

## SEGMENTAÇÃO AUTOMATIZADA DE VAGAS DE ESTACIONAMENTO<sup>1</sup>

João Vitor Fröhlich<sup>2</sup>, Paulo Ricardo Lisboa de Almeida<sup>3</sup>, André Gustavo Hochuli<sup>4</sup>, Rodrigo Augusto Krauel<sup>5</sup>

<sup>1</sup> Vinculado ao projeto “Detecção Automatizada de Vagas de Estacionamento por Imagem”

<sup>2</sup> Acadêmico do Curso de Ciência da Computação – CCT – Bolsista PROBIC

<sup>3</sup> Orientador, Departamento de Ciência da Computação – CCT – paulo.almeida@udesc.br

<sup>4</sup> Doutor em Ciência da Computação – Université de Rouen – Laboratorie LITIS

<sup>5</sup> Acadêmico do Curso de Ciência da Computação – CCT

Atualmente, existe uma grande dificuldade quando se utiliza o carro, que é a tarefa de estacionar o veículo. Para auxiliar nessa tarefa, diversos métodos já foram desenvolvidos para que, dado uma imagem de estacionamento e a posição das vagas nessa imagem, o computador seja capaz de processar as informações e informar se uma determinada vaga está ocupada ou desocupada. Porém, tais métodos possuem um fator que dificulta sua implementação, que é a necessidade de definir manualmente na imagem a posição das vagas. Para resolver este problema, está sendo proposto um método que seja capaz de, dado um conjunto de imagens de uma câmera fixa, processar as vagas de estacionamento presentes no campo de visão dessa câmera.

Para a implementação do método, é necessário utilizar algum algoritmo de detecção de objetos. Para tal, foi utilizado a rede de segmentação semântica Mask-RCNN [1]. Para fornecer dados de treinamento para a rede, foram utilizadas imagens de cinco bases de dados distintas: Common Object in Context (COCO) [2], The Unnamed Aerial Vehicle Benchmark: Object Detection and Tracking (UAVDT-Benchmark) [3], CNR-EXT [4] [5], Parking Lots Datasets (PLDs) [6] e PKLot [7]. O maior desafio desse projeto é a falta de máscaras segmentadas nessas bases, que são marcações criadas por humanos de forma a representar onde estão os objetos na imagem. Essas máscaras são utilizadas tanto no treinamento da rede, quanto na validação de sua acurácia. Das bases utilizadas no projeto, apenas a COCO possuía as marcações necessárias para o projeto, sendo necessário criar as máscaras para as outras redes durante o projeto. A criação das máscaras para essas redes foi realizada por ambos os alunos e serão disponibilizadas publicamente. O resultado com a quantidade de máscaras geradas, bem como a quantidade de imagens existentes e utilizadas de cada base pode ser conferida na tabela 1.

Para o treinamento da rede, foi realizado um transfer learning da base COCO, onde é possível identificar muitos objetos, para ser capaz de identificar apenas carros. Para aumentar o número de imagens de treinamento sem ser necessário buscar novas imagens, foram utilizadas técnicas de aumento de dados, onde são geradas cópias das imagens com algumas transformações, como espelhamento, aproximação e distanciamento da imagem. Para ser possível testar a generalização da rede, a base de dados PKLOT não foi utilizada no treinamento, sendo mantida para utilização na aplicação do método proposto, de forma que no momento em que a rede for detectar os carros da PKLOT, ela nunca tenha visto alguma imagem semelhante antes, fazendo com que o método possa ser testado para ser utilizado em qualquer estacionamento.

A partir do que foi feito até agora, o próximo passo é conseguir transformar os carros detectados em vagas de estacionamento. Essa fase já está em andamento, onde um mapa de calor é utilizado, sendo preenchido de acordo com os carros detectados ao longo do tempo. Se uma

posição da imagem é ocupada durante uma determinada porcentagem, que ainda está para ser estimada, aquela posição é considerada uma vaga de estacionamento. Apesar de já ser possível visualizar a aplicação do método, ainda é necessário realizar testes quantitativos usando algumas métricas, como Intersection over Union (IoU), mean Average Precision (mAP) e número de acertos e erros nas vagas, para ser capaz de comprovar a eficácia do método proposto. A visualização do método pode ser visualizada na figura 1-a, onde os quadriláteros brancos representam as vagas de estacionamento encontradas pelo computador, enquanto na figura 1-b está representada as vagas de estacionamento realizadas de forma manual por uma pessoa.

**Tabela 1.** Bases de dados utilizadas no trabalho

Base de dados	Imagens totais	Imagens utilizadas	Nº de Máscaras	Exclusivo Estacionamento
COCO	328000	150	1938	
UAVDT-Benchmark	40735	100	1884	
CNR-EXT	4081	4081	89217	X
PLds	8731	8309	135780	X
PKLOT	12417	12417	337780	X
Total	393964	25057	566.599	



**Figura 1-a.** Segmentação Automática



**Figura 1-b.** Segmentação Manual

**Palavras-chave:** Reconhecimento de Padrões. Processamento de Imagem. Estacionamento.

## Referências

- [1] HE, Kaiming et al. Mask r-cnn. In: **Proceedings of the IEEE international conference on computer vision**. 2017. p. 2961-2969.
- [2] LIN, Tsung-Yi et al. Microsoft coco: Common objects in context. In: **European conference on computer vision**. Springer, Cham, 2014. p. 740-755.
- [3] DU, Dawei et al. The unmanned aerial vehicle benchmark: Object detection and tracking. In: **Proceedings of the European Conference on Computer Vision (ECCV)**. 2018. p. 370-386.
- [4] AMATO, Giuseppe et al. Car parking occupancy detection using smart camera networks and deep learning. In: **2016 IEEE Symposium on Computers and Communication (ISCC)**. IEEE, 2016. p. 1212-1217.
- [5] AMATO, G. et al. Deep learning for decentralized parking lot occupancy detection. **Expert Systems with Applications**, v. 72, p. 327-334, 2017.
- [6] NIETO, Rafael Martín et al. Automatic vacant parking places management system using multicamera vehicle detection. **IEEE Transactions on Intelligent Transportation Systems**, v. 20, n. 3, p. 1069-1080, 2018.
- [7] DE ALMEIDA, Paulo RL et al. PKlot—A robust dataset for parking lot classification. **Expert Systems with Applications**, v. 42, n. 11, p. 4937-4949, 2015.