

Inteligência Artificial para Gestão de Estacionamentos: *Deep Learning* aplicado na Classificação de Vagas

Calebe P. Lemos¹, Ederson R. da Costa¹, Enilda A. M. da R.
Cáceres¹, Maurício de S. Estevam¹, Thiago G. de Almeida¹

¹Serviço Nacional de Aprendizagem Comercial - Hub Academy - SENAC - MS
R. Francisco C. Xavier, 75 - Centro, Campo Grande – MS CEP: 79002052 – Brasil

{calebe.lemos, ederson.costa, enilda.caceres,
mauricio.estevam, thiago.almeida}@ms.senac.br

Abstract. *This article describes the result of creating an Artificial Intelligence (AI) model to identify parking spaces, seeking to mitigate the problem of identifying empty spaces. The objective is to identify the accuracy of the trained model. The study used images from a public dataset and demonstrated accuracy above 99% using the ResNeXt method.*

Resumo. *Este artigo descreve o resultado da criação de um modelo de Inteligência Artificial (IA) para identificação de vagas de estacionamento, buscando mitigar o problema de identificação de vagas vazias. O projeto teve como objetivo identificar a acurácia do modelo treinado. O estudo utilizou imagens de um dataset público e demonstrou uma acurácia acima de 99% a partir da utilização do método da ResNeXt.*

1. Introdução

No Brasil, a frota supera 119 milhões de veículos [IBGE 2023], e seu crescimento dificulta a busca por vagas em locais de alto fluxo, gerando insatisfação [Fiorin and Stares 2019], causando até 30% dos congestionamentos [Tekouabou et al. 2022] e aumentando a emissão de poluentes, agravada pela urbanização e incentivo ao transporte individual [Derísio 2017].

Soluções como sistemas de detecção de vagas baseados em sensores RFID, ultrassônicos ou infravermelho foram desenvolvidas, mas o custo de instalação e manutenção é elevado em estacionamentos de grande porte [Cavenagli and Mendes 2020]. Em áreas abertas ou vias públicas, a instalação desses sensores pode ser inviável devido à infraestrutura necessária.

O projeto avalia modelos de Inteligência Artificial para classificar vagas de estacionamento, analisando fotos ou vídeos para identificar vagas livres ou ocupadas, contabilizar o total e oferecer alternativa de baixo custo frente a sensores, apesar de desafios na visualização. O estudo foca na otimização da gestão do estacionamento do Hub Academy - (SENAC - MS) visando organizar o espaço, reduzir o tempo de busca e aumentar a comodidade de colaboradores, alunos e visitantes.

As imagens podem ser obtidas de sistemas de segurança já existentes, evitando investimentos adicionais. Essa prática já foi aplicada por [Lima et al. 2014], que utilizaram câmeras de segurança de forma oportunista para detecção de vagas.

2. Referencial teórico

Na literatura, a gestão de vagas de estacionamento geralmente é abordada por meio de duas técnicas principais: classificação e segmentação. Conforme [Freitas et al. 2024], a classificação consiste em identificar, a partir de imagens previamente recortadas, se uma vaga está vazia ou ocupada, como ilustrado na Figura 1.



Figura 1. Exemplo de imagem de câmera de segurança (CNR-Park+EXT)
[Amato et al. 2016]

Na segmentação, podem ser aplicadas redes neurais convolucionais (CNN), como no projeto de [de Campos and de Oliveira 2024], além de técnicas como transformações de perspectiva, binarização e detecção de bordas, exemplificadas por [Lima Neto 2025].

3. Materiais e Métodos

As imagens foram extraídas do dataset público CNR-Park+EXT¹ [Amato et al. 2016], que registra vagas de estacionamento em diferentes condições climáticas, aumentando a robustez do modelo.

3.1. Conjunto de Dados

O dataset contém cerca de 130.000 imagens (150×150 px) de um estacionamento com 164 vagas, capturadas em diferentes condições climáticas, de iluminação e com oclusões parciais. Foi dividido em 40% treino, 40% teste e 20% validação [Baia et al. 2024].

3.2. Métodos

Métodos de aprendizado profundo têm se destacado em diversas aplicações. Neste trabalho, utilizaram-se duas arquiteturas principais: ResNeXt [Xie et al. 2016] e SE-ResNeXt [Hu et al. 2017], implementadas com a caixa de ferramentas open source MPretrain [Contributors 2023], baseada em PyTorch. A SE-ResNeXt diferencia-se por incorporar módulos de atenção “Squeeze-and-Excitation” (SE), que destacam características relevantes e aprimoram a representação em relação à ResNeXt tradicional.

Nota: devido à limitação de espaço neste artigo reduzido, os detalhes completos de configuração e treinamento não são descritos, mas seguem práticas consolidadas na literatura e podem ser reproduzidos a partir das referências citadas.

4. Resultados e Discussão

A Tabela 1 mostra que os modelos apresentaram ótimos resultados para a tarefa, com acurácia superior a 98%. A arquitetura ResNeXt alcançou o melhor desempenho nos experimentos realizados neste trabalho, com taxa de acerto de 99.03%.

¹<http://cnrpark.it/>

Tabela 1. Resultados dos modelos para o dataset ALL.

Métodos	Acurácia	Precisão	Revocação	F1-Score
ResNeXt	99,03%	99,05%	98,99%	99,02%
SE-ResNeXt	98,82%	98,90%	98,73%	98,81%

Os resultados obtidos neste estudo superaram trabalhos anteriores. [Paz 2024] buscou resolver o mesmo problema e alcançou acurácia de 80%. De forma similar, [Oliveira et al. 2020], utilizando ResNet, obtiveram acurácia de 95%.

Em uma revisão recente, [Martynova et al. 2024] avaliaram métodos modernos para a mesma tarefa, utilizando a base CNR-Park+EXT. Entre os resultados, o Vision Transformer [Phuong and Hutter 2022] apresentou F1-Score de 91.93%, o AlexNet obteve 95.55% e o EfficientNet-P atingiu 96.83%. Esses valores, entretanto, foram obtidos em experimentos com **datasets mesclados para treino e teste**, o que reduz a confiabilidade dos resultados. Quando os mesmos autores avaliaram **treinamento e teste no mesmo dataset**, os valores variaram de 97.98% a 99.91% no CNR-Park, próximos aos atingidos neste estudo.

Dessa forma, nossos resultados são **comparáveis aos de [Martynova et al. 2024]**, considerando ainda que este trabalho utilizou ResNeXt e SE-ResNeXt, arquiteturas inéditas para esse dataset, reforçando a contribuição inovadora e de baixo custo para a tarefa.

5. Conclusão

Este estudo avaliou redes convolucionais para classificar vagas de estacionamento por imagens, com a ResNeXt [Xie et al. 2016] atingindo mais de 99% de acerto, mesmo diante de desafios como oclusão, variação de iluminação e escala. Em comparação com sensores individuais, a abordagem por imagem reduz custos, permitindo o monitoramento simultâneo de múltiplas vagas com uma única câmera, enquanto sensores custam cerca de R\$350,00 cada [Color 2025].

Além disso, os resultados demonstraram **equivalência com os obtidos por [Martynova et al. 2024]**, consolidando a robustez da proposta, com a vantagem do uso de arquiteturas ainda não aplicadas no dataset CNR-Park+EXT (ResNeXt e SE-ResNeXt).

Trabalhos futuros incluirão avaliação de métodos mais recentes, uso de novos datasets e incorporação de informações temporais para melhorar precisão e aplicabilidade.

Referências

- Amato, G., Carrara, F., Falchi, F., Genaro, C., Meghini, C., and Vairo, C. (2016). Deep learning for decentralized parking lot occupancy detection.
- Baia, A. C., dos Reis, J. C., Técnico-IC-PFG, R., and de Graduação, P. F. (2024). Treinamento de modelos generativos multilíngues: Aplicação em sistemas de perguntas e respostas.
- Cavenagli, W. M. and Mendes, C. M. (2020). Detecção de vagas em estacionamento usando visão computacional e redes neurais convolucionais. In *XI Computer on the Beach*, Balneário Camboriú, SC, Brasil.

- Color, L. V. (2025). Sensor de vagas de estacionamento. Acesso em: 01 mar. 2025.
- Contributors, M. (2023). Openmmlab's pre-training toolbox and benchmark. <https://github.com/open-mmlab/mmpretrain>.
- de Campos, E. A. V. and de Oliveira, O. F. (2024). Detecção de objetos em imagens usando faster r-cnn. *Revista Camalotes*, 3(2).
- Derísio, J. C. (2017). *Introdução ao controle de poluição ambiental*. São Paulo: Oficina de Textos, 5th edition.
- Fiorin, D. C. and Stares, S. C. (2019). Análise da ocupação das vagas de estacionamento na área central do município de joaçaba, sc. *Conhecimento em Construção*, 6:21–34.
- Freitas, E., Gasparotto, R., Fernandes, E., Santos, J. A., Storino, Y., Andrade, S., and Ferrara, L. F. (2024). Sistema de cadastro e controle automático em estacionamento via inteligência artificial. In *Anais do Congresso Brasileiro de Iniciação Científica*, volume 1, pages 37–41.
- Hu, J., Shen, L., Albanie, S., Sun, G., and Wu, E. (2017). Squeeze-and-excitation networks.
- IBGE (2023). Frota de veículos. <https://cidades.ibge.gov.br/brasil/pesquisa/22/52567>. acessado em 01/03/2025.
- Lima, D. H. d. S. et al. (2014). Um sistema oportunista para detecção de vagas de estacionamento utilizando placas inteligentes acopladas em câmeras de segurança.
- Lima Neto, I. S. d. (2025). Detecção de objetos aplicada a nanopartículas com yolo.
- Martynova, A., Kuznetsov, M., Porvatov, V., Tishin, V., Kuznetsov, A., Semenova, N., and Kuznetsova, K. (2024). Revising deep learning methods in parking lot occupancy detection.
- Oliveira, L., Milena, P., Araújo, G., Dias, J., and Haddad, D. (2020). Detecção inteligente de vagas de estacionamento baseado em climas usando imagens aéreas e aprendizado profundo. In *Xxxviii Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*. Sbrt.
- Paz, F. M. d. (2024). Sistema para gestão organizacional de vagas de estacionamento utilizando visão computacional.
- Phuong, M. and Hutter, M. (2022). Formal algorithms for transformers.
- Tekouabou, S. C. K., Cherif, W., Silkan, H., et al. (2022). Improving parking availability prediction in smart cities with iot and ensemble-based model. *Journal of King Saud University-Computer and Information Sciences*, 34(3):687–697.
- Xie, S., Girshick, R., Dollár, P., Tu, Z., and He, K. (2016). Aggregated residual transformations for deep neural networks.