

## SISTEMA AUXILIAR DE DIREÇÃO PARA DIMINUIÇÃO DE ACIDENTES DE TRÂNSITO POR MEIO DE ALERTA ANTICOLISÃO

Gabriel Campos Pinesi e Antônio Newton Licciardi Junior

**Apoio: PIBIC Mackpesquisa**

### RESUMO

Os principais motivos dos acidentes de trânsito (AT) são falhas humanas, que tem como um dos principais fatores a desatenção dos condutores. Em meio ao alto número de AT, que ocasionam até mesmo em fatalidades, vem sendo desenvolvidos cada vez mais na indústria, os chamados ADAS (Advanced Driver Assistance Systems), sistemas de assistência avançados de direção, que como o próprio nome evidencia são eletrônicos capazes de auxiliar o motorista, de forma a aumentar a segurança durante a direção e consequentemente reduzir o número de acidentes e óbitos no trânsito. Porém automóveis que possuam estes sensores pré-instalados não são acessíveis do ponto de vista econômico, para a maior parcela da população brasileira. Um dos sistemas mais relevantes, e principal alvo do estudo realizado neste artigo, é o alerta de colisão frontal, FCW (Frontal Collision Warning) que utiliza uma câmera como sensor a fim de identificar uma possível colisão frontal. Para realizá-lo ela é programada para monitorar em tempo real a velocidade relativa entre si e os veículos a frente. Este trabalho tem como objetivo prototipar e avaliar um hardware embarcado automotivo de FCW com o uso de inteligência artificial aplicada as imagens recebidas em tempo real pelo sistema, que seja de baixo custo e confiável. Busca-se ainda estabelecer a estrutura mais eficiente de DeepLearning com o uso de redes neurais para a aplicação, e estimar as futuras capacidades do hardware levando em conta fatores como a lei de Moore.

**Palavras-chave:** Acidentes de trânsito. Inteligência Artificial. Hardware embarcado.

### ABSTRACT

The main reasons for traffic accidents (TA) are human failures, which have as one of the main factors the inattention of drivers. In the midst of the high number of TA, which even cause fatalities, the so-called ADAS (Advanced Driver Assistance Systems) which as the name implies are electronic systems capable of assisting the driver, have been increasingly developed in the industry in order to increase safety while driving and consequently reduce the number of accidents and deaths in traffic. However, cars that have these sensors pre-installed are not accessible from an economic point of view, for the largest portion of the Brazilian population. One of the most relevant systems, and main target of the study carried out in this article, is the frontal collision warning (FCW) that uses a camera as a sensor in order to identify a possible frontal collision. To do this, it is programmed to monitor in real time the relative

speed between itself and the vehicles ahead. This work aims to prototype and evaluate a low cost and reliable automotive FCW embedded hardware with the use of artificial intelligence applied to the images received in real time by the system. It also seeks to establish the most efficient DeepLearning structure using neural networks for the application, and to estimate the future capabilities of the hardware taking into account factors such as Moore's law.

**Keywords:** Traffic accidents. Artificial Intelligence. Embedded hardware.

## 1. INTRODUÇÃO

A cada ano, 1,35 milhões de pessoas morrem por acidentes de trânsito (WHO, 2018) e aproximadamente mais 2,7 milhões passam a apresentar lesões permanentes. Noventa por cento (90%) das mortes no trânsito ocorrem em países de baixa e média renda. Em 2021, no Brasil, foram registrados 793.562 acidentes de trânsito (AT), responsáveis por 17.996 óbitos, dentre os quais 53,3% motoristas e 11,8% pedestres (RENAEST, 2022). Tais dados, caracterizam o fenômeno de AT como uma epidemia em termos de saúde pública, que gera altos custos com internações hospitalares, além de causar diversos transtornos às pessoas envolvidas como sequelas físicas, problemas econômicos e emocionais, invalidez, de acordo com a CNM (Confederação Brasileira dos Municípios) (SOUZA, LIMA, 2007; PAIXÃO et al., 2015).

Falhas humanas são os principais motivos dos acidentes, que podem envolver desde a desatenção dos condutores até o desrespeito à legislação (OSNV, 2015). As causas principais são: excesso de velocidade, uso do celular, falta de equipamentos de segurança como o cinto de segurança, o uso de bebidas antes de dirigir ou até mesmo dirigir cansado.

Para a OMS (WHO, 2018), veículos seguros desempenham um papel essencial na prevenção de acidentes e na redução da probabilidade de lesões graves. Por veículo seguro entenda como um veículo com sistemas tecnológicos de segurança que garantam a integridade física dos ocupantes (SILVA, 2018).

Em 2021, a frota veicular brasileira atingiu a idade média de 10 anos (SINDIPEÇAS, 2022). Este é o maior número em 25 anos (SILVA, 2021). A idade da frota de um país é um reflexo das condições econômicas da comunidade local e a sua renovação pode trazer uma queda significativa de AT, em razão da chegada de novas tecnologias de direção assistida (DERETIĆ; STANIMIROVIĆ, 2021). A tabela da Figura 1 contém dados estatísticos de AT em função de suas causas, nas rodovias federais brasileiras. Chama a atenção o alto número de acidentes causados pela falta de atenção do condutor.

Figura 1. – Ranking das principais causas de AT nas Rodovias Brasileiras.

Posição	Causas	Números de acidentes
1	Falta de atenção	24.102
2	Desobediência à sinalização	9.219
3	Velocidade incompatível	5.878
4	Ingestão de álcool	5.434
5	Defeito mecânico em veículo	3.748
6	Não guardar distância de segurança	3.617
7	Dormindo	2.109
8	Animais na Pista	1.405
9	Ultrapassagem indevida	1.081
10	Defeito na via	966

Fonte: Atlas da acidentalidade no transporte brasileiro (PRF, 2020)

Face a escala de acidentes causados por erros humanos, tem sido propostos novos sistemas de assistência ao condutor, os chamados ADAS (Advanced Driver Assistance Systems). Estes são capazes de alertar quanto aos potenciais perigos no trânsito e auxiliam a melhorar a habilidade de direção (TIGADI, GUJANATTI, GONCH, 2016). Um deles é o de alerta de colisão frontal, FCW (Frontal Collision Warning), que já está presente em certos veículos de marcas como: Chevrolet e Nissan. O FCW utiliza câmera com o objetivo de identificar e alertar o condutor para uma possível colisão frontal. Para tal, monitora em tempo real a velocidade e distância do veículo à frente em relação ao veículo de trás, e caso a distância esteja abaixo de um limiar estabelecido, o alerta é emitido ao condutor, a fim de que mantenha espaço de segurança (SANTOS, 2015). É importante ressaltar que este não assume o controle do veículo, como efetuar manobras de desvio e frenagem (NHTSA, 2017).

Os métodos de Aprendizado de Máquinas (ML - *Machine Learning*) tornaram-se populares para várias tarefas no âmbito das aplicações ADAS, em particular devido aos rápidos avanços em hardware e algoritmos computacionais que são apoiados por grandes empresas (BORREGO-CARAZO et al, 2020).

Um método popular dentro da família ML é a Rede Neural Artificial (RNA) (J.DAHL et al, 2019). As redes neurais artificiais fornecem um método geral e prático para aprender funções de valores reais, discretos e vetoriais a partir de exemplos. As RNAs são dotadas dos métodos de aprendizagem dentre os mais eficazes conhecidos, sendo resistente a erros nos dados de treino e tem sido aplicada com êxito a problemas como a interpretação de cenas visuais, o reconhecimento da fala e a aprendizagem de estratégias de controle de robôs. (MITCHELL, 1997)

Dentro deste cenário, esta pesquisa pretende estudar e desenvolver um sistema auxiliar de direção, capaz de alertar o motorista durante uma situação de perigo iminente, com a capacidade de ser instalável nos veículos mais antigos da frota. Adicionalmente, deseja-se que este tenha um baixo custo e seja confiável.

## 2. REFERENCIAL TEÓRICO

### **Câmera**

As câmeras de visão frontal, ou FLC (*Forward Looking Camera*) são usadas em veículos rodoviários para fornecer as funcionalidades relacionadas com os ADAS. O FLC consiste na colocação de uma câmera na parte frontal do veículo para capturar imagens que serão processadas. Requisitos adicionais incluem uma interface de comunicação física adequada, uma fonte de alimentação e um sistema embutido de processamento (SANTOS, 2015). Câmeras de baixa resolução são utilizadas (iguais ou menores que 1024x768 pixels), a fim de que o processamento em tempo real seja possível (LEIBE, 2007; WU et al., 2021).

### **Processamento da imagem**

Segundo Morris (2004) um sistema de visão computacional é dividido nas etapas de: aquisição da imagem, pré-processamento, extração de características, detecção e segmentação, e processamento. Este equipamento tem como propósito efetuar tomadas de decisões importantes sobre objetos e cenas reais com base em imagens detectadas (SHAPIRO, STOCKMAN, 2001). Segundo Gonzalez e Woods (2010) deve ser considerado que o processamento realize funções de interpretação e tomada de decisões emulando as cognitivas humanas desempenhadas pela visão.

### **OpenCV**

O software do FCW pode ser desenvolvido com o suporte de biblioteca de visão computacional como a OpenCV (Open Computer Vision Library), desenvolvida pela Intel (MARENGONI, STRINGHINI, 2009). Esta disponibiliza funções computacionais de processamento de imagens, mediante análise de objetos de interesse na imagem capturada. Essa biblioteca é disponibilizada gratuitamente e existe ampla documentação disponível em livros e na internet.

A biblioteca OpenCV possui recursos de aprendizagem profunda (*deep learning*), que facilita a estruturação de hardwares embarcados nos veículos que façam o reconhecimento de objetos e gerem alertas em tempo real (LECUN et al, 2015; MONTAVON; SAMEK; MÜLLER, 2017, DI RENNA, 2013).

### **Microcontroladores**

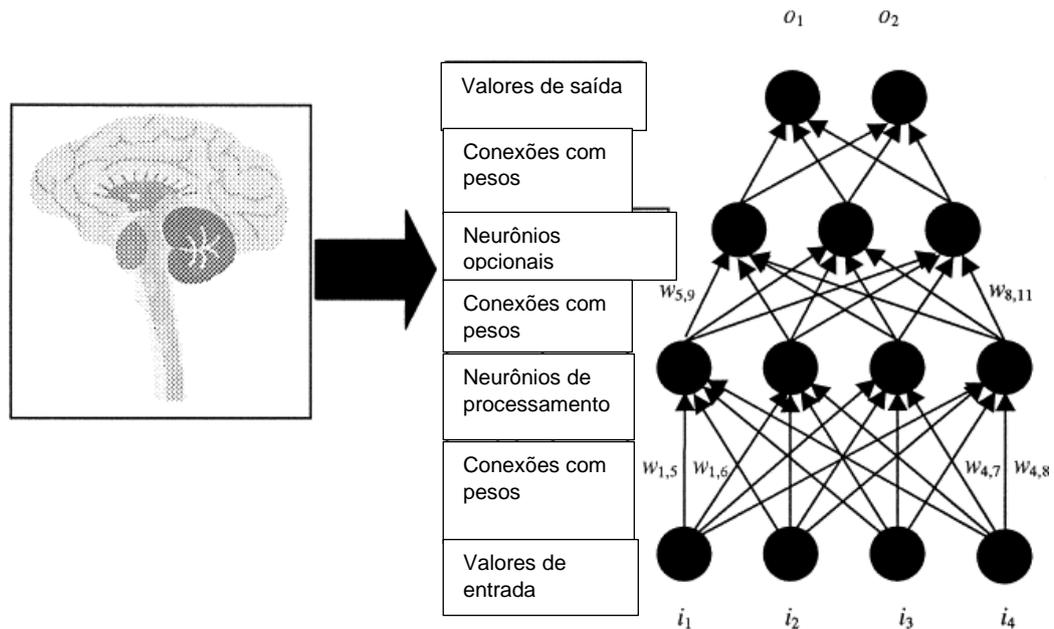
O desenvolvimento de hardwares embarcados são possíveis graças ao uso de microcontroladores (MCU - Microcontroller Unit) adequados (DIAS; JAREK, 2011). Uma MCU é composta por uma unidade central de processamento (UCP) de instruções, memória e interfaces de entrada e saída dados (I/O) integradas em um único circuito de silício. As MCUs propiciam portabilidade, rapidez desenvolvimento, eficiência operacional e robustez ao sistema eletrônico, e em geral alta confiabilidade. Por confiabilidade de um equipamento é possível entender como a habilidade deste de executar a sua função dentro de limites e condições operacionais durante um tempo definido (YASDI et al., 2021).

Dentre os mais utilizados estão o Raspberry Pi e o Arduino, que juntos dominam 93% do mercado (SUN, 2018). O Raspberry mostra-se interessante para aplicação em objetos inteligentes, com suporte a sistema operacional como Linux, que trabalham com imagens e processamento de algoritmos de inteligência artificial, assim como os veículos autônomos, como mencionado por Licciardi (2022).

### **Aprendizagem profunda/Redes neurais**

O termo Aprendizagem Profunda refere-se às RNAs (Redes Neurais Artificiais) com várias camadas (ALBAWI et al, 2017). Os modelos de RNA simulam a atividade elétrica do cérebro e do sistema nervoso. No cérebro a transmissão para outro neurônio se faz de forma bioquímica, enquanto no RNA, por simplicidade, consideram-se somente impulsos elétricos (CHANTSALNYAM, 2020). Os elementos de processamento (também conhecidos por nós) (WALCZAK, CERPA, 2003). Normalmente, os nós estão dispostos em camadas, com a saída de uma camada servindo de entrada para a camada seguinte, como pode ser visto na Figura 2, onde os valores dos elementos ( $i$ ) são multiplicados pelos pesos ( $w$ ) para simular o reforço das vias neurais cerebrais. Os sinais de dados ponderados que entram num nó simulam a excitação elétrica em célula nervosa e, conseqüentemente, a transferência de informação dentro da rede ou do cérebro. É através do ajuste dos pesos das ligações que a aprendizagem é emulada nas RNA (WALCZAK, CERPA, 2003).

Figura 2. - Comparação entre as redes neurais biológicas (esquerda) e artificiais(direita); as artificiais emulam as ligações sinápticas do cérebro.



Fonte: Artificial Neural Networks (WALCZAK, CERPA, 2003)

Uma das redes neurais profundas mais populares é a rede neural convolucional, ou CNN (*Convolutional Neural Network*). O seu nome deriva da operação matemática linear entre matrizes denominada de convolução. O seu aspecto mais vantajoso é a redução do número de parâmetros das RNA. Essa conquista levou pesquisadores e desenvolvedores a abordarem modelos maiores para resolver tarefas complexas, o que não era possível com RNA clássicas (ALBAWI et al, 2017).

### Yolo (You Only Look Once)

A ferramenta YOLO, atualmente, é o estado da arte em sistemas de reconhecimento de objetos em tempo real, de acordo com um compromisso entre velocidade e assertividade; isso se faz possível através do uso de CNN (KÜHNE, 2018)

Os algoritmos da série YOLO desenvolveram-se rapidamente nos últimos anos. Em 2020, surgiram sucessivamente duas versões do YOLO v4 e do YOLO v5. O algoritmo YOLO v5 atingiu uma exatidão de quase 50 mAP no conjunto de dados COCO, enquanto assegurando a boa velocidade de funcionamento (ZHANG et al, 2022). O tamanho do YOLOv5 é pequeno e seu arquivo é quase 90% menor do que o do YOLOv4, o que permite que o YOLOv5 seja implementado em dispositivos embarcados (LIU et al, 2020).

### Métricas para análise do modelo – Precisão média (AP – *Average Precision*)

A métrica mais comum utilizada para medir a precisão das detecções é a precisão média (AP), que consiste na área sob a curva da curva de precisão x

recuperação. Para entendê-la devemos ter como base outros termos: Verdadeiro positivo (VP): Uma detecção correta de uma caixa delimitadora para um objeto existente; Falso positivo (FP): Uma detecção incorreta de um objeto inexistente ou uma detecção deslocada de um objeto existente; e Falso negativo (FN): Uma caixa delimitadora de um objeto existente não detectado. (PADILLA, NETTO, DA SILVA, 2020)

A avaliação dos métodos de detecção de objetos baseia-se principalmente nos conceitos de precisão P (para um sistema ADAS) e de recuperação R (também chamado sensibilidade por Mitchell, 1997), respetivamente definidos como:

$$P = \frac{VP}{VP+FP} \quad (1)$$

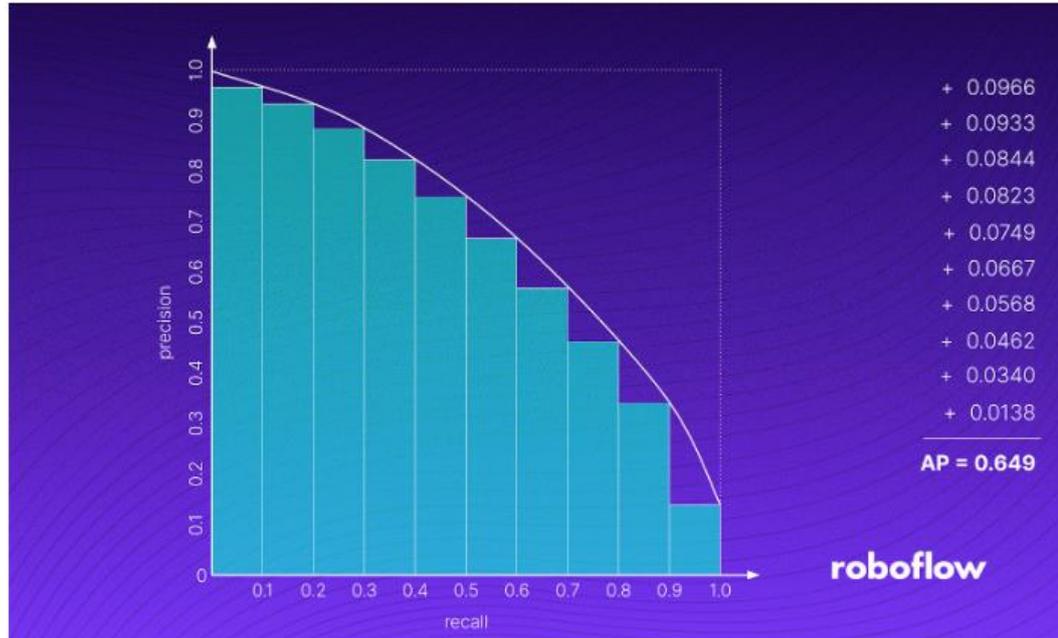
$$R = \frac{VP}{VP+FN} \quad (2)$$

em que VP é Verdadeiro positivo, FN é Falso negativo, e FP é Falso positivo;

A precisão, assim definida para um sistema ADAS, equação 1, mede a quantidade de vezes que o modelo acerta em relação ao total de vezes que ele tenta acertar. Já a recuperação, equação 2, mede a quantidade de vezes que o modelo acerta em relação ao total de vezes que ele deveria ter acertado (FILHO, 2023).

A curva precisão (ADAS) x recuperação, vista na Figura 3, demonstra como a recuperação muda para determinada precisão e vice-versa num determinado modelo. Pode ser realizada uma troca entre P e R, a partir do ajuste do nível de confiança das detecções, a depender das necessidades da aplicação, por exemplo: se o modelo estiver numa posição em que é mais importante evitar FP do que FN, pode-se aumentar a margem de confiança do modelo para que sejam feitas detecções com alta precisão, porém diminuindo a cobertura das detecções, ou seja, a recuperação. O AP médio (mAP) é uma métrica utilizada para medir a precisão dos detectores de objetos em todas as classes de uma base de dados específica, e varia entre 0 e 1 assim como o AP. (SOLAWETZ, 2020). Esta métrica é comparável ao que se entende como CSI – fator crítico de sucesso (MITCHELL, 1997; LICCIARDI, 2022). Pode-se usar a seguinte classificação para o protótipo (LICCIARDI, 2022): Regular:  $0,5 \leq mAP < 0,63$ ; Bom:  $0,63 \leq mAP < 0,75$ ; Muito bom:  $0,75 \leq mAP < 0,87$ ; Ótimo ou excelente:  $0,87 \leq mAP < 1$ .

Figura 3. – Cálculo da precisão média (AP), a partir da curva precisão x recuperação. O AP corresponde a área verde abaixo da linha.



Fonte: *What is Mean Average Precision (mAP) in Object Detection?* (SOLAWETZ, 2020)

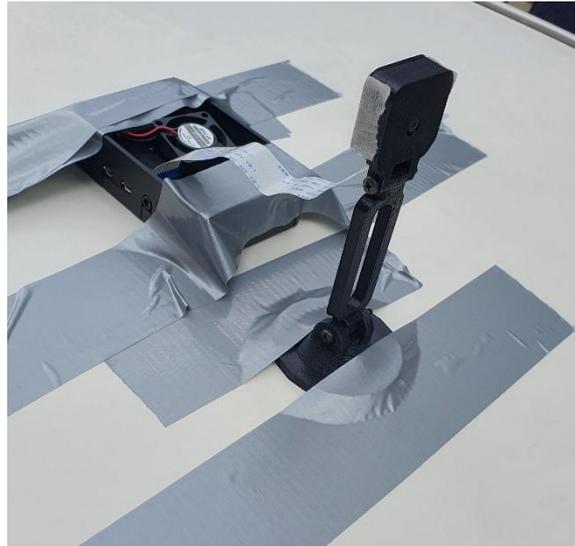
### 3. METODOLOGIA

O desenvolvimento do projeto contempla as seguintes etapas metodológicas:

#### **Criação do banco de dados com imagens do trânsito.**

É essencial o uso de um módulo de câmera, com baixa resolução, no caso de 5MP e distância focal de 3.29mm, a fim de capturar as imagens utilizadas na construção de um banco de imagens original, que seja posteriormente utilizado no treinamento da rede neural. Este, criado a partir de imagens obtidas no trânsito da cidade de São Paulo. A figura 4 apresenta uma foto de como o protótipo foi fixado no veículo para aquisição de imagens que seriam usadas nas sequências de treinamento do modelo. As imagens obtidas são então carregadas no Roboflow, plataforma conhecida por auxiliar desenvolvedores na criação de aplicações de visão computacional, onde é realizada a etiquetagem manual com caixas delimitadoras (bounding boxes), em cada classe de veículos registrados. Dentre as classes criadas estão: Ônibus, carro, motocicleta, pessoa, Van e Caminhão. No final desta etapa separa-se um banco de dados de 1000 imagens etiquetadas em 3 pastas, de treinamento, validação e teste, correspondendo a 70%, 20% e 10%, respectivamente.

Figura 4. – Protótipo do sistema utilizado para a captura de imagens em tempo real, com o módulo da câmera e Raspberry conectados ao teto de um automóvel.

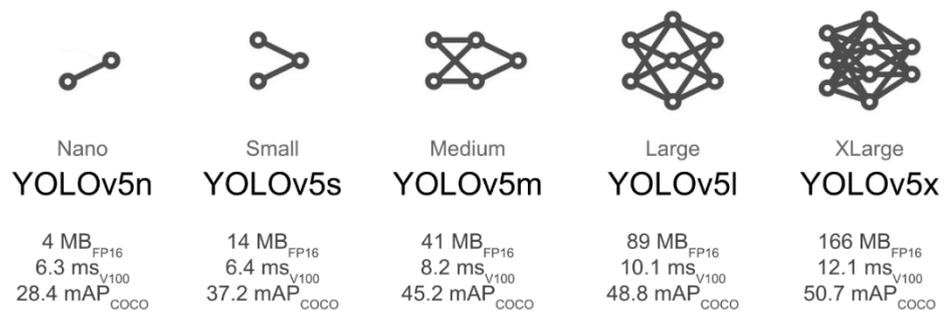


Fonte: os autores

### Treinamento da rede neural com YOLOv5.

Com o banco de imagens completo, é realizado o treinamento de uma rede neural utilizando o modelo YOLOv5, ideal para o uso de visão computacional em dispositivos embarcados. Dentre os modelos pré-treinados disponíveis, é escolhido o yolov5n (nano), que como pode ser visto na figura 5, possui o menor tamanho e velocidade de inferência permitindo assim, potencializar a agilidade de detecção no Raspberry.

Figura 5. - Comparação de tamanho dos arquivos, e velocidade de detecção entre os modelos pré-treinados YOLOv5.



Fonte: Train Custom Data (JOCHER, 2023).

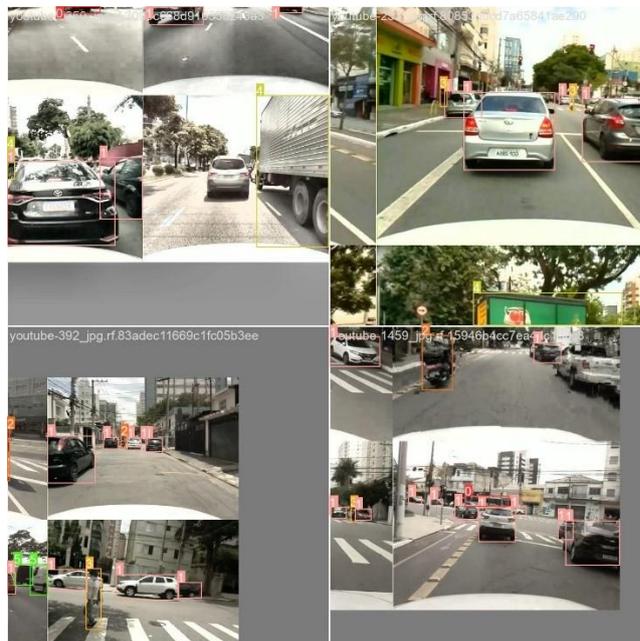
O treino é feito por meio da plataforma Google Colab, produto do Google, focado em análise de dados e aprendizado de máquina utilizando Python na nuvem. O serviço permite a utilização de GPUs gratuitas que a plataforma disponibiliza, e que aceleram o treino da rede.

A rede é treinada com 150 épocas, que consiste no número de vezes que os dados são exibidos para a rede neural, esperando que o resultado nos apresente um conjunto de pesos, para as conexões da rede, melhor ajustados com as características

que desejamos. Porém existe um limite acima do qual os pesos passam a se afastar do ideal ao invés de melhorar, isso é chamado de treinamento excessivo (*overfitting*), e neste caso o limite para evitar isso foram as 150 iterações.

Para o treinamento foram adotados lotes de 4 imagens; o modelo é então exportado para o formato ONNX, a fim de torná-lo mais rápido. A figura 6 ilustra 4 casos de reconhecimento correto de objetos de imagens do conjunto de testes realizado após o treinamento da rede.

Figura 6. – Sequência de treinamento da rede com lotes de 4 imagens.

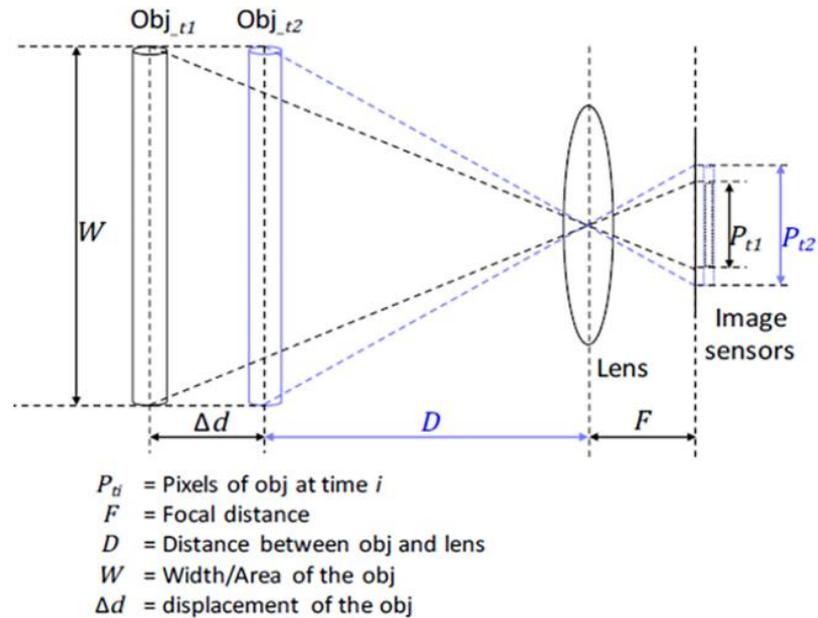


Fonte: os autores

### **Cálculo da distância entre câmera e objetos, com semelhança de triângulos.**

Para calcular a distância da câmera para o veículo à frente, deve ser utilizada uma semelhança de triângulos:  $D = (F \times W) / P$ , tendo como base a distância focal da câmera (F), a largura do veículo na imagem (W), ambos em pixels, e a largura média real do veículo (P) detectado pelo modelo, em metros. Esta relação é melhor ilustrada na figura 7. A distância focal utilizada para a câmera é de 634.868 pixels, e são adotados os valores médios de largura para cada classe de veículos (em metros): Ônibus = 2.60 m, Carro = 1.75, Motocicleta = 0.70 m, Caminhão = 2.20 m, Van = 2.00 m (PAWAR et al., 2023; PONN et al., 2020).

Figura 7. - Semelhança de triângulos aplicada para o cálculo da distância entre a câmera e objetos, que utiliza a distância focal da câmera ( $F$ ), a largura real do objeto ( $W$ ), e a largura do objeto na imagem ( $P$ ) na formula:  $D = (F \times W) / P$ .



Fonte: Smombie Guardian: We watch for potential obstacles while you are walking and conducting smartphone activities (KIM et al, 2018).

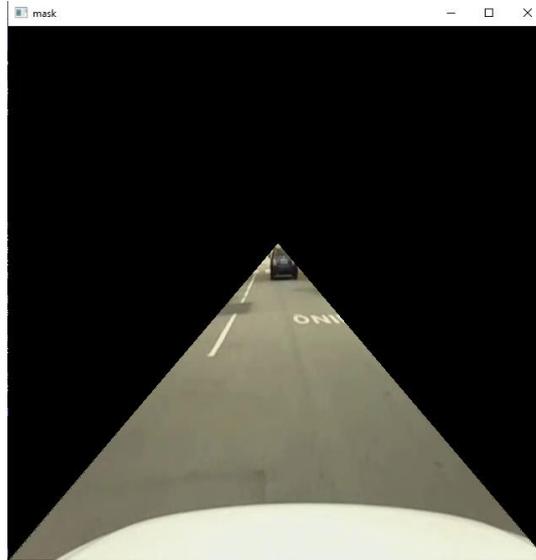
### Cálculo da velocidade média relativa

Logo após, é feito o cálculo da velocidade relativa entre câmera e objeto detectado, no qual o delta das distancias obtidas entre um quadro e outro é dividido pela taxa de quadros por segundo (qps), e multiplicado por 3,6 para obter o resultado em Km/h. No final do cálculo é feita uma média móvel da velocidade relativa, a fim de tornar o resultado menos ruidoso.

### Aplicação de um filtro (máscara) nos cálculos de velocidade realizados.

Vale comentar que o cálculo da velocidade média relativa deve ficar restrito para veículos localizados em um campo de visão da base da câmera (que representa o pavimento que o veículo tem a sua frente) e um ponto central da imagem (que representa o infinito de uma imagem em perspectiva da câmera), impedindo a realização dos cálculos e alertas errôneos para veículos nas laterais do automóvel. Para tal, utilizou-se uma máscara como a apresentada na figura 8. Este artifício é utilizado, pois se busca seguir ou dar foco no conceito de alertas de colisão frontal.

Figura 8. – Máscara aplicada à imagem para a limitação dos cálculos da velocidade relativa, somente, para veículos a frente da câmera, a fim de evitar alertas falsos gerados por veículos nas laterais.



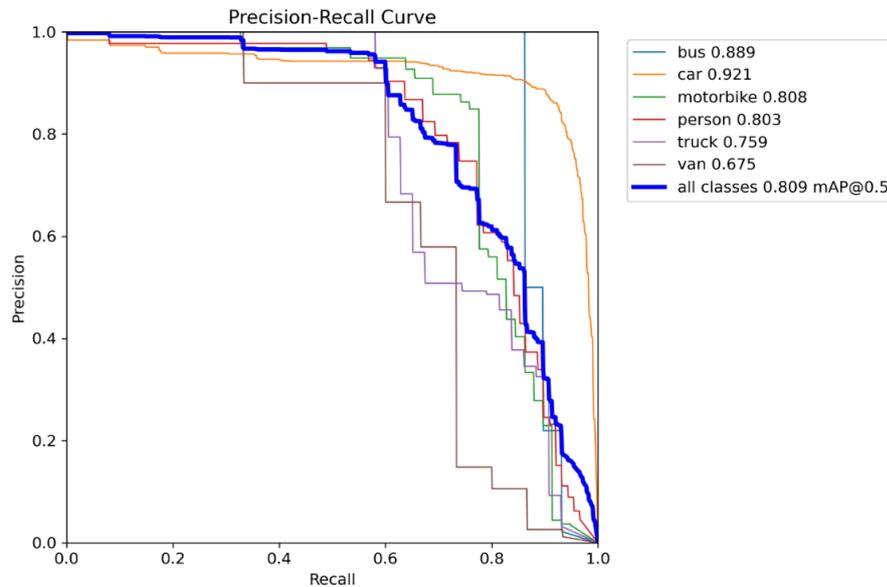
Fonte: os autores

#### 4. RESULTADO E DISCUSSÃO

##### Análise dos dados de treinamento e validação

Como demonstra a figura 9, os resultados obtidos no treino são bem satisfatórios, demonstrando um alto AP, métrica equivalente a área sob a curva (AUC), para a maioria das classes, especialmente para carros e ônibus. A média de precisão, mAP (*Mean Average Precision*), para todas as classes é de 0.8 o que pode ser considerado muito bom. No caso dos caminhões e vans o resultado é menos satisfatório, obtendo 0.759 e 0.675, respectivamente. Este resultado possui algumas explicações plausíveis.

Figura 9 – Curva Precisão x Recuperação do modelo para os dados de treinamento.

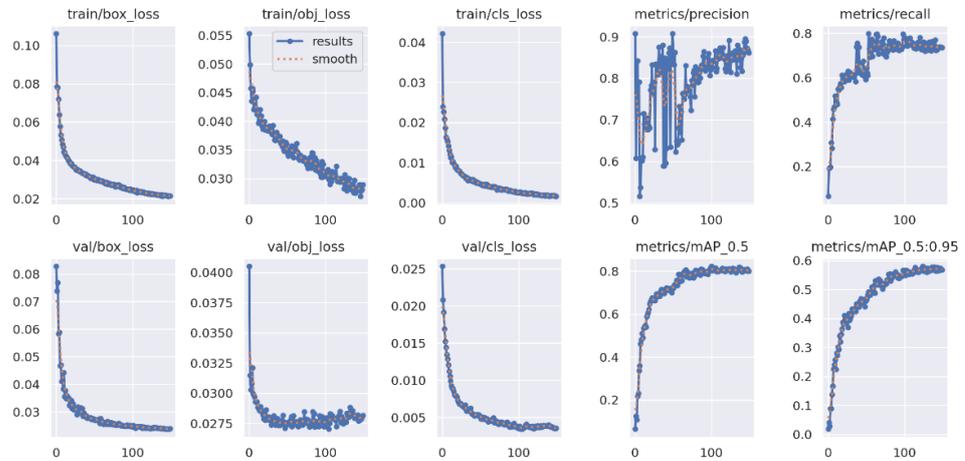


Fonte: os autores

O banco de imagens para treino possui na classe caminhão, majoritariamente imagens de VUCs (Veículos Urbanos de Carga), caminhões urbanos menores, para validação conceitual e prática do modelo proposto deste trabalho e evitar trabalhos não relevantes de inferência já que os dados são coletados nas ruas da cidade. Para uma melhor inferência seriam necessárias mais classes de caminhões devido ao grande número de modelos existentes. Já as Vans possuem pinturas muito diferentes e algumas vezes com adesivos que dificultam sua identificação pelo modelo, como é o caso das escolares. Por outro lado, é válido comentar que a dimensão traseira destes veículos é similar, como apresentado no início da corrente seção, o que não interferiria na eficiência do sistema criado.

A quantidade de 150 épocas de treinamento é o limite máximo capaz de evitar problemas relacionados ao treinamento excessivo (Overfitting), como comprova a figura 10. Pois caso as curvas de validação: val/box\_loss, val/obj\_loss e val/cls\_loss, demonstrem um comportamento de subida enquanto as de treinamento: train/box\_loss, train/obj\_loss e train/cls\_loss continuem diminuindo, estaria comprovado que o modelo sofre de um treinamento excessivo, conseqüentemente possui ótimo desempenho nos dados de treinamento, porém desempenho ruim em dados de teste (HE et al., 2022). Ou seja, este não possui capacidade de generalização.

Figura 10. – Resultados de treinamento e validação do modelo de acordo com N<sup>o</sup> de épocas; comprovando a inexistência de Overfitting, já que os dados de validação: val/box\_loss, val/obj\_loss e val/cls\_loss não sofrem um aumento após sua queda inicial

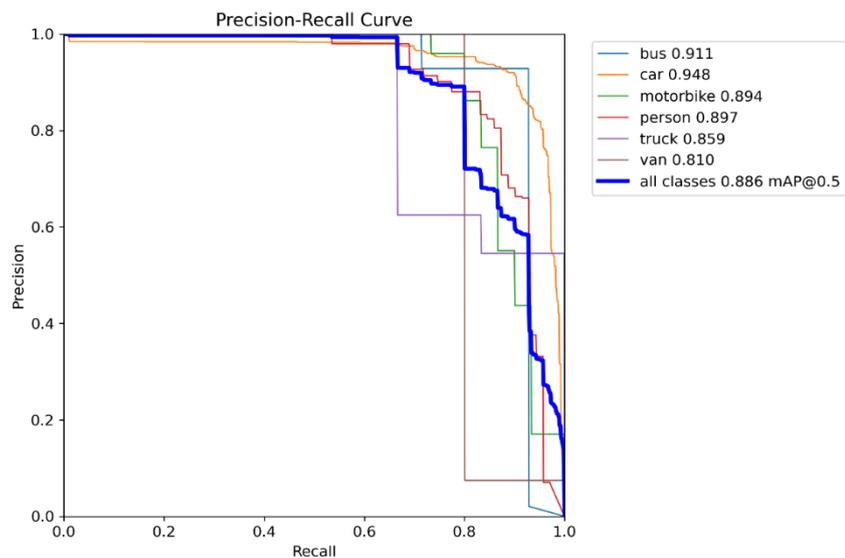


Fonte: os autores

### Análise dos dados de teste

Quando o modelo é submetido a dados de teste podemos ter melhor noção de sua real capacidade, para isso é plotada a curva de precisão x recuperação novamente e obtidos os valores de AP. O mAP tornou-se excelente: 0.886, e acima de 0.89 para 4 classes, dentre elas, ônibus, carro, motocicletas e pessoas. Os resultados para caminhões e vans é melhor do que nos dados de validação. Tal aspecto pode ser observado na figura 11.

Figura 11. – Curva Precisão x Recuperação do modelo para dados de teste, ou seja, casos novos, que ainda não haviam sido “vistos” pela rede.



Fonte: os autores

## **Eficiência do protótipo**

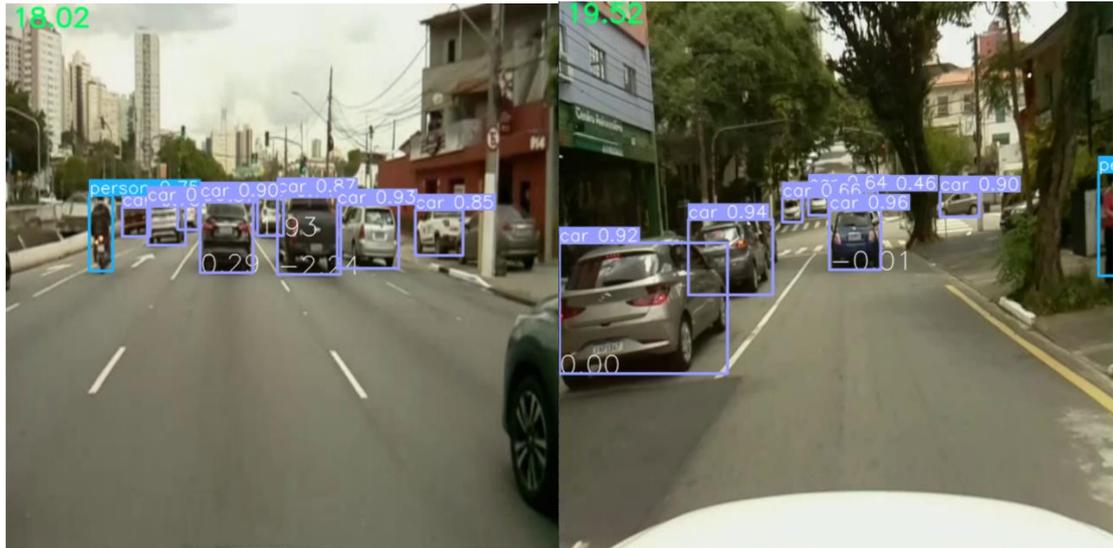
Em relação ao desempenho do processador Broadcom BCM2711 do Raspberry durante a inferência das imagens em tempo real, é atingido um máximo de 2,5 quadros por segundo, com a exportação do modelo para o formato ONNX, que é capaz de acelerar o tempo de inferência de modelos Pytorch de 2 a 3 vezes. Essa velocidade pode ser considerada baixa para um alerta de colisão frontal embarcado se considerada a regra de segurança dos 2 segundos adotado por motoristas, na qual escolhe-se um ponto fixo na estrada e começa-se a contar pausadamente quando o veículo da frente passa por ele, até que se chegue nesse ponto. Se esse tempo for de 2 segundos ou mais, a distância é segura (ABRACICLO, 2018).

Contudo se é levado em consideração a lei de Moore, de que a capacidade de processamento dos chips dobra a cada 18 meses (SHALF, 2020), sabe-se que em 4,5 anos o modelo atingirá, em hardware equivalente, uma velocidade de processamento de 20 qps, adequado para a aplicação e para que possa ser embarcado em veículos como um sistema ADAS viável e de baixo custo. Por hora, para simular esta condição de funcionamento que ocorrerá no futuro, a fim de testar as medidas de velocidade relativa, utiliza-se um computador desktop com CPU de capacidade de processamento suficiente.

## **Velocidade relativa**

Os valores de velocidade relativa a serem obtidos a partir da semelhança de triângulos aplicada, e dispostos sobre vídeos de teste, são condizentes com o esperado. Os reconhecimentos de objetos e velocidades relativas calculadas podem ser observadas na figura 12. Durante a aproximação com outros automóveis ela se torna negativa, já no afastamento ela é positiva. Os valores são condizentes com a relativização de fps usadas. Quando a aproximação ocorre muito rapidamente o valor é positivo e alto, tornando possível o estabelecimento de um limiar para a emissão de um alerta de segurança, ou mesmo, a frenagem automatizada.

Figura 12. – Simulação do cálculo da velocidade média relativa em tempo real, mostrando a velocidade relativa, em km/h, nas caixas delimitadoras dos veículos localizado à frente da câmera. Para aqueles em que ocorre aproximação, o valor é negativo, já para os veículos com os quais ocorre afastamento, o valor é positivo.



Fonte: os autores

## 5. CONSIDERAÇÕES FINAIS

O presente trabalho teve como objetivo o estudo e aplicação de algoritmos de visão computacional no contexto de um alerta de colisão frontal, com o propósito de mitigar acidentes de trânsito, mediante o desenvolvimento de um dispositivo embarcado de baixo custo acessível à população. Neste escopo, destacou-se uma abordagem significativa no estudo de redes neurais aplicadas à detecção de objetos, juntamente ao tratamento de imagens realizado com o OpenCV.

O sistema atingiu uma boa performance na detecção de objetos treinados com YOLOv5, para isso foi essencial a boa etiquetagem das classes do banco de dados criado. Vale destacar que esta fase, é muito relevante para o funcionamento do modelo e requer bastante tempo, dentro do cronograma de pesquisa. Já a medida da velocidade relativa entre câmera e veículos se mostrou funcional nos testes realizados com CPU, porém ainda pouco eficiente no Raspberry devido à baixa taxa de quadros obtida, de 2.5 qps. Porém, sabe-se pela lei de Moore, que será possível um protótipo em custo e velocidade de processamento viável nos próximos 4,5 anos.

Como continuidade do trabalho seria interessante a criação de mais classes de veículos, implicando no aumento do banco de dados, e promovendo detecções mais específicas reduzindo erros na matriz de confusão da identificação de classes. Cabe realçar novamente o aspecto, de que o protótipo em 4,5 anos atingirá um nível de maturidade de custo x benefício esperado, que permitirá a elaboração de produtos comerciais baseados no mesmo. Claro que existe a alternativa de se usar um processador de maior capacidade, porém de maior custo, o que não atenderia um dos objetivos específicos deste trabalho. Vale lembrar que os arquivos utilizados para a

realização do projeto estão disponíveis no GitHub: [www.github.com/Gabriel-sci/FCW-project](https://github.com/Gabriel-sci/FCW-project) (PINESI,2023).

## 6. REFERÊNCIAS

ABRACICLO. **Manual Básico de Segurança no Trânsito.** Disponível em: <[https://www.virapagina.com.br/abraciclo\\_manual/18/#:~:text=Existe%20uma%20regra%20simples%20%E2%80%93%20a,Conte%20dois%20segundos%20pausadamente.](https://www.virapagina.com.br/abraciclo_manual/18/#:~:text=Existe%20uma%20regra%20simples%20%E2%80%93%20a,Conte%20dois%20segundos%20pausadamente.)>, 2018. Acesso em: 12/04/2022.

ALBAWI, Saad; MOHAMMED, Tareq Abed; AL-ZAWI, Saad. **Understanding of a convolutional neural network.** In: 2017 international conference on engineering and technology (ICET). Ieee, 2017. p. 1-6.

BORREGO-CARAZO, J.; CASTELLS-RUFAS, D.; BIEMPICA, E.; CARRABINA, J.; **Resource-Constrained Machine Learning for ADAS: A Systematic Review** in IEEE Access, vol. 8, pp. 40573-40598, 2020.

CHANTSALNYAM, Tuvshinbayar *et al.* **ncRDeep: Non-coding RNA classification with convolutional neural network.** *Computational Biology and Chemistry*, v. 88, p. 107364, 2020.

CONFEDERAÇÃO BRASILEIRA DOS MUNICÍPIOS - CNM. **Mapeamento das mortes por acidentes de trânsito no Brasil.** Estudos Técnicos da Confederação Brasileira dos Municípios, Brasília, 2009.

DERETIĆ, NEMANJA; STANIMIROVIĆ, DRAGAN. **The Impact of the Age of the Vehicle Fleet on Traffic Safety-Vehicle as the Third Pillar of Traffic Safety.** *JOURNAL TTTP-TRAFFIC AND TRANSPORT THEORY AND PRACTICE*, v. 6, n. 2, p. 65-71, 2021.

NOGARE, DIEGO. **Performance de Machine Learning – Matriz de Confusão.** Disponível em: <<https://diegonogare.net/2020/04/performance-de-machine-learning-matriz-de-confusao/>>. Acesso em: 09/04/2022

DI RENNA, R. B. *et al.* **Introdução ao kit de desenvolvimento Arduino.** Universidade Federal Fluminense, Escola de Engenharia. Rio de Janeiro, 2013.

DIAS, B. R.; JAREK, F. L. **SISTEMA EMBARCADO PARA PROCESSAMENTO DE IMAGENS.** Trabalho de conclusão de curso (Graduação em Engenharia Elétrica) - Departamento de Engenharia Elétrica, Setor de Tecnologia, Universidade Federal do Paraná (UTFPR), Curitiba. 2011.

FILHO, MARIO. **Precisão, Recall e F1 Score Em Machine Learning.** Disponível em:< <https://mariofilho.com/precisao-recall-e-f1-score-em-machine-learning/>>. Acesso em: 19/08/2023.

GOMES, B. **Alerta de colisão pode ser instalado em carros mais antigos; entenda como...** Disponível em: <<https://www.uol.com.br/carros/colunas/bene-gomes/2020/03/29/alerta-de-colisao-pode-ser-instalado-em-carros-mais-antigos-entenda-como-04028C9B3160E0B96326.htm>>. Acesso em:14/03/2022.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais.** [s.l.] Edgard Blucher, 2000.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens. tradução: Cristina Yamagami e leonardo piamonte.** [s.l.] Pearson Prentice Hall, São Paulo, 2010.

HE, Panbo *et al.* **HRM: An Intelligent Helmet Recognition Model in Complex Scenes.** *Advances in Mathematical Physics*, v. 2022, 2022.

J. Dahl, G. R. De Campos, C. Olsson And J. Fredriksson, **Collision Avoidance: A Literature Review on Threat-Assessment Techniques**, in IEEE Transactions on Intelligent Vehicles, vol. 4, no. 1, pp. 101-113, March 2019.

JOCHER,G.**Train Custom Data.** Disponível em:< [https://docs.ultralytics.com/yolov5/tutorials/train\\_custom\\_data/#local-logging](https://docs.ultralytics.com/yolov5/tutorials/train_custom_data/#local-logging)>. Acesso em: 31/07/2023

JUNIOR, J. A. C.; SANTOS, L. B. **Estado e Indústria Automobilística no Brasil: Análise das Políticas Inovar-Auto e Rota 2030.** *ENTRE-LUGAR*, v. 11, n. 21, p. 101-127, 2020.

KIM, J. **Effectiveness of Collision Avoidance Technology.** University of Missouri, 2016.

KÜHNE, Felipe. **YOLO: detecção de classes de objetos em tempo real.** Disponível em: <<https://www.profissionaisti.com.br/yolo-deteccao-objetos-tempo-real/>>. Acesso em: 31/07/2023

LECUN, Y., BENGIO, Y. & HINTON, G. **DEEP LEARNING.** *Nature* 521, 436–444, 2015.

LEIBE, Bastian *et al.* Dynamic 3d scene analysis from a moving vehicle. In: **2007 IEEE conference on computer vision and pattern recognition**. IEEE, 2007. p. 1-8.

LICCIARDI, A. Newton Jr. **INTERNET DAS COISAS, TELECOMUNICAÇÕES, EDGE COMPUTING**. 7 abr. 2022. Apresentação do Power Point. Acesso em 09/04/2022.

LIU, Yifan *et al.* **Research on the Use of YOLOv5 Object Detection Algorithm in Mask Wearing Recognition**. World Scientific Research Journal ; 6(11):276-284, 2020.

MITCHELL, Tom M. **Machine learning**. Vol. 1, bk. 9. : McGraw-hill New York, 1997.

MONTAVON, G.; SAMEK, W.; MÜLLER, K.-R. **METHODS FOR INTERPRETING AND UNDERSTANDING DEEP NEURAL NETWORKS**. Elsevier Inc, Technische Universität Berlin, Berlin, Alemanha, 2017.

MORENGONI, M. E STRINGHINI, D. **Tutorial: Introdução à Visão Computacional usando OpenCV**. RITA v. 16, n. 1. UFRGS, Porto Alegre. 2009.

MORRIS, T. **Computer vision and image processing**. Basingstoke: Palgrave Macmillan, 2004

NHTSA. **Safety Technologies | NHTSA**. Disponível em: <<https://www.nhtsa.gov/equipment/driver-assistance-technologies#15226>>. Acesso em: 15/03/2022.

NUNES, ANGELITA BARBOSA. **Análise de Resultados Benchmarks para Escalonamento de Tarefas de Tempo Real em Máquinas Heterogêneas**. 2016. 37f. Trabalho de Conclusão de Curso (Graduação em Ciência da Computação) – Departamento Acadêmico de Informática, Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2016.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS - ONU. **Transformando nosso mundo: A Agenda 2030 para o Desenvolvimento Sustentável**. Objetivos de Desenvolvimento Sustentável, 2015. Disponível em: <<https://nacoesunidas.org/wpcontent/uploads/2015/10/agenda2030-pt-br.pdf>>. Acesso em:14/03/2022.

OSNV. **90% DOS ACIDENTES SÃO CAUSADOS POR FALHAS HUMANAS, ALERTA OBSERVATÓRIO**. Disponível em: <<https://www.osnv.org.br/90-dos-acidentes-sao-causados-por-falhas-humanas-alerta-observatorio/#:~:text=Por%20isso%20%C3%A9%20sempre%20oportuno,Fator%20Ve%C3%ADculo%20e%20Fator%20Via%E2%80%9D>>. Acesso em: 14/03/2022.

PADILLA, R., NETTO, S. L., & DA SILVA, E. A. B. (2020). **A Survey on Performance Metrics for Object-Detection Algorithms**. International Conference on Systems, Signals and Image Processing (IWSSIP) 2020.

PAIXÃO, L.M.M.; GONTIJO, E.D.; MINGOT, S.A.; COSTA, D.A.S.; FRICHE, A.A.L.; CAIAFFA, W.T. (2015). **Óbitos no trânsito urbano: qualificação da informação e caracterização de grupos vulneráveis**. Cad. Saúde Pública, v.31, Sup1, S1:S15.

PAWAR, Rutuparn *et al.* Real-Time Detection of Vehicles on South Asian Roads. In: **Machine Learning, Image Processing, Network Security and Data Sciences: Select Proceedings of 3rd International Conference on MIND 2021**. Singapore: Springer Nature Singapore, 2023. p. 413-427.

PINESI, Gabriel. **FCW-project**. Disponível em: <[www.github.com/Gabriel-sci/FCW-project](http://www.github.com/Gabriel-sci/FCW-project)>.

PONN, Thomas; KRÖGER, Thomas; DIERMEYER, Frank. Identification and explanation of challenging conditions for camera-based object detection of automated vehicles. *Sensors*, v. 20, n. 13, p. 3699, 2020. SANTOS, M. M. D. **FRONT CAMERA UNIT TO SUPPORT FEATURES OF ADVANCED DRIVER ASSISTANCE SYSTEM**. UTFPR: 2015.

SHALF, John. **The future of computing beyond Moore's Law**. Philosophical Transactions of the Royal Society A, v. 378, n. 2166, p. 20190061, 2020.

SHAPIRO, L.; STOCKMAN, G. C. **Computer vision**. 2001. ed: Prentice Hall, 2001.

SILVA, C. **Frota Brasileira é a mais velha dos últimos 25 anos**. Disponível em: <<https://economia.estadao.com.br/noticias/geral,frota-brasileira-e-a-mais-velha-dos-ultimos-25-anos,70003654698>>. Acesso em:15/03/2022

SILVA, MARCOS. **Matriz de Confusão e AUC ROC**. Disponível em: < <https://medium.com/data-hackers/matriz-de-confus%C3%A3o-e-auc-roc-f7e446dca107>>. Acesso em: 09/04/2022

SINDIPEÇAS. **Relatório da frota circulante – Edição 2021**. Disponível em: <<https://www.sindipecas.org.br/area-atuacao/?co=s&a=frota-circulante>>. Acesso em:14/03/2022.

SOARES, T., AMARANTE, M., & AGUIAR SILVA, M. (2018, junho 4). **Estudo do carro mais seguro do mundo**. Revista Pesquisa E Ação, 4(1), 183-191. Recuperado de <https://revistas.brazcubas.br/index.php/pesquisa/article/view/395>.

SOLAWETZ, JACOB. **What is Mean Average Precision (mAP) in Object Detection?** Disponível em: <https://blog.roboflow.com/mean-average-precision/>. Acesso em: 19/08/2023

SOUZA, Edinilsa Ramos de; LIMA, Maria Luiza Carvalho de. **Panorama da violência urbana no Brasil e suas capitais**. Ciência & Saúde Coletiva, v. 11, p. 1211-1222, 2006.

SUN, IAN. **Introduction to Internet of Things (IoT) and Examples in Taiwan**. Disponível em: <<https://iansuny.medium.com/introduction-to-internet-of-things-iot-and-examples-in-taiwan-2be0135ae780>>. Acesso em: 09/04/2022

TIGADI, ARUN *et al.* **Advanced driver assistance systems**. International Journal of Engineering Research and General Science, v. 4, n. 3, p. 151-158, 2016.

WALCZAK, Steven. CERPA, Narciso. **Artificial Neural Networks**. 10.1016/B0-12-227410-5/00837-1. 2003.

WORLD HEALTH ORGANIZATION - WHO. **Global status report on road safety 2018**. Disponível em: <<https://www.who.int/publications/i/item/9789241565684>>. Acesso em: 14/03/2002

WORLD HEALTH ORGANIZATION - WHO. **Injuries and Violence: The Facts**. WHO Library Cataloguing in Publication Data. Geneva, 2014. Disponível em: <[http://apps.who.int/iris/bitstream/10665/44288/1/9789241599375\\_eng.pdf](http://apps.who.int/iris/bitstream/10665/44288/1/9789241599375_eng.pdf)>. Acesso em: 17/03/2022

WU, Yanbin *et al.* **Eye movements predict driver reaction time to takeover request in automated driving: A real-vehicle study**. Transportation research part F: traffic psychology and behaviour, v. 81, p. 355-363, 2021.

YAZDI, Mohammad *et al.* **An improved lasso regression model for evaluating the efficiency of intervention actions in a system reliability analysis**. Neural Computing and Applications, v. 33, n. 13, p. 7913-7928, 2021.

**Contatos:** gabrielcp2002@gmail.com e newton.licciardijr@gmail.com