

URBANFLOW

Alvaro Figueiredo Neto – 248311
Gustavo do Nascimento Ferreira – 249018
Lucas Diniz Vargas – 247711

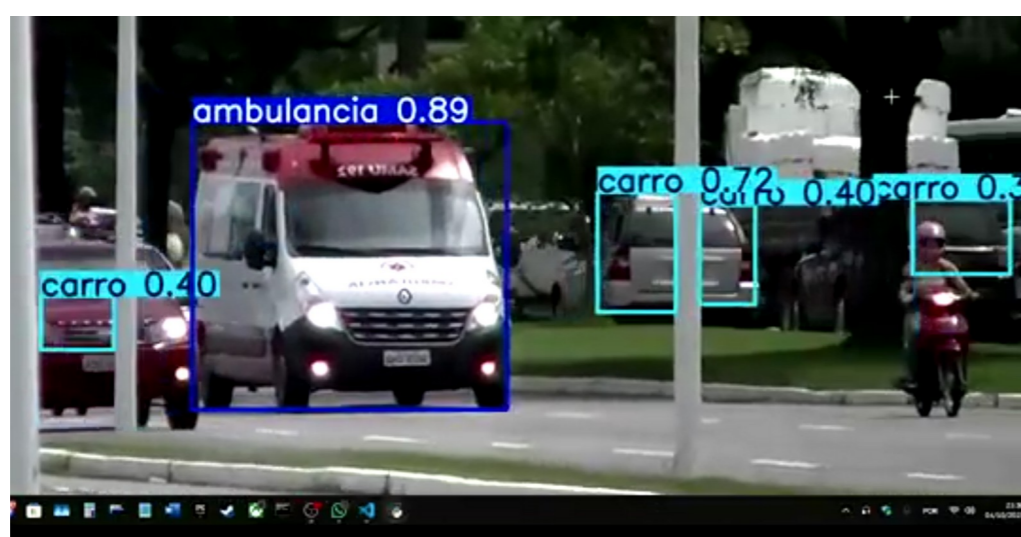
João Andreas Tosto de Azevedo – 248740
Nicolas Xavier Zanata – 247848
André Magalhães Paes – 101706
Gabriel Tavares Feitosa – 247516

Orientadora Profa. Dra. Renata Vasques da Silva Tavares

INTRODUÇÃO

O tempo perdido em cruzamentos congestionados impacta diretamente a agilidade dos serviços de emergência (ambulâncias, bombeiros e polícia), onde cada segundo é vital. Os sistemas semafóricos atuais, baseados em ciclos fixos, frequentemente falham em priorizar esses veículos, causando atrasos inaceitáveis e consequências graves. Diante disso, este trabalho propõe o desenvolvimento de um protótipo de semáforo inteligente que utiliza Inteligência Artificial (IA) e visão computacional para garantir a prioridade imediata a veículos de emergência.

Figura 1. Protótipo Físico.



Fonte: Autoria Própria, 2025.

JUSTIFICATIVA

O atraso causado por semáforos comuns em vias urbanas representa um risco direto à vida humana. Um sistema que garanta a passagem imediata e ininterrupta de veículos de emergência reduz o tempo de percurso, aumentando as chances de sucesso das operações de atendimentos.

OBJETIVOS e ODS

- Validar um modelo de sistema com visão computacional que identifica a presença de ambulâncias em vias públicas
- Testar a utilização do Esp32 para prototipação.
- Criar um protótipo físico com um hardware e software integrados.

Figura 2. Imagem das ODS.

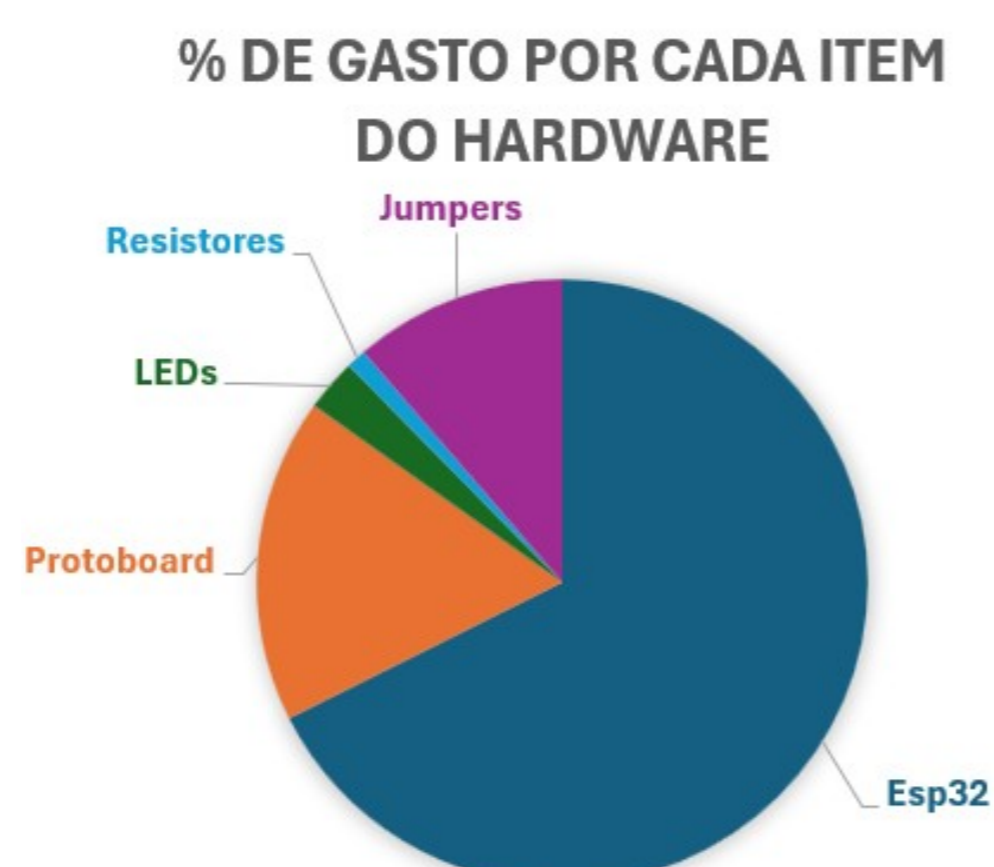


Fonte: ONU, 2025.

ORÇAMENTO

Tabela 1. Tabela de orçamento.

Descrição	Valor Unitário	Qtd/Horas	Total
Programador	R\$ 35,00	40	R\$ 1.400,00
Esp32	R\$ 39,00	1	R\$ 39,00
Protoboard	R\$ 10,00	1	R\$ 10,00
LEDs	R\$ 0,40	4	R\$ 1,60
Resistores	R\$ 0,10	6	R\$ 0,60
Jumpers	R\$ 0,50	13	R\$ 6,50
			R\$ 1.457,70



Fonte: Autoria Própria, 2025.

RESULTADOS E VALIDAÇÃO

O modelo YOLO foi treinado com 183 imagens anotadas manualmente, sendo 150 destinadas ao treinamento (com data augmentation) e 38 para validação. Ele apresentou alta eficiência na detecção de ambulâncias, alcançando Precision de 85,6% (proporção de detecções corretas), Recall de 95,1% (taxa de objetos reais detectados) e mAP50 de 92,3% (média de acertos considerando detecções com pelo menos 50% de sobreposição com o objeto real). A detecção de carros obteve desempenho moderado, com Precision de 63,3%, Recall de 64,6% e mAP50 de 60%, podendo ser aprimorada pela inclusão de uma maior variedade de veículos não emergenciais no dataset, como vans, caminhões, pickups e motos.

Figura 3. Formulas matemáticas usadas na validação do modelo

$$\text{Recall} = \frac{TP}{TP + FN} \quad \text{Precision} = \frac{TP}{TP + FP}$$

Fonte: Autoria Própria.

Tabela 2. Tabela das métricas do modelo

Class	Images	Instances	Box(P)	R	mAP50
all	38	104	0.745	0.798	0.761
ambulancia	24	25	0.856	0.951	0.923
carro	16	79	0.633	0.646	0.6

Fonte: Autoria Própria, 2025.

Figura 4. Início dos testes.



Fonte: Autoria Própria, 2025.

Figura 5. Conclusão dos testes.



Fonte: Autoria Própria, 2025.

CONCLUSÃO

O modelo alcançou 94% de acurácia na detecção, mesmo utilizando um dataset reduzido com apenas duas classes (ambulâncias e carros). A arquitetura YOLO Nano v11, otimizada para eficiência em dispositivos de baixo processamento, permitiu realizar inferência em tempo real mantendo alta precisão. Com um número reduzido de parâmetros e camadas, o modelo consegue processar fluxos de vídeo contínuos sem comprometer desempenho, mostrando-se robusto e com potencial para escalabilidade em cenários mais complexos.

AGRADECIMENTOS

Gostaríamos de expressar nosso sincero agradecimento aos integrantes do grupo pelo empenho e dedicação ao longo do projeto. Agradecemos também a Profa. Dra. Renata Vasques e ao Professor Isaias Goldschmidt por todo suporte e orientações valiosas. Nossa gratidão se estende à Faculdade Facens pelo ambiente de aprendizado e oportunidades oferecidas.