

Detecção de Placas de Veículos Roubados com YOLOv5s em Cidades Inteligentes.

Isa C. C. de Andrade^{1(*)}, João P. S. Cardoso¹, Roberto C. L. Oliveira¹, Carlos R. L. Francês¹

¹Instituto de Tecnologia – Universidade Federal do Pará (UFPA)
Caixa Postal 66075-110 – Belém – PA – Brasil

(*)isacristina.c@gmail.com, {jpscardoso, limao}@ufpa.br,
renato.frances2010@gmail.com

Resumo. *No Brasil, o alto número de roubos e furtos de veículos é alarmante, com 564 mil casos em 2021, cerca de um roubo por hora. Este trabalho propõe um sistema de detecção de placas de veículos roubados, usando YOLOv5s, para rastrear e identificar a localização dos veículos, visando auxiliar na segurança pública. Essa abordagem atingiu um mAP@.5 de quase 95% em um tempo de resposta de 0,056 segundos.*

1. Introdução

O conceito de cidades inteligentes tem recebido cada vez mais atenção nos últimos anos como uma forma de melhorar a qualidade de vida dos habitantes urbanos por meio da integração de tecnologia e soluções inovadoras. Uma área em que esses avanços podem ter um impacto significativo é no campo da segurança pública. O roubo e furto de veículos representam desafios significativos em muitos países, incluindo o Brasil, onde o número de ocorrências relatadas é alarmante. Apenas em 2021, foram registrados 564.000 casos de roubo e furto de veículos, uma média de uma ocorrência a cada hora, de acordo com a Pesquisa Nacional por Amostra de Domicílios Contínua (PNAD Contínua), realizada pelo Instituto Brasileiro de Geografia e Estatística (IBGE).

Para enfrentar esse problema urgente, o desenvolvimento de um sistema que permita a detecção eficiente de placas de veículos roubados tornou-se relevante dentro do contexto das cidades inteligentes, esse sistema, idealmente, poderá se integrar à infraestrutura de monitoramento de câmeras da polícia já existente. Aproveitando o poder da tecnologia YOLOv5s (You Only Look Once – “Você só olha uma vez”), usa uma única rede convolucional que prevê simultaneamente várias caixas delimitadoras e probabilidades de classe para essas caixas, detectando assim, os objetos de interesse. [Redmon et al 2016].

Neste artigo, será apresentado os detalhes do sistema proposto utilizando a rede YOLOv5s e a avaliação de seu desempenho. O rastreamento de veículos roubados, a partir da identificação das placas ao receber um boletim de ocorrência. Desta forma permitindo decisões ágeis para interceptação ou recuperação.

2. Materiais e Métodos

2.1 Trabalhos correlatos

Muitos trabalhos utilizam o reconhecimento de caracteres óticos (OCR) com aplicações em diversas finalidades. [Cimirro 2022], desenvolveu um sistema para reconhecimento

de imagens de placas de trânsito. Outro sistema assíncrono para reconhecimento automático de placas de motos utilizando YOLOv5, foi desenvolvido [Leal 2022].

2.2 Detecção de objetos

A detecção de objetos é uma área amplamente explorada na visão computacional, pois permite identificar a localização e categoria dos objetos em imagens e vídeos. A detecção consiste em delimitar os objetos com uma caixa delimitadora e atribuir a eles uma classificação específica [Zhao et al 2019]. Anteriormente a 2014, as técnicas de detecção de objetos baseavam-se em abordagens clássicas da visão computacional, utilizando modelos pouco profundos programados para detectar características pré-definidas [Dalal; Triggs 2005]. Esses métodos seguiam um processo de seleção da região, extração de características e classificação. No entanto, com o surgimento das redes neurais convolucionais (CNN), a detecção de objetos passou a utilizar algoritmos baseados nessas redes. [Zhao et al 2019].

2.3 Algoritmo YOLO e YOLOv5

A série de algoritmos YOLO utiliza uma rede neural em estágio único para realizar a detecção, posicionamento e classificação direta de objetos [Redmon et al 2016]. O YOLO considera a detecção de imagens como um problema de regressão, com um pipeline simples e alta velocidade. O YOLOv5 [Ultralytics 2020], lançado em 2020, oferece uma variedade de arquiteturas de identificação de objetos que já foram treinadas usando o conjunto de dados MS COCO. Existem cinco versões distintas do YOLOv5, desde a versão YOLOv5 *nano*, projetada para uso em dispositivos móveis e embarcados, até a versão YOLOv5x *large*. Neste trabalho foi utilizado a versão YOLOv5s. A arquitetura YOLOv5 é composta por vários componentes, incluindo o *backbone*, *neck* e *head*, ou seja, os três principais componentes da série YOLO. A estrutura da rede é mostrada na Figura 1.

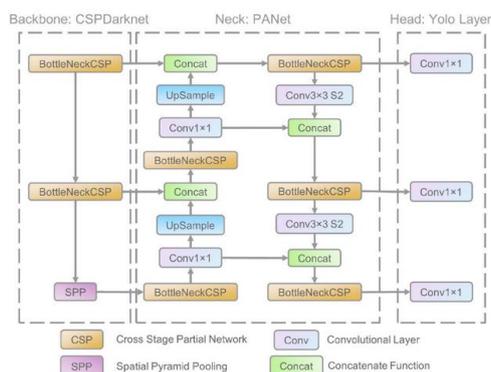


Figura 1: Diagrama estrutural da rede YOLOv5. Fonte [Xu et al 2021]

2.4 Métricas de desempenho

Ao treinar qualquer modelo baseado em *deep learning* é importante conhecer qual é seu desempenho. Portanto, é necessário selecionar as métricas apropriadas que revelam quão precisos são os modelos. Nas tarefas de detecção de objetos, as métricas geralmente utilizadas são: *precision*, *recall*, *Average Precision* (AP) e *mean Average Precision* (mAP) [Everingham et al 2010] e [Liu, L. et al 2020].

2.5 Dataset e Treinamento

O sistema de detecção de placas de veículos roubados com YOLOv5 envolveu a coleta de um conjunto diversificado de imagens de placas de veículos, anotação das letras e números das placas, treinamento do modelo YOLOv5, validação do desempenho, teste com imagens inéditas. A base de dados *OCR Image Dataset* está disponível na plataforma *Roboflow*. Ela contém placas de veículos anotadas com números de 0 a 9 e letras do alfabeto de A à Z, totalizando 36 classes. Os dados de treinamento foram divididos de acordo com a tabela 1. O treinamento foi realizado com as seguintes configurações: tamanho da imagem de entrada 416x416; tamanho do batch 16; épocas 100 concluídas em 1.6 horas.

Tabela 1: Divisão do *dataset* para treinamento.

Treino	Validação	Teste	Total
70%	20%	10%	100%
4245	1221	610	6076

3. Resultados

Os valores máximos de *precision* e *recall* são de 0,962 e 0.904, respectivamente. As curvas de *precision* e de *recall*. O valor máximo da métrica de *mAP@.5*, para todas as classes, estabilizou no valor de 0.948, tendo sido alcançado por volta da época 96, durante a fase de treinamento, conforme ilustra a Figura 3. A Figura 4 exemplifica um teste de inferência da rede.

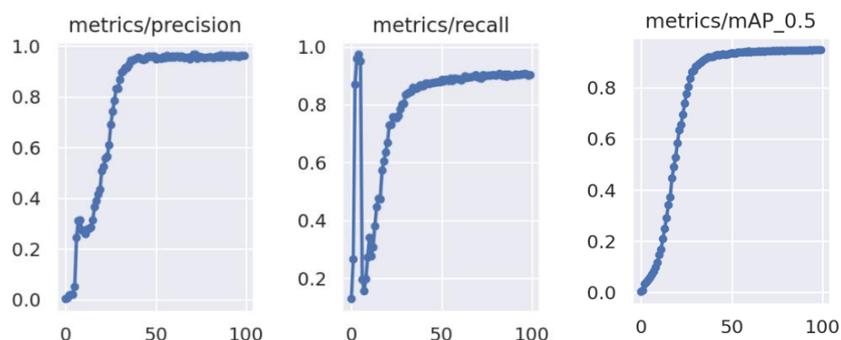


Figura 3: Gráficos de *precision* e *recall* e *mAP@.5*. Fonte: Autores.



Figura 4: exemplo de teste de detecção da rede. Foram encontrados nesta imagem: 8 números-0; 6-1; 6-2; 5-3; 6-4; 3-5; 6-6; 2-7; 4-8; 3-9; 1-A; 2-B; 3-C; 2-D; 2-E; 2-F; 2-G; 3-H, 1-I, 3-J, 1-K, 3-M, 2-N, 1-O, 1-P, 2-R, 1-S, em 8.2ms. Fonte: Autores.

4. Conclusões e propostas futuras

Essa abordagem foi altamente eficaz, atingindo um mAP@.5 de quase 95% com um tempo de resposta de apenas 0,056 segundos por inferência. Como próxima etapa, planeja-se treinar novos modelos usando a rede YOLOv8, incluir dados de placas de veículos nacionais e criar um chatbot no Telegram para permitir que os usuários identifiquem se um veículo é roubado, enviando uma foto da placa e recebendo uma previsão. Essas melhorias têm o potencial de aprimorar ainda mais o sistema, contribuindo para a segurança e mobilidade nas cidades inteligentes.

Referências

- Cimirro, J. L. D. S. (2022). Reconhecimento de imagens: Uso do método Yolo no reconhecimento de placas de trânsito.
- Dalal, N., & Triggs, B. (2005, June). Histograms of oriented gradients for human detection. In 2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05) (Vol. 1, pp. 886-893). Ieee.
- Everingham, M., Eslami, S. A., Van Gool, L., Williams, C. K., Winn, J., & Zisserman, A. (2015). The pascal visual object classes challenge: A retrospective. *International journal of computer vision*, 111, 98-136.
- Leal, N. G. M. (2022). Sistema assíncrono para reconhecimento automático de placas de motos (Bachelor's thesis, Universidade Federal do Rio Grande do Norte).
- Liu, Li; Ouyang, Wanli; Wang, Xiaogang; Fieguth, Paul; Chen, Jie; Liu, Xinwang; Pietikäinen, Matti. "Deep Learning for Generic Object Detection: A Survey." *International Journal of Computer Vision*, vol. 128, no. 2, Springer, 2020, p. 261–318.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 779-788).
- Trimestral, Divulgação. "Pesquisa Nacional por Amostra de Domicílios Contínua." 2021. Ultralytics. "YOLOv5." 2022. Disponível em: <https://github.com/ultralytics/yolov5>. Acesso em: 10 mar. 2023.
- W251ocr. "OCR Dataset." Conjunto de dados de código aberto. Roboflow Universe, 2023. Disponível em: <https://universe.roboflow.com/w251ocr/ocr-oy9a7>. Acesso em: 28 jun. 2023.
- Xu, Renjie, LIN, Haifeng, LU, Kangjie, et al. A forest fire detection system based on ensemble learning. *Forests*, 2021, vol. 12, no 2, p. 217.
- Zhao, Z. Q., Zheng, P., Xu, S. T., & Wu, X. (2019). Object detection with deep learning: A review. *IEEE transactions on neural networks and learning systems*, 30(11), 3212-3232.