



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS FLORIANO
CURSO TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE
SISTEMAS

DANIEL DE SOUSA BARBOSA

IMPLEMENTAÇÃO DE UM SISTEMA DE MONITORAMENTO INTELIGENTE
COM RASTREAMENTO DE VEÍCULOS E IDENTIFICAÇÃO DE PLACAS
UTILIZANDO VISÃO COMPUTACIONAL

FLORIANO
2024

DANIEL DE SOUSA BARBOSA

**IMPLEMENTAÇÃO DE UM SISTEMA DE MONITORAMENTO INTELIGENTE
COM RASTREAMENTO DE VEÍCULOS E IDENTIFICAÇÃO DE PLACAS
UTILIZANDO VISÃO COMPUTACIONAL**

Trabalho de Conclusão de Curso (artigo científico)
apresentado como exigência parcial para obtenção
do diploma do Curso de Tecnologia em Análise e
Desenvolvimento de Sistemas do Instituto Federal
de Educação, Ciência e Tecnologia do Piauí,
Campus Floriano.

Orientador : Prof. Dr. Willamys Rangel Nunes de
Sousa

FLORIANO

2024

IMPLEMENTAÇÃO DE UM SISTEMA DE MONITORAMENTO INTELIGENTE COM RASTREAMENTO DE VEÍCULOS E IDENTIFICAÇÃO DE PLACAS UTILIZANDO VISÃO COMPUTACIONAL

Daniel de Sousa barbosa¹
Willamys Rangel Nunes de Sousa²

RESUMO

Este estudo concentra-se em aprimorar o monitoramento de veículos por meio da Visão Computacional e do reconhecimento óptico de caracteres (OCR). Com o aumento constante da frota de veículos, tornou-se crucial desenvolver sistemas de monitoramento mais avançados. O estudo apresenta um algoritmo eficiente para identificar os caracteres das placas dos veículos, testado e validado no estacionamento do Instituto Federal do Piauí (IFPI) campus Floriano. A metodologia incluiu um amplo levantamento bibliográfico, aquisição e treinamento de dados de dois bancos diferentes, e o desenvolvimento e teste do modelo proposto. Esse algoritmo oferece suporte valioso aos profissionais responsáveis pela vigilância e monitoramento em ambientes específicos, destacando perspectivas promissoras para otimizar sistemas de segurança e eficiência no monitoramento veicular. A integração de técnicas avançadas de Visão Computacional e reconhecimento óptico de caracteres surge como uma solução prática e acessível, trazendo agilidade e economia nos processos de identificação e rastreamento de veículos, contribuindo assim para o avanço dos sistemas de monitoramento e segurança viária.

Palavras-chave: visão computacional; monitoramento veicular; Reconhecimento óptico de caracteres; identificação de placas.

ABSTRACT

This study focuses on enhancing vehicle monitoring through Computer Vision and Optical Character Recognition (OCR). With the constant increase in the vehicle fleet, developing more advanced monitoring systems has become crucial. The study presents an efficient algorithm to identify vehicle plate characters, tested and validated at the Instituto Federal do Piauí (IFPI) campus Floriano parking lot. The methodology involved extensive literature review, acquisition, and training of data from two different databases, and the development and testing of the proposed model. This algorithm provides valuable support to professionals responsible for surveillance and monitoring in specific environments, highlighting promising prospects to optimize security systems and efficiency in vehicle monitoring. The integration of advanced Computer Vision and OCR techniques emerges as a practical and accessible solution, streamlining vehicle identification and tracking processes, thereby contributing to the advancement of monitoring and road safety systems.

Keywords: computer vision; vehicle monitoring; optical character recognition; license plate identification.

Data de aprovação: 09/01/2024 (data de apresentação do TCC)

¹ Graduando em Análise e Desenvolvimento de Sistemas. IFPI - campus Floriano. caflo.20191s.25.06@aluno.ifpi.edu.br.

² Professor do Ensino Básico, Técnico e Tecnológico. IFPI - campus Floriano. rangelnunes@ifpi.edu.br.

1 INTRODUÇÃO

Ao longo do tempo, o aumento significativo na quantidade de veículos em circulação tem desafiado o gerenciamento do tráfego e a segurança viária. De acordo com dados disponibilizados pela SENATRAN - Secretaria Nacional de Trânsito, no Brasil, a frota ativa já alcança aproximadamente 118 milhões de unidades, sendo 74,56% referentes a automóveis e motocicletas. Esse crescimento expressivo requer sistemas de monitoramento mais eficientes (Ministério dos Transportes, 2023).

A complexidade e a intensificação do tráfego atual exigem sistemas de monitoramento robustos para lidar com questões como congestionamentos, segurança viária e gestão eficaz do fluxo de veículos. Essa necessidade urgente de soluções tecnológicas mais avançadas é destacada pelo crescimento do número de veículos, para o qual os métodos convencionais não têm conseguido atender (Santos, 2021).

Nesse contexto, a Visão Computacional emerge como uma solução promissora para o monitoramento veicular, oferecendo recursos relevantes e em constante evolução. Suas aplicações incluem técnicas avançadas de detecção de caracteres e classificação de objetos em movimento, com a demanda por uma capacidade computacional reduzida para a realização dessas tarefas (Cortez, 2022).

Um exemplo do uso da visão computacional no monitoramento veicular foi apresentado por Corbolan e Rodrigues (2022). Eles exploraram essa tecnologia para facilitar a identificação das placas dos veículos pelas centrais de monitoramento, utilizando fotografias capturadas por câmeras de segurança. O objetivo principal foi desenvolver uma aplicação para aprimorar as operações das centrais, automatizando a identificação dos caracteres das placas e localizando os veículos com base nas imagens das câmeras.

Outro trabalho nesta vertente foi conduzido por Colodette (2023), que desenvolveu um algoritmo acessível para monitorar a entrada e saída de veículos em ambientes específicos. Utilizando técnicas avançadas de visão computacional e reconhecimento óptico de caracteres (OCR) com Python, OpenCV e Tesseract, o projeto visou atender à crescente demanda por tecnologias acessíveis de monitoramento. Diferenciando-se de sistemas onerosos ou que necessitam de pré-registro de veículos, essa abordagem utiliza um *Raspberry Pi* para processar localmente a detecção e identificação de placas de veículos, tornando o processo mais ágil, sustentável e economicamente viável.

Frente à necessidade de aprimorar os procedimentos existentes, este estudo foi desenvolvido para auxiliar no monitoramento veicular, especificamente na identificação e rastreamento de veículos e suas placas. O algoritmo proposto revela sua eficiência ao decifrar os caracteres das placas dos veículos, dentro do campo de visão de uma câmera, possibilitando a elaboração de relatórios personalizados. A validação desse método foi conduzida no estacionamento do Instituto Federal do Piauí (IFPI) campus Floriano, fornecendo um suporte valioso aos profissionais responsáveis pela vigilância e monitoramento em ambientes específicos.

2 FUNDAMENTAÇÃO TEÓRICA

A Inteligência Artificial (IA) representa um ramo da ciência da computação dedicado à concepção e implementação de algoritmos e sistemas aptos a executarem atividades que requerem capacidades comparáveis à inteligência humana. Entre os exemplos preeminentes de aplicação da IA, destacam-se a habilidade de interação verbal por meio de assistentes pessoais em dispositivos móveis, bem como a capacidade de perceber e interpretar o ambiente, evidenciada no reconhecimento de padrões visuais por veículos autônomos (Garcia, 2020).

A versatilidade da IA permite sua aplicação em diversos setores, destacando-se na área da medicina, onde desempenha um papel significativo em múltiplos campos. Notavelmente, ela tem contribuído para o aprimoramento das técnicas associadas à saúde em seu contexto mais abrangente. Além disso, seu uso tem sido especialmente marcante na análise de imagens médicas e na realização de previsões (Braga *et al.*, 2019).

Ademais, outra área que vem crescendo bastante é a da extração de dados através de informações presentes em imagens, como o trabalho realizado por Kroth (2023), que consiste na construção de um protótipo de *web service*³ que conseguia, através de técnicas de IA, identificar o tipo, a marca e a cor predominante de veículos, presentes em fotografias digitais, como ilustrado na Figura 1, onde é mostrado o algoritmo reconhecendo a marca dos veículos presentes na imagem.

Figura 1 - Identificação de marcas dos veículos.



Fonte: Kroth (2023).

³ web service é uma tecnologia que permite que diferentes aplicativos se comuniquem pela internet, trocando dados e serviços entre si de forma padronizada e independente de plataforma.

2.1 VISÃO COMPUTACIONAL


A visão computacional representa uma área específica dentro do campo da IA, cujo objetivo central é dotar as máquinas da capacidade de interpretar e compreender informações visuais presentes em imagens ou vídeos, onde concentra-se na criação e no desenvolvimento de algoritmos e técnicas que possibilitam às máquinas processar e extrair dados a partir de dados visuais, permitindo, assim, a análise e a compreensão de elementos e padrões contidos nessas informações (Da Silva, 2020).

Após a obtenção desses dados, a visão computacional demonstra a capacidade de processar as imagens adquiridas, visando extrair informações relevantes que possibilitam uma gama de ações, tais como identificação de áreas específicas ou objetos de interesse, além da extração de uma variedade de dados pertinentes, refletindo um paralelo próximo à capacidade perceptiva humana (Backes; Junior; De Mesquita, 2016).

A implementação da visão computacional mostra utilidade significativa em diversos campos. Diversas aplicações exemplificam essa utilização, como o uso de câmeras inteligentes capazes de reconhecer rostos ao capturar imagens, sua aplicação na inspeção visual durante processos de controle de qualidade industrial, na viabilização de voos autônomos não tripulados, na interpretação automatizada de exames médicos, na análise de tecidos biológicos, entre outras áreas de aplicação (Delai; Coelho, 2012).

Uma aplicação em ascensão da visão computacional é a identificação, segmentação e interpretação de caracteres, permitindo a identificação de textos presentes em diversas áreas através de imagens. Por exemplo, como mostrado na Figura 2, sistemas de monitoramento veicular podem extrair informações de imagens às quais têm acesso e aproveitar essa capacidade para identificar com maior precisão e eficiência os caracteres das placas de carros (Corbolan; Rodrigues, 2022)

Figura 2 - Identificação de caracteres em placas de carros.



Fonte: Corbolan; Rodrigues (2022).


2.2 REDES NEURAIIS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) constituem uma área de pesquisa fundamental na Inteligência Artificial (IA), buscando emular a capacidade cognitiva humana. Este campo está voltado para a capacidade de aprender a partir de modelos prévios, visando atingir uma eficaz capacidade de generalização (Fleck *et al.*, 2016).

O processo de treinamento de uma rede neural é reconhecido como o pilar fundamental no aprendizado desses modelos, associando estímulos de entrada às respostas desejadas na saída. Uma das vantagens fundamentais no emprego de Redes Neurais Artificiais (RNAs) é sua capacidade intrínseca de minimizar o impacto de variações, como mudanças de escala e rotação, nos resultados gerados (Moreira, 2013).

O uso generalizado de Redes Neurais Artificiais (RNAs) está se expandindo devido à sua adaptabilidade a uma ampla gama de estudos de caso em diversos campos. Por exemplo, como apresentado na Figura 3, Meireles e Cendón (2010) exploraram o uso de RNAs na análise de citações em artigos relacionados a esta área.

Figura 3 - Ocorrência de citações por autor.



Fonte: Meireles; Cendón (2010).

Similarmente, Alves (2016) empregou redes neurais do tipo MLP (*Multi Layer Perceptron*) que utilizou um neurônio para cada uma das variáveis de entrada para estimar a produtividade da soja, onde esses dados foram exportados em um arquivo em formato *CSV*, contendo os resultados detalhadamente, como representados abaixo, na Figura 4. Esses exemplos evidenciam a diversidade de aplicações potenciais das RNAs em diferentes domínios.

Figura 4 - Estimativa da Produtividade de Soja.

	A	B	C	D	E	F	G	H	I	J
1	C2	C3	D2	D3	A	R	V	G	PMS	Produtividade
2	0	0	0	0	-0,01044444	0,02857143	-0,30571429	-0,29351536	-0,28870286	0,43344772
3	0	0	0	0	-0,12155556	0,47142857	0,23714286	-0,25051760	0,33554857	0,57929865
4	0	0	0	0	-0,07844444	0,00000000	-0,24142857	-0,32699419	-0,18180571	0,24086991
5	0	0	1	0	-0,18955556	-0,10000000	-0,03000000	-0,36157467	0,04282857	0,17437394
6	0	0	1	0	-0,11240329	0,00899471	-0,12783069	-0,31481095	-0,03643280	-0,05727004
7	0	0	1	0	-0,09592593	0,00000000	-0,16349206	-0,31172339	-0,07404444	0,03819886
8	0	0	1	0	-0,05172840	0,12698413	-0,19000000	-0,26336832	-0,07808254	0,20278091
9	0	0	0	1	-0,13488889	-0,24285714	-0,20285714	-0,40628166	-0,25700571	0,49858569
10	0	0	0	1	-0,02500000	-0,41428571	-0,57000000	-0,32502078	-0,61761143	-0,21651252
11	0	0	0	1	-0,01866667	-0,10000000	-0,30142857	-0,39219015	-0,38569143	0,27204812

Fonte: Alves (2016).


2.3 REDES NEURAIS CONVOLUCIONAIS

As Redes Neurais Convolucionais (CNNs) são um tipo importante de Redes Neurais Profundas (DNNs) e, no campo do aprendizado de máquina, são amplamente utilizadas para lidar com desafios relacionados à visão computacional. Estas redes são inspiradas na estrutura hierárquica do córtex visual humano e se destacam por sua capacidade de processamento estratificado de informações. Semelhante a outras redes neurais artificiais, as CNNs são compostas por neurônios artificiais, atuando como blocos fundamentais para aprender e extrair características significativas dos dados de entrada (Lopez; Mattos, 2021).

As CNNs apresentam uma arquitetura frequentemente organizada em múltiplas camadas, sendo as camadas de convolução uma parte fundamental desse arranjo. Estas camadas desempenham um papel crucial na identificação e extração de características essenciais de imagens. Pode-se conceituá-las como conjuntos de filtros adaptativos que percorrem a imagem, cada um deles dedicado a capturar e reconhecer uma característica específica (Cunha, 2020). Esta capacidade de explorar padrões em diferentes regiões da imagem, de forma progressiva e hierárquica ao longo das camadas, confere às CNNs uma eficiência notável na compreensão e análise de informações visuais complexas.

Portanto, encontramos uma sucessão estruturada de camadas, onde cada uma delas desempenha uma função específica na propagação do sinal de entrada, como demonstrado na Figura 5.

Figura 5 - Modelo de Rede Neural Convolucional.



Fonte: Poloni (2022).

Tradicionalmente, identificamos três categorias principais de camadas: convolucionais, de subamostragem e totalmente conectadas. Cada camada tem um papel determinante na transformação e processamento sequencial dos dados, viabilizando a identificação e interpretação de características complexas em espaços multidimensionais. Essa organização camada a camada é crucial para a aprendizagem progressiva de representações hierárquicas, desempenhando um papel fundamental em uma variedade de aplicações que requerem análise detalhada e extração de padrões em conjuntos de dados complexos (Poloni, 2022).

Como ilustrado na Figura 5, as camadas convolucionais assumem o papel de extração de características, seja das camadas precedentes ou da própria imagem inicial, quando se trata da primeira camada da rede. As camadas de subamostragem, por sua vez, desempenham a função de reduzir a dimensionalidade dos dados, ao mesmo tempo em que promovem invariância a pequenas translações na entrada. Por fim, as camadas totalmente conectadas são responsáveis por propagar o sinal através da multiplicação ponto a ponto e pela aplicação de uma função de ativação. Destaca-se que a última camada tem como saída o valor de probabilidade associado à pertinência da imagem de entrada a uma das classes para as quais a rede foi treinada, variando de acordo com a função de ativação empregada (Poloni, 2022).

2.4 DETECÇÃO E RASTREAMENTO DE OBJETOS EM IMAGENS UTILIZANDO O YOLO

O método YOLO (*You Only Look Once*) revoluciona a detecção de objetos ao empregar uma única rede convolucional dedicada a identificar elementos em imagens. Sua singularidade reside na simulação do processo cognitivo humano: da mesma maneira que nós, ao observar uma imagem, ele identifica os objetos presentes, determinando suas localizações e interações no ambiente visual (Redmon, 2016).

Na visão computacional, a detecção de objetos representa uma fase crucial que abrange não apenas a identificação, mas também o posicionamento preciso de elementos de interesse dentro de uma imagem. Além de reconhecer os tipos de objetos presentes, a ênfase recai na localização exata desses elementos, alcançada através do uso de caixas delimitadoras (Redmon *et al.*, 2016).

Essa abordagem não apenas reconhece uma vasta gama de objetos, mas os categoriza em classes predefinidas, como carros, pessoas e animais, acompanhadas pela indicação de suas coordenadas espaciais na imagem. Essa metodologia não só permite uma identificação mais precisa, mas também discrimina os objetos de forma mais eficiente dentro do contexto visual (Leal, 2023).

Um exemplo notável que ilustra a eficácia do método YOLO é um estudo conduzido por Albuquerque *et al.* (2022). Neste estudo, o detector de objetos YOLO foi empregado para distinguir entre operárias e zangões de abelhas melíferas. Essa pesquisa desempenha um papel vital no avanço da apicultura de precisão, uma vez que, por meio da validação cruzada, a arquitetura adotada demonstrou sua eficácia ao identificar e classificar com exatidão a maioria das abelhas presentes nas imagens, evidenciando seu potencial prático e impacto significativo na área como demonstrado na figura 6.

Figura 6 - Identificação de tipos de abelhas melíferas.



Fonte: Albuquerque *et al.* (2022).

2.5 RECONHECIMENTO DE PLACAS VEICULARES UTILIZANDO VISÃO COMPUTACIONAL

A visão computacional desempenha um papel fundamental na melhoria da autenticação veicular, especialmente quando combinada com sistemas de monitoramento por câmeras e softwares inteligentes (Wojahn, 2022).

Segundo Jesus *et al.* (2022), a automação do processo de autenticação, por meio do reconhecimento dos caracteres presentes nas placas de veículos, agiliza a entrada e saída em ambientes controlados. Isso a torna uma poderosa aliada para a segurança e eficiência dos sistemas baseados em reconhecimento de placas de carros, elevando a confiabilidade nos processos de controle de acesso.

A aplicação dessas tecnologias começa com as técnicas da visão computacional, que seguem uma sequência específica: segmentação, extração de características e classificação. Essa mesma sequência é empregada no processo de identificação de caracteres nas placas de veículos (Prazeres *et al.*, 2018).

Além dessas técnicas, é comum o uso do reconhecimento óptico de caracteres (OCR - Optical Character Recognition). Os sistemas de OCR conseguem extrair eficientemente informações relevantes das placas, como números e letras, mesmo em condições desafiadoras, como baixa iluminação ou ângulos variados de visão (Fernandes, 2019). Essa capacidade de interpretar grandes volumes de dados de imagens em tempo real é notável.

Essas metodologias são frequentemente combinadas e otimizadas com o uso de redes neurais artificiais (RNAs) e algoritmos de aprendizado de máquina. Essa estratégia é crucial para aumentar tanto a precisão quanto a confiabilidade do reconhecimento de placas por meio da visão computacional. A sinergia entre essas tecnologias proporciona uma base sólida para avanços contínuos no monitoramento veicular, melhorando consideravelmente os sistemas de segurança e controle de acesso.

2.6 VISÃO COMPUTACIONAL APLICADA AO MONITORAMENTO DE VEÍCULOS

A visão computacional emerge como uma ferramenta capaz de complementar ou até mesmo substituir atividades manuais em diversos setores. Em particular, destaca-se sua relevância no monitoramento de veículos que circulam diariamente em ambientes específicos. Alguns algoritmos notáveis, como HAAR (*Haar-like features*), HOG (*Histogram of Oriented Gradients*) e CNN (*Convolutional Neural Network*), se destacam como os mais empregados na detecção de imagens e padrões (Nogueira; Lima; Oliveira, 2019).


A integração da visão computacional é amplamente adotada em sistemas de monitoramento veicular, desempenhando papéis variados, desde o controle de portões e cancelas em garagens e estacionamentos até a gestão do acesso, tempo de permanência e cobrança de vagas. Além disso, é empregada na administração da disponibilidade de vagas no ambiente, entre outras aplicações (Ferreira; Soares, 2012).

O reconhecimento de placas é um dos pilares do monitoramento veicular inteligente, possibilitando uma ampla gama de ações. Um exemplo é o sistema de radares do Departamento de Trânsito (DETRAN), popularmente conhecido como "pardais". Esse sistema monitora a velocidade dos veículos e aplica multas àqueles que excedem os limites permitidos na via, utilizando o reconhecimento dos caracteres presentes nas placas (Stopassole, 2020).

3 METODOLOGIA

Para o desenvolvimento do projeto em questão, cujo objetivo é auxiliar os sistemas de monitoramento identificando os veículos e suas respectivas placas, foram adotados os seguintes procedimentos metodológicos que foram divididos em etapas, conforme apresentado na Figura 7.

Figura 7 - Etapas do processo metodológico.



Fonte: Autoria própria (2023).

O estudo seguiu uma metodologia sequencial, conforme demonstrado na Figura 7. Inicialmente, realizou-se um extenso levantamento bibliográfico nas principais bases de pesquisa para compreender o cenário atual dos sistemas de monitoramento veicular em contextos específicos. Este levantamento visou explorar a relevância contemporânea desses sistemas e as aplicações em que a visão computacional, aliada à integração de redes neurais, desempenha um papel crucial na identificação e interpretação de placas de veículos.

Posteriormente, foi conduzido um processo de aquisição de dados, utilizando dois bancos de dados distintos para propósitos específicos. O primeiro banco de dados foi empregado no treinamento da rede neural para identificar carros, motocicletas e caminhões, utilizando um modelo treinado disponibilizado pela ferramenta *YOLO*⁴. Enquanto isso, o segundo banco de dados foi utilizado para treinar o modelo responsável pelo reconhecimento das placas de veículos.

Embora a ferramenta *YOLO* ofereça um modelo pré-treinado para identificar veículos em imagens capturadas, para treinar o modelo específico responsável pelo reconhecimento das placas dos veículos, foi utilizada uma base de dados robusta, contendo mais de 21 mil imagens de placas em diversas condições e suas respectivas coordenadas. Esta base foi adquirida por meio da plataforma web *Roboflow*⁵, destacando outra vantagem do *YOLO*: a eliminação da necessidade de etapas adicionais no treinamento do modelo. As imagens abrangem uma ampla gama de variações, incluindo diferentes ângulos, condições de iluminação e distâncias.

Com os modelos já treinados, foi iniciado o processo de teste do modelo, utilizando um algoritmo construído utilizando a linguagem de programação *Python*⁶ e uma interface desenvolvida com a biblioteca *Tkinter*⁷ para facilitar seu uso. Já o processo de validação se deu através de um teste em ambiente real realizado no estacionamento do IFPI - Campus Floriano, permitindo a captura de imagens através de uma câmera onde foi possível adquirir informações de veículos em um ambiente real.

⁴ <https://pjreddie.com/darknet/yolo/>

⁵ <https://roboflow.com>


⁶ <https://www.python.org>

⁷ <https://docs.python.org/3/library/tkinter.html>

4 ANÁLISES E RESULTADOS

Após aplicar as etapas descritas no procedimento metodológico, foi adquirido um modelo de rede neural treinado para detectar placas veiculares em ambientes específicos. Este modelo demonstrou capacidade de identificação em uma variedade de situações, incluindo variações de ângulos, iluminação e cores, entre outras condições. Os resultados deste treinamento estão detalhados na Figura 8 para uma análise mais aprofundada.

Figura 8 - Resultados do treinamento da rede neural para detecção de placas veiculares.



Fonte: Autoria própria(2023).

A análise das curvas de confiança detalhadas pela Figura 8 revela um bom desempenho do modelo de rede neural.

A confiança da precisão exibindo um valor de 1.00 até 0.877 indica uma precisão consistente e excepcionalmente alta em suas previsões, evidenciando a confiabilidade do modelo em classificar corretamente as instâncias positivas. Além disso, o *Recall* de 0.98 até 0.00 demonstra que, mesmo com um nível de confiança mais baixo, o modelo ainda consegue capturar uma quantidade significativa de instâncias positivas, garantindo uma boa cobertura dos casos relevantes. O *F1 score* de 0.97 até 0.424 reflete um equilíbrio eficaz entre precisão e *recall*, ressaltando a capacidade do modelo de manter um desempenho consistente em diferentes níveis de confiança. Esses resultados indicam a robustez e a capacidade do modelo em lidar com diferentes situações, tornando-o promissor para aplicações práticas que exigem uma balanceada identificação de padrões.

4.1 TESTE DO MODELO

A identificação dos veículos e suas respectivas placas foi conduzida por um algoritmo desenvolvido em *Python*, o qual integra os dois modelos já treinados. Esse algoritmo processa, *frame a frame*, as imagens em tempo real capturadas por uma câmera, empregando a biblioteca *OpenCV*⁸ para operações de visão computacional.

Este procedimento inclui não apenas a identificação dos veículos, mas também o reconhecimento dos caracteres presentes nas placas dos veículos detectados. Essa funcionalidade é viabilizada pelo tratamento específico da área de interesse na imagem, focalizando apenas na região que contém a placa do veículo.


Essa abordagem potencializa o desempenho do algoritmo, direcionando sua atenção exclusivamente para a área de interesse. Os dados obtidos são então registrados em um arquivo CSV, atribuindo a cada veículo um ID único para identificação.

4.2 CONSTRUÇÃO DA INTERFACE

Para a construção da interface da aplicação, foi utilizada a biblioteca *Tkinter*, reconhecida por sua ampla gama de recursos voltados para interfaces gráficas. Nesse contexto, foram incorporados dois botões principais: um destinado a iniciar a captura de imagens pela câmera e outro para interromper esse processo, possibilitando a exportação dos dados pertinentes ao veículo.

Esses dados incluem o ID do veículo, o melhor frame para a identificação da placa, suas coordenadas específicas no frame, suas respectivas precisões e os caracteres presentes na placa. Todas essas informações são registradas em um arquivo CSV para posterior referência. Adicionalmente, foi desenvolvida uma tela que exhibe, em tempo real, as imagens capturadas pela câmera, conforme ilustrado na Figura 9.

Figura 9 - Interface do projeto.



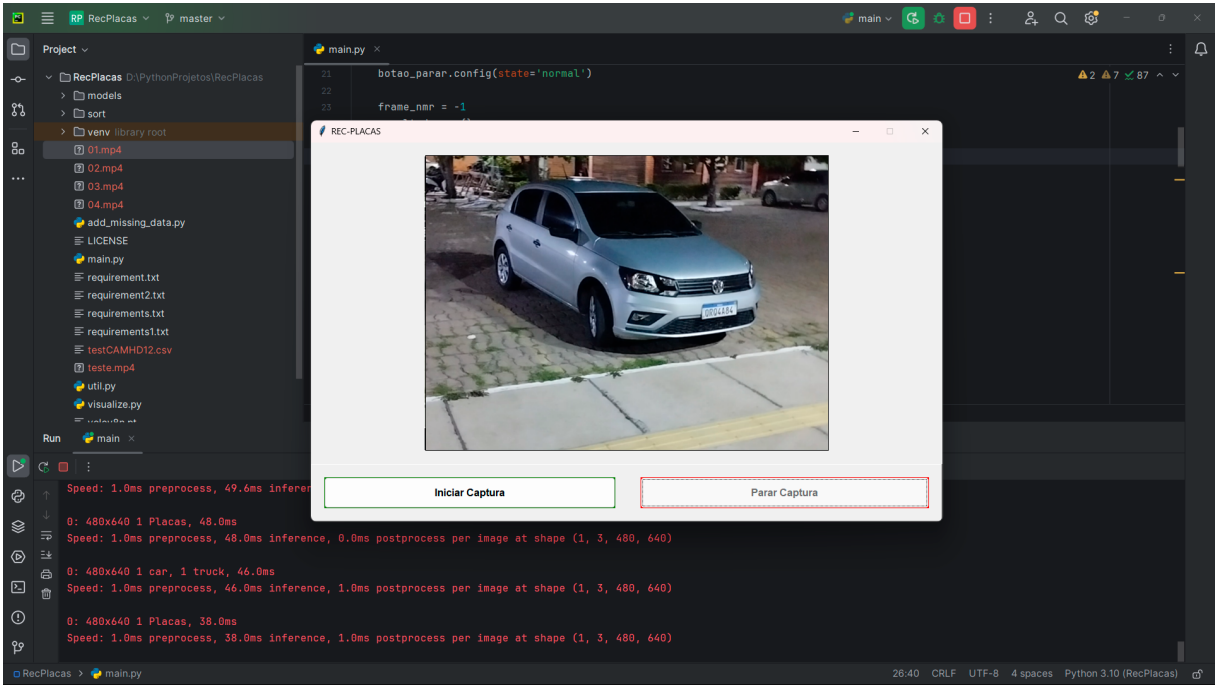
Fonte: Autoria própria (2023).

⁸ <https://opencv.org>

4.3 VALIDAÇÃO DA APLICAÇÃO

Para confirmar a efetividade e o desempenho do projeto em questão, representado pela Figura 10, foram executados testes em um cenário prático no estacionamento do Instituto Federal do Piauí (IFPI), Campus Floriano.

Figura 10 - Teste em ambiente real.



Fonte: Autoria Própria (2023).

As capturas permitiram a identificação imediata e a extração dos dados dos veículos, incluindo o registro de suas placas conforme percorriam a área dentro do campo de visão da câmera. Durante essa análise, os veículos foram classificados por um identificador único (ID) e seus detalhes foram exportados para um arquivo CSV, conforme demonstrado na Figura 11.

Figura 11 - Dados do reconhecimento de veículos em ambiente real.

	A	B	C	D	E	F	G
1	frame_nmr	car_id	carro_bbox	placa_bbox	placa_bbox_score	placa	placa_score
2			[752.7639831240283 1369.258433009659	[976.2636108398438 1751.9381103515625			
			1430.4360742863275 1982.8931752947508]	1210.35400390625 1863.0216064453125]	0.6287685632705688	QRZ3B62	0.66598036794006946
3			[748.0782560818191 1378.2311290714365	[968.3560180664062 1766.3167724609375			
			1424.6946939351217 1996.1644820295228]	1202.3255615234375 1869.68017578125]	0.7723671078681946	RNYGB47	0.8446704715472132
4			[2194.0966294240507 1174.1965144074265	[2409.551025390625 1558.30078125			
			2789.7639398274723 1755.6259437877734]	2590.7900390625 1656.407958984375]	0.41496729850769043	ORQ4A84	0.7106486276346287

Fonte: Autoria Própria (2023).

A Figura 11 oferece uma análise minuciosa dos dados provenientes do algoritmo. Esses dados evidenciam a capacidade do algoritmo desenvolvido para identificar veículos e suas respectivas placas em cenários do mundo real. Além disso, revelam variações na precisão dos caracteres presentes nas placas dos veículos, assim como na identificação geral dos veículos e suas placas. Essa variação destaca a influência do contexto em que o veículo é capturado nas imagens adquiridas, impactando diretamente nos valores retornados pela análise.

5 CONCLUSÃO

O presente estudo propôs e desenvolveu um algoritmo para aprimorar o monitoramento veicular, com foco na identificação e rastreamento eficaz das placas dos veículos. A eficiência demonstrada por este algoritmo ao decifrar os caracteres das placas dos veículos dentro do campo de visão da câmera abre novas possibilidades e aplicações no contexto de vigilância e controle veicular.

A validação realizada no estacionamento do Instituto Federal do Piauí (IFPI) campus Floriano foi fundamental para demonstrar a viabilidade e eficácia prática desse método. Os resultados obtidos podem proporcionar um suporte valioso aos profissionais responsáveis pela vigilância, evidenciando a capacidade do algoritmo em gerar relatórios abrangentes e precisos.

É notável o potencial deste algoritmo para aprimorar não apenas o monitoramento em ambientes específicos, mas também para contribuir significativamente com a segurança e controle de tráfego em espaços urbanos e rodoviários. As aplicações práticas deste estudo podem beneficiar não apenas instituições acadêmicas, mas também órgãos de segurança pública, empresas de monitoramento e gestão de tráfego, entre outros.

Contudo, é importante reconhecer que o desenvolvimento tecnológico é um processo contínuo e dinâmico. Este estudo abre portas para futuras pesquisas que possam aperfeiçoar ainda mais o algoritmo proposto, explorar novas técnicas de reconhecimento e rastreamento veicular, além de considerar diferentes cenários e condições de captura de imagem. Em síntese, este trabalho oferece uma contribuição significativa no campo do monitoramento veicular.

REFERÊNCIAS

- ALBUQUERQUE, Davi Queiroz et al. Aplicando um modelo YOLO para detectar e diferenciar por imagem castas de abelhas melíferas de forma automatizada. In: Anais do XIII Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais. SBC, 2022. p. 51-60.
- ALVES, Guiliano Rangel. Estimativa da produtividade da soja com redes neurais artificiais. 2016. 76f. Dissertação (Mestrado em Engenharia Agrícola) -Câmpus Central - Sede: Anápolis - CET, Universidade Estadual de Goiás, Anápolis.
- BACKES, André Ricardo; JUNIOR, Sá; DE MESQUITA, Jarbas Joaci. Introdução à visão computacional usando Matlab. Alta Books Editora, 2016.
- COLODETTE, Fabrício Louzada. Sistema para o gerenciamento e monitoramento de tráfego de veículos. 2023.
- CORBOLAN, Márcio Oliveira; RODRIGUES, André Ricardo Prazeres. A UTILIZAÇÃO DA VISÃO COMPUTACIONAL NAS CENTRAIS DE MONITORAMENTO PARA AUXILIAR NA IDENTIFICAÇÃO DE PLACAS DE VEÍCULOS. Episteme Transversalis, v. 13, n. 2, 2022.
- CORTEZ, Diogo Eugênio da Silva. Desenvolvimento de um sistema de controle de tráfego inteligente baseado em visão computacional. 2022. Dissertação de Mestrado. Universidade Federal do Rio Grande do Norte.
- CUNHA, Leonardo Cardoso da. Redes neurais convolucionais e segmentação de imagens: uma revisão bibliográfica. 2020.
- DA SILVA, Tarcízio. Visão computacional e racismo algorítmico: branquitude e opacidade no aprendizado de máquina. Revista da Associação Brasileira de Pesquisadores/as Negros/as (ABPN), v. 12, n. 31, 2020.
- DELAI, Riccardo Luigi; COELHO, Alessandra Dutra. Visão computacional com a OpenCV–material apostilado e veículo seguidor autônomo. 2012.
- FERNANDES, Lucas de Sousa. Reconhecimento automático de placas veiculares brasileiras incorporando Max-Margin Object Detection e redes neurais convolucionais. 2019.
- FERREIRA, Luismar Sebastião; SOARES, L. P. Reconhecimento automático de placas veiculares. In: 2012 Workshop de Visão Computacional. 2012.

FLECK, Leandro et al. Redes neurais artificiais: Princípios básicos. Revista Eletrônica Científica Inovação e Tecnologia, v. 1, n. 13, p. 47-57, 2016.

GARCIA, Ana Cristina. Ética e inteligência artificial. Computação Brasil, n. 43, p. 14-22, 2020.

JESUS, Anderson S. et al. Reconhecimento de Placas Veiculares em Cenários Complexos utilizando o Método do Subespaço Mútuo e Redes Neurais Convolucionais. 2022.

KROTH, Christian Fernando. SISTEMA PARA IDENTIFICAÇÃO DAS CARACTERÍSTICAS DE UM VEÍCULO PRESENTE EM IMAGEM DIGITAL. 2023.

LEAL, Danilo Menon. Detecção e rastreamento de objetos em vídeo via rede neural convolucional (CNN): YOLO e DeepSORT aplicados para contar veículos e estimar suas velocidades médias a partir de referencial fixo. 2023.

LOPEZ, Martin Andreoni; MATTOS, Diogo MF. Resumo de grandes volumes de dados com filtro de bloom: Uma abordagem eficiente para aprendizado profundo com redes neurais convolucionais em fluxos de rede. In: Anais do XXXIX Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos. SBC, 2021. p. 532-545.

MEIRELES, M. R. G.; CENDÓN, B. V. Aplicação prática dos processos de análise de conteúdo e de análise de citações em artigos relacionados às Redes Neurais Artificiais. Informação & Informação, [S. l.], v. 15, n. 2, p. 77-93, 2010. DOI: 10.5433/1981-8920.2010v15n2p77.

MINISTÉRIO DOS TRANSPORTES, SENATRAN - Secretaria Nacional de Trânsito. 2023. Disponível em: https://www.gov.br/transportes/pt-br/assuntos/transito/arquivos-senatran/estatisticas/renavam/2023/setembro/frota_reg_uf-tipo_modelo_setembro_2023.xls. Acesso em: 23 set. 2023.

MOREIRA, Alexandre Amaral. Reconhecimento de Placas de Veículos Através da Aplicação de Técnicas de Processamento de Imagens e Redes Neurais Artificiais. 2013.

NOGUEIRA, Luís Felipe; LIMA, Fernando Paim; OLIVEIRA, Paloma Maira. SISTEMA DE IDENTIFICAÇÃO E MONITORAMENTO DE VEÍCULOS EM AMBIENTES CONTROLADOS. 2019.

PRAZERES, Raphael Pires de Mello Alvares et al. Uso de visão computacional e reconhecimento óptico de caracteres para rastreamento e controle de veículos. 2018.

POLONI, K. Redes neurais convolucionais, 2022. Disponível em: <https://medium.com/itau-data/redes-neurais-convolucionais-2206a089c715>. Acesso em: 17 out. 2023.

REDMON, Joseph. Darknet: Open Source Neural Networks in C. 2013--2016. Disponível em: <https://pjreddie.com/darknet>. Acesso em: 18 out 2023.

REDMON, Joseph et al. You only look once: Unified, real-time object detection. In: Proceedings of the IEEE conference on computer vision and pattern recognition. 2016. p. 779-788.

SANTOS, Alef Menezes dos. SMALL: soluções computacionais em mobilidade urbana para auxiliar na consolidação de cidades inteligentes. 2021.

STOPASSOLE, Alisson. Reconhecimento automático de placas veiculares para o controle de estacionamentos baseado em aprendizado de máquina e visão computacional. 2020. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.

WOJAHN, Carlos Cristiano. Sistema de detecção de veículos e análise de situação cadastral. 2022.