

DETECÇÃO DE CONES PARA DIREÇÃO AUTONOMA EM VEICULO BAJA

Juan Caio Paronitti Galera¹, Andre Mendes², Danilo Hernani Perico¹

¹ Departamento, Instituição

² Departamento, Instituição

juancaio.galera@gmail.com

dperico@fei.edu.br

Resumo: Com o avanço da tecnologia, a direção autônoma tornou-se uma realidade, impulsionada principalmente pelos avanços nos modelos de visão computacional. No contexto de veículos baja, a aplicação prática desses modelos tornaria a direção autônoma mais segura, especialmente em ambientes off-road. Durante o desenvolvimento dos estudos, dois modelos se destacaram: YOLOv4 e YOLOv8. Para determinar qual deles é o mais adequado para essa aplicação, foram realizados diversos testes práticos, visando identificar o modelo mais eficiente e confiável para o uso em terrenos desafiadores.

1. Introdução

A crescente demanda por veículos autônomos off-road tem impulsionado o estudo e desenvolvimento de soluções tecnológicas capazes de operar em ambientes pouco estruturados, como áreas agrícolas e minas.

No entanto, o desenvolvimento de veículos autônomos off-road enfrenta desafios significativos. Diferentemente dos ambientes urbanos, que são relativamente controlados e contam com infraestrutura como placas de sinalização, faixas de pedestres e semáforos, os ambientes off-road são imprevisíveis e frequentemente desprovidos de orientações visuais padronizadas.

Para enfrentar esses desafios, foram desenvolvidos modelos de visão computacional especializados na detecção de cones de trânsito, utilizados para demarcar trajetos em ambientes off-road. A arquitetura de rede neural escolhida para esse projeto foi a YOLO. O principal diferencial do YOLO é sua capacidade de processar a imagem em uma única passagem pela rede neural.

O foco principal durante o desenvolvimento dos modelos de detecção foi otimizar o tempo de resposta, uma vez que a latência mínima é essencial para aplicações em tempo real. Diante dessa necessidade, diversas técnicas foram exploradas para reduzir o tempo de inferência. Uma das abordagens adotadas foi a redução do número de convoluções no modelo, diminuindo a complexidade computacional sem sacrificar a precisão necessária para a detecção de cones.

Após utilizar diversas métricas para escolher o melhor modelo, a versão YOLOv8x foi escolhida por

apresentar a melhor velocidade de resposta em comparação ao número de acertos de detecção

2. Metodologia

A pesquisa iniciou-se com uma revisão abrangente de modelos de visão computacional voltados para tarefas de detecção de objetos. O foco era identificar modelos que apresentassem um bom equilíbrio entre precisão e velocidade de inferência, sendo adequados para aplicações em tempo real.

Após a análise de diversas arquiteturas, a rede neural YOLO (You Only Look Once) foi selecionada como base para o desenvolvimento do sistema de detecção. Com a arquitetura YOLO definida, foram implementados e comparados dois dos seus modelos: YOLOv4 e YOLOv8. A versão YOLOv4 foi inicialmente explorada devido à sua robustez e à ampla aceitação na comunidade de visão computacional.

Posteriormente, a versão YOLOv8 foi introduzida para o desenvolvimento. A YOLOv8 oferece melhorias em termos de precisão e eficiência, além de suporte para diferentes escalas de modelos, o que permite ajustá-los conforme as necessidades de processamento e a capacidade de hardware. Dentro da YOLOv8, foram desenvolvidas e testadas quatro variações de modelos, com diferentes tamanhos: S (Small), M (Medium), L (Large) e X (Extra Large). Esses modelos foram treinados para detectar cones em ambientes off-road.

Os modelos foram treinados utilizando um conjunto de dados de imagens de cones. O treinamento foi realizado utilizando técnicas padrão de aprendizado supervisionado, com divisão dos dados em conjuntos de treino e validação. A métrica de avaliação utilizada foi o mAP (mean Average Precision), com foco na detecção de cones, sendo avaliada em cada uma das versões do YOLO.

Após o desenvolvimento e treinamento dos modelos, foi realizado um teste prático utilizando um vídeo fornecido pelo veículo Baja em um cenário com cones dispostos ao longo do trajeto. O vídeo foi processado utilizando cada um dos modelos desenvolvidos (YOLOv4 e as variações S, M, L e X do YOLOv8), e duas métricas principais foram registradas:

- **Precisão de Detecção:** A precisão de detecção dos cones em cada frame do vídeo foi medida utilizando o mAP. Esta métrica avaliou a capacidade dos modelos em detectar corretamente os cones presentes no ambiente.

- **Tempo de Carregamento e Processamento do Vídeo:** O tempo necessário para carregar e processar o

vídeo foi registrado para cada modelo, fornecendo uma avaliação do desempenho em tempo real dos diferentes tamanhos de modelo (S, M, L, X) do YOLOv8 em comparação com o YOLOv4.

Os resultados obtidos foram analisados e foi considerado a precisão de detecção e o tempo de processamento para cada modelo. A partir dessas análises, foi possível identificar que o modelo da YOLOv4 apresentou bons resultados de detecção, mas o seu tempo de processamento foi muito longo, entretanto o modelo YOLOv8x apresentou bons resultados de detecção e um baixo tempo de processamento, como podemos ver na Tabela 1.

Tabela 1- Resultados dos modelos YOLO

modelos	MAP	latencia (S)	n° de epocas	tempo para treinamento (h)
YOLOv4	88.06%	159	4000	80
YOLOv8s	90.3%	18	100	0.95
YOLOv8m	90.5%	21	100	1.20
YOLOv8l	88.6%	25	100	1.95
YOLOv8x	91.6%	30	100	3.30

3. Resultados

O modelo YOLOv4, embora tenha mostrado uma boa precisão, foi descartado devido ao longo tempo de treinamento e à alta demanda de poder computacional, resultado do grande número de convoluções. Já os modelos YOLOv8 S e M, apesar de atingirem altos valores de mAP, falharam em fornecer detecções válidas no teste de campo com o veículo em movimento. O modelo YOLOv8L, por sua vez, apresentou bons valores de mAP, mas teve poucas detecções válidas no teste prático. O destaque foi o modelo YOLOv8x, que combinou bons valores de mAP com desempenho superior no teste de campo, consolidando-se como a escolha ideal para a aplicação.

4. Conclusão

Ao final da pesquisa e desenvolvimento dos modelos, foi identificado que o modelo YOLOv8x se destacou como a melhor escolha para a aplicação no veículo Baja. Esse modelo apresentou uma elevada capacidade de aprendizado e rápida adaptação como podemos observar na figura 1, sendo capaz de detectar com precisão os cones utilizados nos testes de campo. Além disso, o YOLOv8x demonstrou eficiência em termos de consumo de recursos, exigindo uma baixa carga de poder computacional, o que é essencial para a implementação em um ambiente embarcado no veículo. Esses fatores combinados fazem do YOLOv8x a solução ideal para a detecção de objetos em cenários off-road.

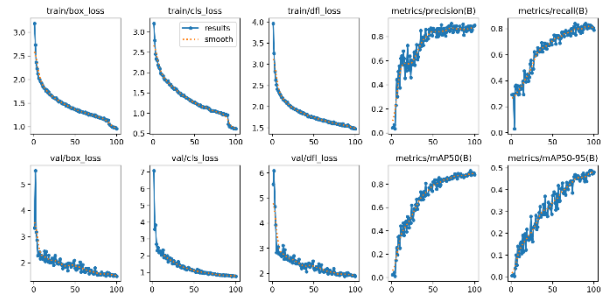


Figura 1 – Resultados treinamento YOLOv8x

5. Referências

Agradecimentos

À instituição Centro Universitário da FEI.

¹ Aluno de IC do Centro Universitário FEI (ou FAPESP, CNPq ou outra). Projeto com vigência de 05/2023 a 04/2024.