

SOLUÇÕES DE CONDICIONAMENTO DE IMAGENS DE CÂMERAS MONOCULARES APLICADO À SISTEMAS AVANÇADOS DE ASSISTÊNCIA À DIREÇÃO DE VEÍCULOS

Gustavo Henrique Gimenes Vieira (PIBIC/CNPq/FA/UEM), Arthur Gonçalves Serra Guarrata, Igor Rossi Fermo (Coorientador), Rafael Krummenauer (Orientador). E-mail: rkrummenauer2@uem.br.

Universidade Estadual de Maringá, Departamento de Engenharia Química, Maringá, PR.

Área e subárea do conhecimento: Engenharias / Engenharia Elétrica

Palavras-chave: Visão Computacional; Redes Neurais; Veículos Inteligentes.

RESUMO

O projeto visa contribuir com o estudo de soluções para sistemas avançados de assistência à direção de veículos, atuando mais especificamente na detecção e leitura de informações de placas de trânsito. A função do sistema é detectar e classificar as placas de sinalização vertical operando em tempo real. Este trabalho traz informações do desenvolvimento e conclusão do projeto, técnicas e ferramentas utilizadas, principais resultados obtidos até o momento e discussões importantes para a continuidade do mesmo, levando em consideração até mesmo os problemas encontrados.

INTRODUÇÃO

Nos dias de hoje o trânsito tem proporcionado uma série de desafios, principalmente para as grandes cidades, tanto em questões de mobilidade urbana, quanto em questões ambientais. Dados mostram que, mesmo com a queda do número de acidentes e mortes com o passar dos anos, os problemas de trânsito ainda trazem números preocupantes: 31.468 pessoas morreram no Brasil em 2021 por acidentes de trânsito. Os acidentes de trânsito são a maior causa de morte não natural no mundo (TISCHER, 2019).

Muito se fala sobre as causas destes acidentes, geralmente ocorrido por imprudência do condutor. Na maioria das vezes, as placas de trânsito são ignoradas, o que não deveria acontecer pois sua função é prevenção de acidentes e organização do fluxo de veículos e pessoas nas vias. Sendo assim, avanços tecnológicos têm sido feitos no desenvolvimento de sistemas de identificação de pedestres, carros, placas, etc. Estes que por ventura buscam contribuir com a segurança.

MATERIAIS E MÉTODOS

Primeiramente, deve-se levar em conta que o sistema de placas varia de acordo com o país e dentro do Brasil, dependendo do caso, pode variar entre os estados, portanto a primeira tarefa foi encontrar um *dataset* (conjunto de imagens), com placas que são utilizadas em Maringá. Por isso, foi disponibilizado por Bruno Dantas de Oliveira (DANTAS, 2021), exclusivamente para este projeto, um *dataset* completo com várias fotografias de placas tiradas e pré-processadas por ele, contendo as placas desejadas. Posteriormente, mais imagens foram adicionadas manualmente para complementar o conjunto.

Após a obtenção e organização do conjunto de dados, com o intuito de separar as imagens em sua categoria (10 categorias), um processo de rotulagem foi realizado. O conjunto de dados é uma coleção de imagens rotuladas que são usadas para ensinar um modelo de detecção de objetos a reconhecer padrões em novas imagens. Para isso foi utilizado um software chamado *Roboflow* (ROBOFLOW, 2023), no qual é possível demarcar as caixas delimitadoras de cada placa (retângulos delimitadores que envolvem regiões específicas de uma imagem onde o algoritmo identificou a presença de um objeto) (MATUCK *et al.*, 2023). Os parâmetros determinam a coordenada do objeto na imagem, como demonstrado na Figura 1.

1 0.90625 0.57421875 0.06953125 0.115625

Figura 1 – Coordenada de uma caixa delimitadora

Este formato de rotulagem é necessário para aplicação do YOLO, um modelo que tem a função de identificar objetos em uma imagem, através de uma rede neural nomeada de DNN (*Deep Neural Network*) (REDMON *et al.*, 2016).

Com isso todas as imagens do dataset passam pelo processo de rotulagem e geram um arquivo .txt como a Figura 1, e após isso foi possível seguir para o processo de treinamento.

O processo de treinamento é realizado na plataforma Google Colaboratory, é uma plataforma muito simples e fácil de se utilizar, além de ser prática, fazendo com que grandes dataset de imagens possam ser treinados com computação em nuvem.

O processo é feito conectando-se a plataforma no google drive onde estão os arquivos de imagem com os outros arquivos de treinamento. Após o treinamento vários testes são realizados com fotografias tiradas nas vias internas da UEM.

Deve-se atentar pois o treinamento tem um limite máximo que caso ultrapassado aparece o problema de sobre ajuste (*Overfitting*), que consiste em um treinamento exagerado do modelo, situação na qual o modelo fica viciado nos dados de treinamento e perde generalização.

RESULTADOS E DISCUSSÃO

De primeira instância foi realizado um treinamento com base nas fotos disponibilizadas, e a cada um período de tempo era gerado um gráfico de erro e testadas imagens para verificar a precisão. Após aproximadamente 1800 iterações de treinamento, foi obtido um gráfico de erro do modelo treinado (Figura 2), nele é

possível perceber um erro muito baixo (0,687%), posteriormente algumas imagens de placas tiradas na própria UEM foram testadas, sendo possível verificar a precisão do sistema (Figuras 3a, 3b e 3c).




Figura 2 – Erro após o primeiro treinamento



Figuras 3a, 3b e 3c – Resultado de alguns testes parte 1

Porém como foi possível observar algumas imagens não se comportaram como o esperado. Além da Figura 3c, outras se comportaram da mesma maneira. Para isso novamente um modelo foi treinado. 50 novas fotos foram adicionadas, divididas igualmente entre as classes, e novamente foi realizado um treinamento, após a amostragem das fotos será feita uma análise do ocorrido (Figuras 4, 5a, 5b e 5c).




Figura 4 – Erro após o segundo treinamento



Figuras 5a, 5b e 5c – Resultado de alguns testes parte 2

Como é possível observar o erro obtido se apresentou menor com menos tempo de treinamento, além disso, nas mesmas imagens apresentadas

anteriormente (Figuras 3a, 3b e 3c), foi obtida uma precisão maior, porém ainda se observou alguns erros não esperados, o que leva a entender que ainda sim é possível obter resultados melhores com a adição de mais fotos no dataset de treinamento. Porém como descrito 50 fotos a mais já demonstraram um nível considerável de melhora.

CONCLUSÕES

Neste trabalho foi proposto um sistema inteligente para detectar e classificar as placas de sinalização vertical, com capacidade de operar em tempo real. O algoritmo YOLO foi utilizado em um conjunto de dados de placas de trânsito. Os resultados demonstraram bom potencial na solução proposta. Mas alguns pontos devem ser levados em conta. Primeiramente ainda é de extrema importância aperfeiçoar o treinamento, pois a ideia é que o modelo identifique com a maior precisão possível e uma forma simples seria adicionando mais imagens. Em segundo lugar, este processo mostra que a área da visão computacional ainda está em um crescimento constante, pois hoje já existem até mesmo carro de direção autônoma que utilizam da leitura de placas. Por fim, pode-se considerar o treinamento como sucesso pois o sistema conseguiu identificar a maioria das placas com precisão elevada.

AGRADECIMENTOS

À Fundação Araucária e ao CNPq pelo auxílio financeiro.

REFERÊNCIAS

TISCHER, V. O custo social e econômico dos acidentes de trânsito com pedestres e ciclistas: estudo de caso do estado de Santa Catarina, Brasil. 2019.

DANTAS, B. O. Rotulagem e treinamento do yolo para reconhecimento de placas de trânsito brasileiras. 2021.

REDMON, J. *et al.* You Only Look Once: Unified, real-time object detection. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, p. 779 – 788, 2016.

ROBOFLOW. Roboflow. Novembro 2023. Disponível em: <https://roboflow.com/>. Acessado em 25/08/2024.

MATUCK, G. R. *et al.* Reconhecimento facial com inteligência artificial utilizando a plataforma Roboflow. 2023.