

Detecção de Elementos em Construções Históricas da Cidade do Serro com Aprendizado Profundo

Lara Toledo Cordeiro Ottoni
Departamento de Automação Industrial
Instituto Federal de Minas Gerais (IFMG)
Ouro Preto, Brasil
lara.ottoni@ifmg.edu.br

André Luiz Carvalho Ottoni
Departamento de Computação
Universidade Federal de Ouro Preto (UFOP)
Ouro Preto, Brasil
andre.ottoni@ufop.edu.br

Abstract—Cultural heritage plays a fundamental role in preserving a society's identity and history, encompassing architectural, social, and artistic values. However, its conservation faces challenges such as natural deterioration, human actions, and the inefficiency of traditional inspection methods. This study proposes a deep learning-based approach to assist in the automated detection of architectural elements in historical buildings in the city of Serro, Minas Gerais, Brazil. A Convolutional Neural Network (CNN) was trained using the ImageOP dataset, which contains over 1600 high-resolution images of monuments in Ouro Preto. Through simulated experiments, the best network architecture was identified, and practical tests were conducted in Serro to evaluate the system's accuracy in recognizing architectural elements such as pediments, towers, windows, doors, and churches. The results show that the best-performing architecture was MobileNet V2 (160x160 0,50), achieving an accuracy of 96,78%. The practical tests showed promising results, demonstrating the model's generalization capability by achieving accuracies above 84% in identifying monuments in the historical city of Serro using computer vision via smartphone.

Index Terms—Deep Learning, Computer Vision, Cultural Heritage, Architectural Element Detection, Image Processing.

I. INTRODUÇÃO

O patrimônio cultural é uma expressão da identidade e da história de uma sociedade, representando valores arquitetônicos, sociais e artísticos de diferentes períodos. Sua preservação é essencial para manter a memória coletiva e garantir que futuras gerações possam compreender e apreciar o passado [1]. No Brasil as cidades históricas abrigam construções de grande relevância, que necessitam de constante monitoramento e conservação [2].

No entanto, a preservação desses bens enfrenta desafios, especialmente devido ao desgaste natural, ações humanas e a falta de métodos eficazes para identificação e manutenção dos elementos construtivos [3]. Além disso, a escassez de mão de obra especializada e a dificuldade de monitoramento eficiente tornam a manutenção dessas edificações um processo complexo e, muitas vezes, custoso. Métodos tradicionais de inspeção podem ser demorados e subjetivos, tornando necessária a adoção de abordagens mais eficientes e automatizadas para a identificação e análise dos elementos arquitetônicos [4].

Nesse contexto, a inteligência computacional tem se destacado como uma ferramenta promissora para auxiliar na

preservação do patrimônio cultural [5] [6]. Técnicas como visão computacional e aprendizado profundo já são utilizadas em diversas aplicações, como a reconstrução digital de monumentos [7], a detecção de danos estruturais [8] e a classificação de estilos arquitetônicos [9]. O uso dessas tecnologias permite um monitoramento mais preciso e ágil das construções históricas, facilitando a tomada de decisões sobre intervenções e restaurações [3].

Além da preservação física do patrimônio, é essencial garantir sua digitalização para a conservação do conhecimento e das informações associadas [1]. A preservação física pode ser realizada por meio de técnicas de conservação e restauração, enquanto a digitalização permite armazenar e difundir seu valor cultural. Dessa forma, a preservação do patrimônio cultural desempenha um papel crucial na manutenção da memória cultural, na acessibilidade, na valorização da diversidade ambiental e nos benefícios econômicos [1].

Este trabalho tem como objetivo desenvolver uma ferramenta baseada em aprendizado profundo para auxiliar na digitalização automática de elementos construtivos presentes em edificações históricas do Serro, como frontões, torres, janelas, portas e igrejas. Para isso, foi utilizada uma rede neural convolucional (CNN) treinada com a base de dados ImageOP, composta por mais de 1600 imagens de monumentos da cidade de Ouro Preto. Após a definição da arquitetura mais adequada para o modelo, foram realizados testes práticos no município do Serro, com o intuito de avaliar a eficácia do sistema na identificação dos elementos arquitetônicos. Essa etapa é fundamental para os processos de conservação e preservação do patrimônio histórico, pois, a partir do reconhecimento dos elementos, será possível realizar, por exemplo, a classificação de patologias associadas a essas estruturas.

Este artigo está organizado da seguinte forma: a Seção II apresenta um panorama histórico e arquitetônico da cidade do Serro; a Seção III descreve a metodologia adotada para o desenvolvimento do trabalho; a Seção IV apresenta os resultados obtidos nos testes simulados e práticos; por fim, a Seção V traz as considerações finais sobre o estudo realizado.

II. CIDADE HISTÓRICA DO SERRO

O patrimônio cultural representa bens materiais e imateriais que possuem importância histórica, artística, social e cultural

para uma comunidade. Ele pode incluir edificações, monumentos, festas, tradições, músicas e saberes transmitidos ao longo do tempo [10]. O Instituto do Patrimônio Histórico e Artístico Nacional (IPHAN)¹ é o órgão brasileiro responsável pela preservação do patrimônio cultural do país, atuando na identificação, tombamento e proteção de bens históricos e culturais. No âmbito internacional, a Organização das Nações Unidas para a Educação, a Ciência e a Cultura (UNESCO)² também desempenha um papel fundamental na preservação do patrimônio, promovendo o reconhecimento de bens culturais e naturais como Patrimônio Mundial, incentivando sua conservação e valorização.

A cidade do Serro, localizada em Minas Gerais, é um importante patrimônio cultural brasileiro devido ao seu conjunto arquitetônico colonial e suas tradições culturais preservadas ao longo dos séculos [11]. Fundada no período colonial, a cidade desempenhou um papel essencial no ciclo do ouro e na formação histórica do estado. Seu centro histórico é reconhecido pelo IPHAN como Patrimônio Nacional, destacando-se por suas igrejas, casarões e festas populares [10]. Além disso, Serro é famoso pela produção do queijo artesanal, que também é um elemento de identidade cultural e patrimônio imaterial da região. A preservação da cidade é essencial para manter viva a memória histórica e cultural do Brasil [12].

O povoado que originou a cidade do Serro foi fundado em 1701, quando bandeirantes chegaram à região em busca de ouro e outras riquezas minerais [13]. O local recebeu o nome de “Arraial do Ribeirão das Minas de Santo Antônio do Bom Retiro do Serro do Frio”, devido à sua geografia montanhosa e às temperaturas amenas [10]. Em 1714, o povoado foi elevado à categoria de vila e passou a se chamar Vila do Príncipe. Somente em 1838, já no período imperial, o local foi reconhecido como cidade e recebeu o nome de Serro [13]. Inicialmente voltada para a mineração, a economia do Serro se diversificou ao longo do século XVIII, tornando-se um importante centro comercial e cultural, e preserva até hoje ca-



Fig. 1. Cidade histórica do Serro (MG) - Patrimônio Histórico e Artístico Nacional.

¹<http://portal.iphan.gov.br/>

²<https://www.unesco.org/en>

racterísticas desse período, especialmente na produção de leite e queijo [10]. A Figura 1 apresenta uma fotografia do centro histórico da cidade.

A cidade é marcada por casarões dos séculos XVIII e XIX, além de igrejas construídas nos estilos barroco e rococó. Entre os principais monumentos, destacam-se a Igreja de Nossa Senhora do Rosário (Figura 2(a)), a Igreja de Nossa Senhora do Carmo (Figura 2(b)), a Igreja de Santa Rita (Figura 2(c)), a Igreja Matriz de Nossa Senhora da Conceição (Figura 2(d)), a Igreja do Senhor Bom Jesus de Matozinhos (Figura 2(e)), a Casa do Barão (atual Escola Estadual Ministro Edmundo Lins (Figura 2(f)), o Museu Regional Casa dos Ottoni (Figura 2(g)) e a Prefeitura do Serro (Figura 2(h)).



Fig. 2. Monumentos históricos da cidade Serro (MG) (a) Igreja de Nossa Senhora do Rosário (b) Igreja de Nossa Senhora do Carmo (c) Igreja de Santa Rita (d) Igreja Matriz de Nossa Senhora da Conceição (e) Igreja do Senhor Bom Jesus de Matozinhos, (f) Casa do Barão, (g) Museu Regional Casa dos Ottoni e (h) Prefeitura do Serro.




Fig. 3. Fluxograma da metodologia proposta para os experimentos simulados e práticos.

III. METODOLOGIA

Esta seção apresenta a metodologia proposta para a abordagem de detecção de elementos construções históricas usando aprendizado profundo, conforme Figura 3. O cenário de aplicação foi a cidade do Serro (MG), tendo em vista a relevância do uso do aprendizado profundo aplicado ao patrimônio cultural. Inicialmente, foram realizados experimentos simulados para uma investigação quanto a melhor arquitetura da rede neural convolucional para o uso de visão computacional com *smartphone*. Dentre as opções, foram testadas as variações da *MobileNet V1* e *V2*. Após obter a melhor arquitetura para o conjunto de dados do ImageOP, realizou-se experimentos práticos na cidade do Serro, com o objetivo de testar a capacidade de generalização do modelo obtido.

A seguir, serão apresentados mais informações sobre a base de dados utilizada, ImageOP. Além disso, são apresentadas as etapas dos experimentos simulados e práticos.

A. Base de Dados

A escolha da base de dados é uma etapa importante para um sistema de aprendizado profundo. Nesse sentido, utilizou-se a base de dados ImageOP [2]. O ImageOP é um conjunto de imagens da cidade de Ouro Preto, Patrimônio Mundial reconhecido pela UNESCO em 1980.



Fig. 4. Classes da base de dados ImageOP: (i) Igreja, (ii) Frontão, (iii) Janela, (iv) Porta e (v) Torre. Exemplo da Igreja Nossa Senhora do Carmo de Ouro Preto MG.

A base de dados, contém um conjunto de fotografias de alta resolução com 1613 imagens de fachadas referentes à 32 monumentos religiosos do século XVII e XVIII. A base de dados foi dividida em 5 classes: (i) Igreja, (ii) Frontão, (iii) Janela, (iv) Porta e (v) Torre. Na Figura 4 é possível observar a divisão das classes por meio de um exemplo da faxada da Igreja Nossa Senhora do Carmo de Ouro Preto.

Na Figura 5, estão exemplos da diversidade dos elementos



Fig. 5. Exemplos das classes da base de dados ImageOP [2].

da fachada dos monumentos religiosos do estilo barroco e as cinco classes consideradas. O *dataset* está disponível no repositório *Mendeley Data*³.

B. Experimentos Simulados

Os experimentos simulados correspondem à primeira etapa da metodologia proposta, apresentada na Figura 3, na qual se investiga a arquitetura da Rede Neural Convolutiva. As arquiteturas *MobileNets* foram desenvolvidas com o objetivo de viabilizar a execução de redes profundas em dispositivos móveis, oferecendo um bom equilíbrio entre desempenho e leveza. Diante disso, realizou-se uma comparação entre diferentes variações das arquiteturas *MobileNet V1* [14] e *MobileNet V2* [15].

A arquitetura da *MobileNet V1* é apresentada na Tabela I. Em que consiste em uma arquitetura com 28 camadas convolucionais e camada totalmente conectada, finalizando com a função de ativação softmax. A *MobileNet V1* utiliza operações convolucionais separáveis em profundidade, conforme mostrado na Figura 6, fragmentando a convolução tradicional em duas fases distintas. A primeira, chamada de Convolução em Profundidade (*depthwise convolution*), aplica filtros convolucionais de forma independente a cada canal da imagem de entrada. Na sequência, a segunda fase, denominada Convolução Pontual (*pointwise convolution*), combina linearmente os resultados da etapa anterior, levando em conta todos os canais da imagem [14], [16].

TABLE I
ARQUITETURA DA MOBILENETV1

Tipo	Formato do Filtro
Conv / s2	$3 \times 3 \times 3 \rightarrow 32$
Conv dw / s1	$3 \times 3 \times 32$ dw
Conv / s1	$1 \times 1 \times 32 \rightarrow 64$
Conv dw / s2	$3 \times 3 \times 64$ dw
Conv / s1	$1 \times 1 \times 64 \rightarrow 128$
Conv dw / s1	$3 \times 3 \times 128$ dw
Conv / s1	$1 \times 1 \times 128 \rightarrow 128$
Conv dw / s2	$3 \times 3 \times 128$ dw
Conv / s1	$1 \times 1 \times 128 \rightarrow 256$
Conv dw / s1	$3 \times 3 \times 256$ dw
Conv / s1	$1 \times 1 \times 256 \rightarrow 256$
Conv dw / s2	$3 \times 3 \times 256$ dw
Conv / s1	$1 \times 1 \times 256 \rightarrow 512$
Repetir 5 vezes:	
Conv dw / s1	$3 \times 3 \times 512$ dw
Conv / s1	$1 \times 1 \times 512 \rightarrow 512$
Continua...	
Conv dw / s2	$3 \times 3 \times 512$ dw
Conv / s1	$1 \times 1 \times 512 \rightarrow 1024$
Conv dw / s2	$3 \times 3 \times 1024$ dw
Conv / s1	$1 \times 1 \times 1024 \rightarrow 1024$
Avg Pool / s1	Pool 7×7
FC / s1	$1024 \rightarrow 1000$
Softmax / s1	Classificador

A arquitetura da *MobileNet V2* trouxe aprimoramentos para melhorar o desempenho do modelo. Na Tabela II, pode-se observar a arquitetura simplificada da *MobileNet V2* [15]. Nessa atualização, foram incorporados blocos residuais (*bottleneck*),




Fig. 6. Camada Convolutiva Separável em Profundidade. Adaptado de [17].

os quais são formados por três camadas principais: (1) camada de expansão, (2) camada de convolução em profundidade e (3) camada de projeção [15], [16], conforme pode ser visto na Figura 7.

TABLE II
ARQUITETURA MOBILENETV2 (SIMPLIFICADA)

Entrada	Operação
$224^2 \times 3$	conv2d
$112^2 \times 32$	bottleneck
$112^2 \times 16$	bottleneck
$56^2 \times 24$	bottleneck
$28^2 \times 32$	bottleneck
$14^2 \times 64$	bottleneck
$14^2 \times 96$	bottleneck
$7^2 \times 160$	bottleneck
$7^2 \times 320$	conv2d 1×1
$7^2 \times 1280$	avgpool 7×7
$1 \times 1 \times 1280$	conv2d 1×1

Como ambiente de simulação foi utilizado o *software Edge Impulse*⁴ [18], uma plataforma que facilita o uso de inteligência computacional embarcada. As arquiteturas estão disponíveis na plataforma com pesos pré-treinados no *dataset* ImageNet.

Desta forma, os experimentos da primeira etapa da metodologia consistem na investigação das combinações entre diferentes tipos de arquitetura e dos parâmetros relacionados às dimensões de entrada e ao valor de alpha. A base de dados utilizada, ImageOP, foi dividida em 60% para treinamento, 20% para validação e 20% para teste, para este trabalho não foram utilizadas técnicas de aumento de dados. Os resultados foram analisados com base na acurácia, calculada pela Equação (1).

³ImageOP dataset: <https://data.mendeley.com/datasets/hdz96zts8j/1>

⁴<https://edgeimpulse.com/>




Fig. 7. Camada Blocos Residuais (Bottleneck). Adaptado de [17].

$$\text{Acurácia} = \frac{\text{Predições Corretas}}{\text{Número total de amostras}} \times 100 \quad (1)$$

As dimensões de entrada foram configuradas conforme as resoluções permitidas pela plataforma *Edge Impulse*. Para as arquiteturas MobileNet V1 e MobileNet V2, as duas opções disponíveis eram 160×160 e 96×96.

O parâmetro α (α), também conhecido como *width multiplier*, é um hiperparâmetro utilizado na arquitetura MobileNet para controlar a largura da rede, reduzindo uniformemente o número de canais em cada camada. Especificamente, para um valor de $\alpha \in (0, 1]$, o número de canais de entrada M e de saída N em uma camada convolucional são escalados para αM e αN , respectivamente. Essa redução tem como efeito colateral a diminuição do custo computacional e do número total de parâmetros da rede, possibilitando a geração de modelos menores, mais rápidos e com menor consumo de recursos [14]. No Edge Impulse, as variações de α disponíveis para seleção foram, para a arquitetura V1: 0,10, 0,20, 0,25, 0,35, e para a arquitetura V2: 0,05, 0,10, 0,35, 0,50, 0,75 e 1,00. Desta forma, foram avaliadas todas as combinações que a plataforma Edge Impulse oferece.

C. Experimentos Práticos

Após a definição da arquitetura da CNN, a etapa seguinte consistiu na realização de testes práticos na cidade do Serro

com *smartphone*. Conforme ilustrado na Figura 3, a utilização do *QR Code* gerado pelo Edge Impulse permitiu o uso do sistema de visão computacional embarcado em um dispositivo móvel.

Os testes foram conduzidos em oito monumentos históricos do Serro, incluindo a Igreja N. S. da Conceição, Igreja N. S. do Carmo, Igreja N. S. do Rosário, Igreja Santa Rita, Prédio da Prefeitura, Museu Regional Casa dos Ottoni e a Casa do Barão (atual Escola Estadual Ministro Edmundo Lins).

Durante os experimentos, o dispositivo móvel foi direcionado para os elementos arquitetônicos, conforme ilustrado na Figura 3. Nas edificações religiosas, foram analisadas cinco classes: igreja, torre, frontão, porta e janela. Já nas construções históricas não religiosas, a avaliação considerou apenas portas e janelas.

IV. RESULTADOS

Nesta seção serão apresentados os resultados obtidos com a metodologia proposta na Seção III. Inicialmente serão apresentados os resultados para os testes simulados e em seguida os resultados para os testes práticos.

A. Resultados dos Experimentos Simulados

Nos experimentos simulados realizou-se uma investigação quanto à arquitetura neural. Tendo em vista que foram utilizadas 10 arquiteturas, sendo quatro variações da *MobileNet V1* e seis tipos da *MobileNet V2*.

Na Tabela III são apresentados os resultados para os experimentos simulados em termos da Acurácia (%). Pode-se observar que a arquitetura que obteve um melhor desempenho para base de dados ImageOP foi a *MobileNet V2* com dimensões de entrada 160×160 e valor de α igual a 0,50; obtendo uma acurácia de validação no valor de 96,78%.

TABLE III
RESULTADOS DOS VALORES DE ACURÁCIA DE TESTE EM % DAS DIFERENTES ARQUITETURAS TESTADAS.

Arquitetura	Dimensões da Entrada	Alpha	Acurácia (%)
MobileNet v1	96×96	0,10	56,27
MobileNet v1	96×96	0,20	69,77
MobileNet v1	96×96	0,25	84,24
MobileNet v1	160×160	0,35	94,50
MobileNet v2	96×96	0,05	81,99
MobileNet v2	96×96	0,10	87,78
MobileNet v2	96×96	0,35	92,60
MobileNet v2	160×160	0,50	96,78
MobileNet v2	160×160	0,75	95,50
MobileNet v2	160×160	1,00	93,89

B. Resultados dos Experimentos Práticos

Após a definição da melhor arquitetura neural, foi então realizado testes práticos na cidade do Serro. Para esta etapa foi utilizado o QR Code disponibilizado pelo software Edge Impulse para o uso de *smartphone*. Conforme mostrado na Figura 8, o processo consistia em apontar o celular para os elementos construtivos (torre, janela, porta, frontão e igreja) e verificar a porcentagem e acerto ou erro na classificação.



Fig. 8. Processo de classificação utilizando o celular.

Na Figura 9, é possível observar algumas capturas de telas feitas do celular enquanto foi realizado a classificação. Desta forma, é possível verificar a classificação de igreja, torre, porta, frontão e janela.




Fig. 9. Captura de tela do celular ao realizar a classificação do elemento pelo Edge Impulse.

Ao final dos experimentos práticos, os dados foram coletados e calculadas as taxas de acurácia para cada monumento. Conforme pode-se observar na Tabela IV, os resultados foram satisfatórios, sendo que as imagens dos testes práticos não foram "vistas" pelo treinamento da CNN utilizada. Portanto, pode-se dizer que a rede neural conseguiu generalizar as características de cada classe e foi possível realizar essa

aplicação em com dados distintos.

TABLE IV
TABELA COM OS RESULTADOS DO TESTE PRÁTICO UTILIZANDO CELULAR.

Monumento Histórico	Acurácia (%)
Igreja N. S. da Conceição	88,00
Igreja N. S. do Carmo	100,00
Igreja Sta. Rita	100,00
Igreja N. S. do Rosário	90,00
Igreja do Matosinhos	95,00
Prefeitura	86,95
Museu Casa dos Ottoni	100,00
Casa do Barão	84,61

V. CONCLUSÃO

A preservação do patrimônio cultural é essencial para manter viva a memória histórica e arquitetônica das cidades coloniais. No entanto, os desafios relacionados à inspeção manual e à conservação dessas edificações evidenciam a necessidade de soluções automatizadas e eficientes. Neste estudo, foi proposto o uso de aprendizado profundo para a identificação de elementos arquitetônicos em construções históricas do Serro, utilizando a base de dados ImageOP.

Os experimentos realizados demonstraram que a arquitetura *MobileNet V2* com entrada de 160×160 e α de 0,50 apresentou o melhor desempenho, alcançando uma acurácia de 96,78% na validação. A partir dessa configuração, foram conduzidos testes práticos na cidade do Serro, nos quais o modelo mostrou capacidade satisfatória de generalização na identificação dos elementos arquitetônicos de igrejas e construções históricas. Os resultados indicam que a aplicação de técnicas de visão computacional pode contribuir significativamente para o monitoramento e preservação do patrimônio cultural, permitindo análises mais rápidas, objetivas e de menor custo.

Em trabalhos futuros, espera-se a ampliação do conjunto de dados, incluindo imagens de diferentes cidades históricas, bem como a melhoria do modelo para a identificação de patologias nos elementos arquitetônicos, auxiliando diretamente na tomada de decisões para ações de restauração e conservação.

AGRADECIMENTOS

Agradecemos ao IFMG e a UFOP (Edital PROPII 18/2024).

REFERENCES

- [1] W. M. W. Isa, N. A. M. Zin, F. Rosdi, and H. M. Sarim, "Digital preservation of intangible cultural heritage," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 12, no. 3, pp. 1373–1379, 2018.
- [2] A. L. C. Ottoni and L. T. C. Ottoni, "Imageop: The image dataset with religious buildings in the world heritage town of ouro preto for deep learning classification," *Heritage*, vol. 7, no. 11, p. 6499, 2024.
- [3] M. Mishra and P. B. Lourenço, "Artificial intelligence-assisted visual inspection for cultural heritage: State-of-the-art review," *Journal of Cultural Heritage*, vol. 66, pp. 536–550, 2024.
- [4] A. L. C. Ottoni and L. T. C. Ottoni, "A deep learning approach for cultural heritage building classification using transfer learning and data augmentation," *Journal of Cultural Heritage*, vol. 74, pp. 214–224, 2025.
- [5] M. Samhoury, L. Al-Arabi, and F. Al-Atrash, "Prediction and measurement of damage to architectural heritages facades using convolutional neural networks," *Neural Computing and Applications*, vol. 34, no. 20, pp. 18 125–18 141, 2022.

- [6] M. Mishra, "Machine learning techniques for structural health monitoring of heritage buildings: A state-of-the-art review and case studies," *Journal of Cultural Heritage*, vol. 47, pp. 227–245, 2021.
- [7] P. R. Madhu and M. V. Joshi, "Digital heritage reconstruction using deep learning-based super-resolution," *Heritage Preservation: A Computational Approach*, pp. 67–86, 2018.
- [8] M. Mishra and P. B. Lourenço, "Artificial intelligence-assisted visual inspection for cultural heritage: State-of-the-art review," *Journal of Cultural Heritage*, vol. 66, pp. 536–550, 2024.
- [9] Z. Xu, D. Tao, Y. Zhang, J. Wu, and A. C. Tsoi, "Architectural style classification using multinomial latent logistic regression," in *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6–12, 2014, Proceedings, Part I 13*. Springer, 2014, pp. 600–615.
- [10] C. A. Pereira, *Educação patrimonial no contexto do Serro-MG: um estudo de caso*. Oculum Ensaios, 2024.
- [11] A. L. Silva, "Cultura, festa e cidade: a festa do rosário do serro (mg)-contextualizações e inflexões," Master's thesis, Universidade Federal da Bahia, 2014.
- [12] A. A. Barbosa, A. Maria, and S. Bortolucci, "Serro (mg), uma trajetória para a preservação urbana," *Oculum Ensaios*, no. 3, pp. 54–67, 2005.
- [13] D. Briskievicz, "Um panorama da arrematação de lavras de ouro nas minas do serro do frio, minas gerais, brasil, 1702-1714," *Faces da História*, vol. 9, no. 2, pp. 274–297, 2022.
- [14] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto, and H. Adam, "Mobilenets: Efficient convolutional neural networks for mobile vision applications," *arXiv preprint arXiv:1704.04861*, 2017.
- [15] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 4510–4520.
- [16] A. M. Arcanjo and A. L. C. Ottoni, "Análise de modelos de aprendizado profundo para sistemas embarcados aplicados a classificação de rachaduras em construções," in *XVI Brazilian Conference on Computational Intelligence (CBIC)*, 2023.
- [17] J. R. N. Sousa, "Detecção de ações a partir da pose corporal dentro de veículos autônomos partilhados," Master's thesis, Universidade do Minho (Portugal), 2021.
- [18] S. Hymel, C. Banbury, D. Situnayake, A. Elum, C. Ward, M. Kelcey, M. Baaijens, M. Majchrzycki, J. Plunkett, D. Tischler *et al.*, "Edge impulse: An mlops platform for tiny machine learning," *arXiv preprint arXiv:2212.03332*, 2022.