

Sinalização vista de cima: desenvolvimento de um modelo de visão computacional para classificação da conservação de marcações rodoviárias

Guilherme Brizzi¹, Luís Gustavo Werle Tozevich¹

¹Curso de Ciência da Computação, Universidade Federal de Santa Maria (UFSM)
- Santa Maria, RS - Brasil

gbrizzi@inf.ufsm.br, lgtozevich@inf.ufsm.br

Abstract. *The maintenance of road signage is fundamental for traffic safety, but its monitoring is costly and laborious. This work proposes an Artificial Intelligence approach for classifying the condition of horizontal markings on Brazilian highways from aerial images. A dataset of images was built, labeled according to the condition of the markings, and a model based on MobileNetV2 was trained using transfer learning and fine-tuning. The results demonstrate high accuracy, despite a small dataset. The presented solution shows the usefulness of AI in infrastructure monitoring applications.*

Resumo. *A manutenção da sinalização rodoviária é fundamental para a segurança no trânsito, mas seu monitoramento é oneroso e trabalhoso. Este trabalho propõe uma abordagem de Inteligência Artificial para classificação da conservação das marcações horizontais em rodovias brasileiras a partir de imagens aéreas. Foi construído um dataset de imagens, rotuladas quanto ao estado da sinalização, e treinado um modelo baseado em MobileNetV2 utilizando transfer learning e fine-tuning. Os resultados demonstram alta acurácia, apesar de um dataset pequeno. A solução apresentada demonstra a utilidade da IA em aplicações de monitoramento de infraestrutura.*

1. Introdução

O Brasil possui mais de 200 mil quilômetros de rodovias pavimentadas, em diferentes graus de qualidade e conservação quanto à pavimentação, geometria e sinalização [Confederação Nacional do Transporte (CNT) 2022]. Ademais, a Pesquisa CNT de Rodovias mostra que, dentre mais de 111 mil quilômetros vistoriados, apenas 35,9% desses apresentaram estado de sinalização avaliado como “ótimo” ou “bom” [Confederação Nacional do Transporte (CNT) 2024]. Desse modo, pode-se afirmar que a falta de manutenção da sinalização viária representa um obstáculo a ser suplantado.

Um dos empecilhos para a manutenção da sinalização rodoviária é, além do custo, o monitoramento [Wu et al. 2024]. Com a grande extensão da malha, é difícil e dispendioso avaliar quais trechos se encontram em condições aceitáveis e quais têm um estado pior. Tendo em vista que a sinalização rodoviária é um fator essencial para a diminuição de acidentes no transito [Babić et al. 2020], é crucial que ferramentas que facilitem sua melhoria sejam desenvolvidas.

A partir desse panorama, o presente trabalho busca desenvolver soluções computacionais que auxiliem com o monitoramento e manutenção da malha rodoviária. Dessa

forma, valendo-se de uma abordagem de IA, foi construído um modelo de visão computacional para automaticamente classificar imagens aéreas de rodovias quanto ao estado de conservação da sinalização rodoviária horizontal do pavimento - ou seja, as marcações como faixas, linhas, símbolos e legendas feitas na superfície.

2. Motivação e Objetivos

O desenvolvimento de uma solução para avaliação da sinalização permitiria seu monitoramento automatizado, sem a necessidade de enviar equipes para presencialmente aferir as condições. Essa facilitação reduziria, pois, os custos de manutenção, melhorando sua eficiência. É inegável que um avanço na qualidade da manutenção seria benéfico, tendo em vista os benefícios para a segurança dos condutores e demais usuários da via.

Portanto, objetivou-se o desenvolvimento de um modelo de IA capaz de, a partir de uma imagem aérea, determinar se as marcações da pista estão ou não adequadas. Para tal, este trabalho também visou à criação de um *dataset* de imagens rotuladas conforme o estado da sinalização.

3. Metodologia e Desenvolvimento

O desenvolvimento da solução ocorreu em duas etapas, as quais serão delineadas nas subseções seguintes.

3.1. Construção do *dataset*

Inicialmente, buscou-se por *datasets* rotulados já existentes. Contudo, por mais que existam *datasets* análogos para visão computacional rodoviária, como o usado por [Wu et al. 2024], não foi encontrado um apropriado para a tarefa em questão.

Assim, construiu-se e anotou-se um *dataset* com 938 imagens aéreas publicamente disponíveis de estradas brasileiras, capturadas nas dimensões de 512 por 512 pixels. Dessas imagens, 40.2% (377 amostras) consistem em capturas de rodovias com mau estado de conservação das marcações, e 59.8% (561 amostras) com bom estado. A Figura 1 é uma amostra com condições rotuladas como ruins, e a Figura 2, boas.



Figura 1. Amostra “ruim”



Figura 2. Amostra “boa”

3.2. Treinamento do modelo

O modelo foi treinado utilizando as bibliotecas *Tensorflow* e *Keras* para fazer a categorização binária (“ruim”/“bom”) de imagens 512x512 em cor. O treinamento foi feito em três fases: pré-processamento, fase 1 de treinamento e fase 2 de treinamento.

No pré-processamento, as amostras do *dataset* foram carregadas e divididas entre o grupo de treinamento e o de validação, na proporção 80/20. Ademais, cada amostra foi modificada aleatoriamente, com zoom, rotação, contraste e brilho para tornar o *dataset* mais diverso, a fim de criar um modelo capaz de generalizar. Tal prática é consolidada para enriquecimento de bases de dados pequenas [Tozevich et al. 2023].

Após, realizou-se, de fato, o treinamento do modelo. Usou-se como base a arquitetura *MobileNetV2*, uma rede neural convolucional *lightweight* para visão computacional [Sandler et al. 2018]. A fim de mitigar os efeitos do tamanho relativamente pequeno do *dataset*, optou-se pelo uso de *transfer learning*. Assim, a *MobileNetV2* foi pré-inicializada com os pesos já existentes de seu treinamento com o *Imagenet*. Desse modo, começou-se com uma rede já capaz de reconhecer características básicas - como bordas, formas e texturas [Deng et al. 2009].

Na primeira fase de treinamento, manteve-se as camadas originais da *MobileNetV2* congeladas. Nesse momento, em vez de retrainar a rede por completo, mantemos intactas as camadas pré-treinadas já capazes de extrair características. Posteriormente, na segunda fase de treinamento, mais camadas são liberadas e é feito o *fine-tuning* do modelo para a tarefa em questão. Essa abordagem concilia a estabilidade dos pesos originais com a especialização para o reconhecimento em questão [Zhuang et al. 2021].

O modelo, seu respectivo código de treinamento, e o *dataset* completo estão disponíveis no repositório do GitHub em github.com/brizzigui/road_markings.

4. Resultados

De modo geral, o modelo foi capaz de classificar as imagens com ótimo desempenho. Para melhorar a testagem do funcionamento da ferramenta, além do *dataset* original, também foram coletadas e rotuladas 50 imagens adicionais de rodovias, seguindo o mesmo processo da construção do *dataset* original. A Tabela 1 mostra métricas da performance do modelo nos diferentes conjuntos de dados.

Tabela 1. Performance do modelo nos diferentes conjuntos de dados

Conjunto	Composição ¹	Acurácia	Precisão	Recall
Treino	445 / 305	98.26%	98.21%	98.87%
Validação	116 / 71	96.79%	97.41%	97.41%
Teste	25 / 25	92.00%	88.89%	96.00%

Empiricamente, notou-se que o modelo teve dificuldade em avaliar amostras em alguns casos específicos, como em áreas urbanas mais densas - em que as imagens possuem grande número de elementos distintos e complexos -, em rodovias de concreto - cujo

¹ A composição representa o número de amostras positivas (“boas”) e negativas (“ruins”), respectivamente, em cada conjunto.

pavimento é mais claro, tendo menos contraste com as marcações -, e em casos ambíguos - em que é difícil avaliar categoricamente se o trecho da via está ou não com a sinalização adequada.

5. Conclusão

Evidenciou-se que é possível construir um modelo funcional para a classificação da conservação de marcações rodoviárias a partir de um *dataset* pequeno, de menos de 1000 imagens. Esse resultado foi possibilitado por uma abordagem de *transfer learning*, permitindo que o treinamento se valesse de uma base de reconhecimento já pré-treinada.

Ademais, comprehende-se que a solução desenvolvida é útil como ferramenta de monitoramento. Se acoplada a um sistema de captura contínua de imagens, seria possível construir uma base de dados do estado da sinalização em tempo real - o que seria benéfico para ações de manutenção da infraestrutura rodoviária e, consequentemente, para a segurança de seus usuários. Em trabalhos futuros, objetiva-se explorar essa possibilidade. Ademais, visa-se a também expandir o *dataset* e as capacidades de detecção e generalização do modelo.

Nesse sentido, conclui-se que a IA aplicada ao monitoramento rodoviário, como no presente trabalho, é válida e deve continuar a ser estudada, desenvolvida e aprimorada.

Referências

- Babić, D., Fiolić, M., Babić, D., and Gates, T. (2020). Road markings and their impact on driver behaviour and road safety: A systematic review of current findings. *Journal of Advanced Transportation*, 2020.
- Confederação Nacional do Transporte (CNT) (2022). Anuário CNT do Transporte 2022. <https://anuariodotransporte.cnt.org.br/2022/Inicial>.
- Confederação Nacional do Transporte (CNT) (2024). Pesquisa CNT de Rodovias 2024. <https://cnt.org.br/documento/cbf59b9e-fd1a-41fc-b230-172c4dc42100>.
- Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., and Fei-Fei, L. (2009). Imagenet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pages 248–255.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L.-C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Tozevich, L. G. W., Librelotto, G. R., and Tozevich, P. L. (2023). Classificação de patologias em estruturas usando redes neurais convolucionais: diferenciação em trincas, fissuras e rachaduras. *Revista ComInG – Communications and Innovations Gazette*, 7(1):73–86.
- Wu, J., Liu, W., and Maruyama, Y. (2024). Street view image-based road marking inspection system using computer vision and deep learning techniques. *Sensors*, 24(23):7724.
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., and He, Q. (2021). A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1):43–76.