens de Patologias Da Construção Civil: Análise de Aumento de Dados Para Bancos de Dados Desbalanceados**. 2023. Tese (Bacharelado em Ciências exatas e tecnológicas) - Universidade Federal do Recôncavo da Bahia, Cruz das Almas, 2023.