

Desenvolvimento de um Sistema de Visão Computacional para Inspeção de Rachaduras em Edificações com um Robô Móvel

Kevin L. Santos¹, André L. C. Ottoni²

RAI/CETEC/UFRB, Cruz das Almas, BA

Marcos S. Oliveira³

DEMAT/UFSJ, São João del-Rei, MG

Monitorar a saúde das infraestruturas de engenharia civil, incluindo a detecção precoce de rachaduras, é crucial para garantir segurança e durabilidade [6]. No entanto, a detecção e localização de rachaduras são processos dispendiosos, demorados e suscetíveis a falhas humanas [1]. A indústria da construção 4.0 surge como uma solução, integrando sistemas avançados de produção industrial e tecnologias digitais para remodelar o ciclo de construção, operação e manutenção [2]. Dentro desse cenário, a Inteligência Artificial (IA) desempenha um papel crucial, especialmente com o uso de métodos de *Machine Learning* em sistemas de visão artificial [4]. Isso permite que o computador aprenda com os dados com pouca ou nenhuma intervenção humana [3].

Com o avanço da visão computacional e da robótica móvel, cresce a necessidade por aprimoramentos técnicos, ressaltando o papel crucial do *Deep Learning* [5]. Várias propostas na literatura visam a construção de robôs autônomos com visão computacional, direcionados à automatização da inspeção na construção civil, como evidenciado em estudos como [7–9]. Assim, este trabalho tem como objetivo a criação de um sistema de visão computacional com inteligência artificial aplicável em um robô móvel de baixo custo, visando a inspeção de rachaduras em edificações.

A metodologia deste trabalho foi desenvolvida em três etapas distintas: (1) seleção do *dataset*; (2) planejamento de experimentos na plataforma Edge Impulse; e (3) análise de resultados. Na primeira etapa, o conjunto de dados do *Concrete Crack Images for Classification*⁴ foi escolhido. A partir disso, foram selecionadas 16.000 imagens, divididas igualmente entre as duas classes (paredes e rachaduras), reservando 20% dos dados para os experimentos de teste. Em seguida, a plataforma online Edge Impulse foi empregada, fornecendo uma variedade de algoritmos de *machine learning* já implementados. O treinamento começou com o uso da rede neural convolucional *MobileNet*, disponível na plataforma Edge Impulse com pesos pré-treinados no *dataset ImageNet*.

Com o objetivo de encontrar o melhor modelo para classificação, foram realizados treinamentos com diferentes configurações. A Tabela 1 apresenta os resultados dos experimentos com diferentes combinações de hiperparâmetros.

Tabela 1: Resultados.

Modelo	Arquitetura	Nº de imagens	Ciclos	TA	Acurácia
1	MobileNetV2 96x96 0.35	3000	15	0,0005	98,70%
2	MobileNetV2 96x96 0.35	16000	15	0,0020	99,62%
3	MobileNetV1 96x96 0.25	16000	20	0,0030	99,70%

¹kevinluis81@gmail.com

²andre.ottoni@ufrb.edu.br

³mso@ufsj.edu.br

⁴Link do dataset: <https://data.mendeley.com/datasets/5y9wdsg2zt/2>

Ao analisar os dados da Tabela 1, destaca-se o desempenho do modelo 3, obtendo uma acurácia de 99,70%. Este resultado ressalta a eficácia e a confiabilidade desse modelo em relação aos demais avaliados. A análise revela que a arquitetura *MobileNetV1 96x96 0.25*, com uma taxa de aprendizado (TA) de 0,0030 e 20 ciclos de treinamento, apresentou um desempenho superior na classificação durante os testes. De um total de 1600 imagens da classe rachadura, a configuração selecionada acertou 1595 amostras no teste, demonstrando alta capacidade do modelo treinado para o reconhecimento dessa manifestação patológica da construção.

Em trabalhos futuros, planeja-se aprimorar o modelo por meio da exploração de diversas combinações de hiperparâmetros. Além disso, pretende-se desenvolver um protótipo de um robô móvel, desde a concepção do seu design 3D até a impressão e montagem de seus componentes. Esse protótipo será utilizado para realizar testes em ambientes reais, visando avaliar a eficácia do modelo na detecção e classificação de rachaduras em edificações.

Agradecimentos

Os autores agradecem o apoio do Edital PIBITI 2/2023/PPGCI/UFRB, UFRB e UFSJ.

Referências

- [1] L. Ali et al. “Bibliometric Analysis and Review of Deep Learning-Based Crack Detection Literature Published between 2010 and 2022”. Em: **Buildings** 12.4 (2022). DOI: 10.3390/buildings12040432.
- [2] S. K. Baduge et al. “Artificial intelligence and smart vision for building and construction 4.0: Machine and deep learning methods and applications”. Em: **Automation in Construction** 141 (2022). DOI: 10.1016/j.autcon.2022.104440.
- [3] M. Massao-Hanaoka e C. E. Rubio-Mercedes. “Classificação e Agrupamento de Dados Utilizando Conceitos dos Algoritmos k-NN e k-means”. Em: **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics** 10.1 (2023).
- [4] A. L. C. Ottoni, M. S. Novo e D. B. Costa. “Deep Learning for vision systems in Construction 4.0: a systematic review”. Em: **Signal, Image and Video Processing** 17.5 (2023), pp. 1821–1829. DOI: 10.1007/s11760-022-02393-y.
- [5] A. L. C. Ottoni et al. “Tuning of data augmentation hyperparameters in deep learning to building construction image classification with small datasets”. Em: **International Journal of Machine Learning and Cybernetics** 14.1 (2023), pp. 171–186.
- [6] S. Pennada et al. “Threshold-Based BRISQUE-Assisted Deep Learning for Enhancing Crack Detection in Concrete Structures”. Em: **Journal of Imaging** 9.10 (2023). DOI: 10.3390/jimaging9100218.
- [7] A. Sheta e S. A. Mokhtar. “Autonomous robot system for pavement crack inspection based CNN model”. Em: **Journal of Theoretical and Applied Information Technology** 100.16 (2022), pp. 5119–5128.
- [8] S. K. Sinha e P. W. Fieguth. “Automated detection of cracks in buried concrete pipe images”. Em: **Automation in Construction** 15.1 (2006), pp. 58–72. DOI: 10.1016/j.autcon.2005.02.006.
- [9] S. N. Yu, J. H. Jang e C. S. Han. “Auto inspection system using a mobile robot for detecting concrete cracks in a tunnel”. Em: **Automation in Construction** 16.3 (2007), pp. 255–261. DOI: 10.1016/j.autcon.2006.05.003.