



REVISTA BRASILEIRA DE MECATRÔNICA
FACULDADE SENAI DE TECNOLOGIA MECATRÔNICA

**RECONHECIMENTO AUTOMÁTICO DE PLACAS VEICULARES COM VISÃO COMPUTACIONAL
PARA APOIO À GESTÃO DE ESTACIONAMENTOS**

**AUTOMATIC LICENSE PLATE RECOGNITION USING COMPUTER VISION FOR PARKING
MANAGEMENT SUPPORT**

Anderson de Jesus Riva^{1, i}
João Victor de Angeli Pudo^{2, ii}
José Firmino Leite da Silva Júnior^{3, iii}
Rafael de Souza Araújo^{4, iv}
Ricardo Hovacker Baldaconi^{5, v}

Data de submissão: (27/05/2025) Data de aprovação: (04/10/2025)

RESUMO

Este trabalho apresenta o desenvolvimento e a avaliação de um sistema de reconhecimento automático de placas veiculares (ALPR) aplicado à gestão de estacionamentos, utilizando hardware de baixo custo e bibliotecas de código aberto. O protótipo foi implementado com câmera integrada de notebook, processamento em Python (OpenCV e EasyOCR) e integração com microcontrolador ESP32 para simulação do acionamento de cancela. Foram conduzidos 500 testes sob diferentes condições de iluminação, ângulo de captura e padrões de placa (Mercosul e antigo). Os resultados demonstraram taxa de acerto global de 84,0 %, com desempenho superior para placas Mercosul (91,0 %) em relação ao modelo antigo (79,3 %). A latência média foi de 248 ms entre captura e acionamento, assegurando operação em quase tempo real. Os achados confirmam a viabilidade da solução para estacionamentos de pequeno e médio porte, com potencial de expansão para integração com cobrança digital, monitoramento de vagas e sistemas inteligentes de mobilidade.

Palavras-chave: visão computacional; OCR; ALPR; estacionamento; ESP32.

¹ Graduado em Manutenção Industrial no Centro Universitário SENAI SP - Campus Roberto Simonsen – Brás. E-mail: zanfinni7@gmail.com

² Graduando em Manutenção Industrial no Centro Universitário SENAI SP - Campus Roberto Simonsen – Brás. E-mail: jvpudo18@gmail.com

³ Graduado em Manutenção Industrial no Centro Universitário SENAI SP - Campus Roberto Simonsen – Brás. E-mail: jose.silvajr@gm.com

⁴ Graduado em Manutenção Industrial no Centro Universitário SENAI SP - Campus Roberto Simonsen – Brás. E-mail: rafaelde.souza@hotmail.com

⁵ Mestre em Tecnologia Nuclear no Centro Universitário SENAI SP - Campus Roberto Simonsen – Brás. E-mail: ricardo.baldaconi@sp.senai.br

ABSTRACT

This study presents the development and evaluation of an Automatic License Plate Recognition (ALPR) system designed to support parking management, implemented with low-cost hardware and open-source libraries. The prototype was built using a notebook's integrated camera, Python-based processing (OpenCV and EasyOCR), and an ESP32 microcontroller to simulate gate control. A total of 500 tests were performed under different lighting conditions, camera angles, and license plate types (Mercosur and legacy). Results showed an overall accuracy rate of 84,0 %, with higher performance for Mercosur plates (91,0 %) compared to legacy ones (79,3 %). The average latency was 248 ms from capture to servo activation, enabling near real-time operation. These findings confirm the feasibility of the proposed solution for small and medium-sized parking facilities, with potential extensions towards digital payment, vacancy monitoring, and smart mobility applications.

Keywords: computer vision; OCR; ALPR; parking; ESP32.

1 INTRODUÇÃO

O crescimento da frota de veículos e a consequente pressão sobre a mobilidade urbana evidenciam a necessidade de soluções tecnológicas para otimizar o gerenciamento de estacionamento. Relatórios recentes demonstram que a congestão permanece um problema significativo, acarretando custos econômicos e ambientais elevados. De acordo com o Global Traffic Scorecard (INRIX, 2024), os motoristas de grandes cidades perderam, em média, dezenas de horas em congestionamentos ao longo do ano, o que demonstra a urgência de sistemas mais inteligentes de mobilidade e controle de fluxo.

Nesse contexto, os sistemas de reconhecimento automático de placas veiculares — ALPR (*Automatic License Plate Recognition*) ou ANPR (*Automatic Number Plate Recognition*) — têm se consolidado como ferramentas fundamentais para automação de controle de acesso e monitoramento. Segundo Lubna, Mufti e Shah (2021), tais sistemas normalmente seguem um *pipeline* estruturado em três etapas: detecção da placa, segmentação de caracteres e reconhecimento óptico de caracteres (OCR). Os autores ressaltam que fatores como iluminação inadequada, desfoque por movimento e oclusões parciais podem comprometer significativamente o desempenho dos algoritmos.

Com os avanços recentes em *deep learning*, surgiram abordagens *end-to-end*, que integram todas as etapas em um único modelo. Al-Batat *et al.* (2022) desenvolveram um sistema baseado em YOLO que realiza simultaneamente a detecção do veículo, a detecção da placa e o reconhecimento dos caracteres, alcançando acurácia média superior a 90 % em cenários complexos. Além disso, Plavac *et al.* (2024) avaliaram o impacto de distorções climáticas e ruído de câmera, demonstrando que, mesmo em condições adversas, redes neurais profundas podem manter resultados satisfatórios quando treinadas com bases diversificadas.

No Brasil, destaca-se o UFPR-ALPR, um banco de dados público composto por 4.500 imagens anotadas em cenários reais, incluindo veículos e câmeras em movimento. O *dataset* é amplamente adotado como referência em pesquisas sobre robustez de sistemas de ALPR e serve como *benchmark* nacional para validação de algoritmos (UFPR-ALPR, s.d.). Além disso, Vargas Neto (2023) desenvolveu uma aplicação baseada em OCR para placas do padrão Mercosul, evidenciando o potencial de soluções acessíveis e adaptadas às especificidades

brasileiras.

1.1 Problema de Pesquisa

Apesar dos avanços descritos, muitas soluções comerciais ainda exigem hardware especializado e infraestrutura de alto custo, o que inviabiliza sua adoção em estacionamentos de pequeno e médio porte. Assim, a questão central é: como projetar e validar um sistema de reconhecimento automático de placas com hardware acessível, mantendo taxas de acerto e tempos de processamento compatíveis com aplicações em tempo real?

1.2 Objetivo(s)

O presente trabalho tem como objetivo avaliar a viabilidade de um *pipeline* de visão computacional com OCR para reconhecimento de placas veiculares em cenários de estacionamento, implementado em hardware de baixo custo, utilizando bibliotecas de código aberto e reportando métricas objetivas de desempenho.

1.3 Justificativa

A adoção de soluções acessíveis e reproduzíveis pode ampliar a automação em estacionamentos menores, reduzir erros operacionais e criar base para aplicações complementares, como integração com cancelas automáticas, monitoramento de vagas e cobrança digital.

Organização do artigo. A Seção 2 apresenta os trabalhos relacionados e a fundamentação teórica. A Seção 3 descreve os materiais e métodos empregados. A Seção 4 expõe os resultados obtidos. A Seção 5 discute as implicações dos achados e limitações. Finalmente, a Seção 6 apresenta as conclusões e propõe trabalhos futuros.

2 REVISÃO DE LITERATURA

Nos últimos anos, a aplicação de *deep learning* em visão computacional consolidou-se como a principal abordagem para tarefas de detecção e reconhecimento, superando métodos tradicionais em acurácia e robustez (Silva; Jung, 2018). Em particular, o reconhecimento automático de placas veiculares (ALPR) tem sido beneficiado por avanços em arquiteturas de redes neurais convolucionais (CNNs) e detectores *end-to-end* que integram todas as etapas do *pipeline* (Huang; Cai; Lan, 2021). No cenário brasileiro, Laroca *et al.* (2019) apresentaram uma abordagem robusta baseada no YOLO para placas nacionais.

Esse avanço recente é sustentado por bases conceituais consolidadas na literatura de inteligência artificial e visão computacional. Russell e Norvig (2016) apresentam uma visão abrangente sobre técnicas de IA, enquanto Goodfellow, Bengio e Courville (2016) sistematizam os fundamentos do aprendizado profundo. LeCun, Bengio e Hinton (2015) discutem as contribuições do *deep learning* para áreas como visão computacional e processamento de linguagem natural. Obras clássicas como Szeliski (2010) e Bradski e Kaehler (2008) oferecem fundamentos em visão computacional e processamento de imagens.

No campo específico do ALPR, Lubna, Mufti e Shah (2021) apresentaram uma revisão

abrangente dos algoritmos empregados, destacando os desafios impostos por iluminação, ângulo e obstruções. Al-Batat *et al.* (2022) propuseram uma abordagem *end-to-end* baseada em *YOLOv4*, alcançando acurácia média superior a 90 % em múltiplos *datasets*. Plavac *et al.* (2024), por sua vez, investigaram os efeitos de distorções climáticas e ruídos de câmera, confirmando que redes neurais profundas, quando treinadas em bases diversificadas, podem manter resultados satisfatórios.

No Brasil, além do UFPR-ALPR, outras pesquisas têm buscado adaptar soluções de reconhecimento de placas às especificidades locais. Vargas Neto (2023) aplicou o OCR Tesseract adaptado para placas do padrão Mercosul, demonstrando a viabilidade de soluções de baixo custo em cenários de estacionamento. Jesus *et al.* (2022) também exploraram o uso de CNNs para placas brasileiras em condições complexas, reportando acurácia próxima de 99 % em ambientes controlados. A Tabela 1 sintetiza os principais trabalhos recentes em ALPR, destacando *datasets*, técnicas e resultados.

Tabela 1 – Trabalhos relacionados em ALPR: datasets, técnicas e principais resultados (2018–2024)

Autor/Ano	Dataset	Técnica aplicada	Principais resultados
Silva; Jung (2018)	Múltiplos (unconstrained)	Detecção e reconhecimento em cenários não controlados	Robustez em cenário real
Huang; Cai; Lan (2021)	Múltiplos (mixed style)	Rede única (detecção+reconhecimento)	Robustez em cenários variados
Laroca <i>et al.</i> (2019)	UFPR-ALPR	CNNs + <i>YOLO</i>	<i>Benchmark</i> nacional
Lubna <i>et al.</i> (2021)	Diversos (survey)	Revisão de algoritmos clássicos e DL	Desafios em iluminação e ângulo
Al-Batat <i>et al.</i> (2022)	Vários públicos	<i>YOLOv4</i> + OCR (<i>end-to-end</i>)	~90 % acurácia média
Plavac <i>et al.</i> (2024)	Sintético + real	CNNs sob condições adversas	Robustez a ruído e clima
Vargas Neto (2023)	Placas Mercosul	OCR Tesseract adaptado	Viabilidade em baixo custo
Jesus <i>et al.</i> (2022)	Dataset nacional	CNN em cenários complexos	~99 % acurácia controlada

Fonte: Elaborado pelos autores baseado em Silva; Jung (2018); Huang; Cai; Lan (2021); Laroca *et al.* (2019); Lubna *et al.* (2021); Al-Batat *et al.* (2022); Plavac *et al.* (2024); Vargas Neto (2023); Jesus *et al.* (2022).

Além das frentes já sumarizadas, a literatura aponta uma transição metodológica relevante entre *pipelines* clássicos e arquiteturas profundas. Nos métodos tradicionais, etapas de binarização, morfologia e segmentação de caracteres dependem fortemente de limiares e regras (Szeliski, 2010; Bradski; Kaehler, 2008). Isso torna o desempenho frágil quando há variações de iluminação, artefatos ópticos ou deformações geométricas, pois pequenos erros na ROI (Região de Interesse / *Region of Interest*) degradam todo o fluxo. Em contraste, detectores baseados em CNNs (variantes de *YOLO*) aprendem representações invariantes e

oferecem maior estabilidade em cenas não controladas (Laroca *et al.*, 2019; Lubna; Mufti; Shah, 2021).

Uma segunda linha evolutiva é a consolidação de arquiteturas *end-to-end*, nas quais a detecção da placa e o reconhecimento dos caracteres são co-otimizados em uma única rede. Essa unificação reduz latência e mitiga acúmulo de erro entre módulos, além de ser mais tolerante a oclusões parciais e perspectivas não ideais (Huang; Cai; Lan, 2021; Al-Batat *et al.*, 2022). Embora demandem mais dados rotulados, esses modelos tendem a manter desempenho em condições de “mundo real”, desde que dados diversos sejam incluídos no treinamento (Goodfellow; Bengio; Courville, 2016; LeCun; Bengio; Hinton, 2015).

No contexto brasileiro, o padrão Mercosul favorece regularidade tipográfica e contraste, o que explica parte do ganho observado em relação ao modelo antigo, tanto na literatura (Laroca *et al.*, 2019; Jesus *et al.*, 2022) quanto no presente estudo. A escolha do OCR continua central: soluções como EasyOCR/Tesseract são competitivas quando a ROI é bem normalizada (correção de perspectiva, ajuste de aspecto) e há estabilização de contraste (CLAHE, denoising leve). Essa abordagem se coaduna com cenários de baixo custo, em que a troca por OCRs neurais mais pesados pode penalizar a latência e complexificar a implantação (Vargas Neto, 2023; Szeliski, 2010; Bradski; Kaehler, 2008).

Quanto à avaliação, trabalhos como Zhao; Yu; Li (2018) defendem protocolos que separem claramente métricas de detecção (IoU/mAP) e de leitura (acerto por placa e por caractere), além de reportar tempo fim-a-fim. Já Plavac *et al.* (2024) evidenciam o papel das condições adversas (reflexos, ruído, clima) na queda de desempenho e indicam a importância de dados representativos do domínio de uso, no caso deste artigo, estacionamentos com suas particularidades de iluminação e ângulo.

2.1 Padrões de placa e tipografia (Mercosul vs. modelo antigo)

A literatura indica que o desenho tipográfico e o contraste do fundo influenciam diretamente a etapa de leitura (OCR). Em ambientes reais, pequenos ganhos de legibilidade no padrão da placa acumulam em melhorias na taxa de acerto fim-a-fim (Laroca *et al.*, 2019; Jesus *et al.*, 2022).

O padrão Mercosul, por adotar maior regularidade de kerning e melhor contraste, tende a reduzir confusões entre pares visuais como O–0, I–1 e B–8, sobretudo quando a região de interesse é retificada e o contraste é equalizado (CLAHE) (Vargas Neto, 2023; Szeliski, 2010; Bradski; Kaehler, 2008). Esses achados ajudam a explicar diferenças sistemáticas de desempenho observadas quando se compara Mercosul ao modelo antigo em cenários operacionais.

2.2 Detecção da placa: heurísticas vs. detectores profundos

Abordagens clássicas baseadas em limiares, morfologia e regras geométricas são eficientes em *setups* controlados, porém sensíveis a variações de iluminação e perspectiva (Szeliski, 2010; Bradski; Kaehler, 2008). Detectores baseados em CNN (variantes do YOLO) aprenderam representações mais invariantes, elevando robustez a oclusões parciais e blur (Laroca *et al.*, 2019; Lubna; Mufti; Shah, 2021). Em cenários com restrição de hardware, a literatura sugere duas estratégias de compromisso: (i) detector profundo leve + OCR tradicional, explorando *preprocessing* cuidadoso, ou (ii) modelo *end-to-end* quando a latência e a disponibilidade de dados rotulados permitirem (Huang; Cai; Lan, 2021; Al-Batat *et al.*,

2022).

2.3 Leitura de caracteres: segmentação explícita vs. leitura sequencial

No eixo do OCR, há duas famílias: (a) *pipeline* com segmentação explícita de caracteres e OCR clássico (rápido, porém frágil a *glare* e *motion blur*), e (b) leitura sequencial (CNN+RNN/CTC), mais tolerante a deformações, mas mais custosa (Goodfellow; Bengio; Courville, 2016; LeCun; Bengio; Hinton, 2015). Em soluções de baixo custo, bibliotecas como EasyOCR/Tesseract permanecem competitivas se a ROI chegar normalizada (perspectiva, escala e contraste) — fato recorrente em estudos brasileiros com placas Mercosul (Vargas Neto, 2023; Jesus *et al.*, 2022). Mecanismos de votação temporal entre *frames* e limiar dinâmico de confiança são descritos como formas simples de estabilização em campo (Dalarmelina; Teixeira; Meneguette, 2020; Zhao; Yu; Li, 2018).

2.4 Pré-processamento e engenharia de captura

Mesmo com detectores profundos, o *preprocessing* é determinante para o OCR: CLAHE eleva microcontraste; filtro bilateral/gaussiano reduz ruído preservando bordas; retificação de perspectiva estabiliza a forma dos caracteres; e máscaras de brilho mitigam reflexos (Szeliski, 2010). Em ambientes *outdoor*, balanço de branco e exposição durante a captura impactam o SNR; controlar esses fatores na origem costuma render mais do que correções a jusante (Lubna; Mufti; Shah, 2021). A recomendação é parcimônia: manter somente etapas que entregam ganho líquido de acurácia sem comprometer a latência fim-a-fim (Zhao; Yu; Li, 2018).

2.5 Robustez em condições adversas e transferência de domínio

Resultados reportados sob chuva, neblina, reflexos intensos e ruído de sensor mostram quedas consistentes de desempenho, inclusive para redes profundas (Plavac *et al.*, 2024). Para mitigar, destacam-se: (i) aumento de dados realista (simulação de blur, *glare* e ruído), (ii) amostragem estratificada por condição (dia/noite, seco/chuvoso, ângulo baixo/alto), e (iii) *fine-tuning* local com dados do ponto de instalação quando possível (Goodfellow; Bengio; Courville, 2016). Em implantações com hardware simples, a literatura aponta ganhos práticos com acumulação temporal (*N-frames* com decisão por voto) e regras de desambiguação quando múltiplas placas aparecem no mesmo quadro (Zhao; Yu; Li, 2018).

2.6 Métricas e protocolos de avaliação reprodutíveis

Há consenso sobre relatar métricas separadas para detecção (mAP com IoU) e leitura (acurácia por placa e por caractere), além de latência fim-a-fim com média, DP, mínimo/máximo e IC95 % (Zhao; Yu; Li, 2018). Também se recomenda estratificar os resultados por cenários críticos (reflexos, múltiplas placas, ângulo elevado), pois médias globais podem mascarar fraquezas que afetam a operação (Plavac *et al.*, 2024). Em perspectiva de implantação, indicadores como falsos positivos por hora, taxa de exceção e tempo médio de abertura conectam a métrica técnica ao impacto no processo (Russell e Norvig, 2016).

2.7 Arquiteturas *end-to-end* e custo computacional

Modelos que integram detecção + leitura em uma única rede obtêm ganhos de latência e reduzem o acúmulo de erro entre módulos (Huang; Cai; Lan, 2021; Al-Batat *et al.*, 2022). O custo principal é a necessidade de grandes volumes de dados rotulados e maior carga computacional em tempo de execução. Em contextos com restrição de hardware, permanece atraente o design híbrido “detector robusto + OCR leve”, desde que se invista em normalização de ROI e em lógicas simples de estabilização temporal (Goodfellow; Bengio; Courville, 2016; LeCun; Bengio; Hinton, 2015).

2.8 Síntese da literatura

Por fim, a literatura converge para três diretrizes que orientam as decisões deste trabalho: (i) arquiteturas profundas para detecção robusta (com ou sem *end-to-end*), (ii) normalização de entrada parcimoniosa para potencializar OCR leve e (iii) métricas transparentes e reproduzíveis, incluindo análise de cenários críticos. Essas diretrizes embasam as escolhas de projeto relatadas a seguir (Russell; Norvig, 2016; Goodfellow; Bengio; Courville, 2016; LeCun; Bengio; Hinton, 2015; Lubna; Mufti; Shah, 2021).

3 METODOLOGIA

3.1 Materiais

Hardware

- Notebook: processador Intel i5, 8 GB RAM, Windows 10 Pro, utilizado para desenvolvimento, processamento de imagens e controle geral do sistema.
- Microcontrolador: ESP32 DevKit v1, com suporte a Wi-Fi e Bluetooth, responsável pela comunicação com o software e acionamento do atuador.
- Servo motor: SG90, torque de 1,8 kg·cm, empregado para simulação de abertura e fechamento de cancela.
- Câmera: integrada ao notebook, configurada em resolução 640×480 pixels a 30 FPS.

Software

- Linguagem: Python 3.10 (via Anaconda).
- Bibliotecas principais:
 - OpenCV 4.8 → processamento e manipulação de imagens;
 - NumPy 1.25 → operações matriciais;
 - Matplotlib 3.8 → visualização de resultados;
 - EasyOCR 1.6 → reconhecimento óptico de caracteres;
 - Pandas 2.1 → manipulação e armazenamento de dados;
 - PySerial 3.5 → comunicação serial com o ESP32.
- IDE Arduino 2.2: utilizada para compilação e gravação do firmware no ESP32.
- Google Cloud Platform: credenciais de acesso e integração via Google Sheets API.

3.2 Métodos

O sistema foi estruturado em quatro etapas principais:

1. Captura de vídeo:
 - Realizada pela câmera do notebook, em resolução 640×480 a 30 FPS. Cada *frame* é processado individualmente.
2. Pré-processamento:
 - Conversão para escala de cinza;
 - Normalização de contraste (CLAHE);
 - Filtros de redução de ruído (Gaussian Blur, kernel 3×3);
 - Segmentação da região de interesse (ROI) com base em detecção de bordas (Canny).
3. Reconhecimento óptico de caracteres (OCR):
 - Implementado com EasyOCR;
 - Idioma configurado para “pt” (português) e “en” (inglês), visando placas do padrão Mercosul e antigo;
 - Threshold mínimo de confiança ajustado para 0,6 (60 %).
4. Integração com planilha e microcontrolador:
 - Resultados registrados em planilha Google Sheets via API;
 - Frequência de atualização a cada detecção confirmada;
 - Comunicação simultânea com ESP32 via PySerial a 115200 baud;
 - O ESP32 interpreta o comando e aciona o servo motor SG90.

3.3 Configuração Experimental

Para validar o sistema, foram conduzidos testes em diferentes condições:

Placas utilizadas:

- 10 placas do padrão Mercosul;
- placas do padrão antigo (pré-Mercosul);
- placas simuladas impressas em papel A4.

Ambiente:

- Estacionamento simulado controlado, com testes em iluminação natural (dia), artificial (lâmpada fluorescente) e mista.

Distâncias:

- 1,5 m a 3,0 m da câmera.

Número total de leituras:

- 500 capturas no total (distribuídas pelas condições).

Critérios de avaliação:

- Taxa de acerto de leitura de caracteres (% de caracteres corretos por placa);
- Latência média de processamento (ms entre captura e acionamento do servo);
- Taxa de falhas (% de leituras incorretas ou não reconhecidas).

3.4 Fluxo do Sistema

O sistema segue o fluxo descrito abaixo:

1. Captura do vídeo pela câmera.
2. Pré-processamento da imagem (filtros, segmentação e extração da ROI).
3. OCR via EasyOCR, com verificação de confiança.
4. Registro automático da leitura no Google Sheets.
5. Envio paralelo do resultado ao ESP32 via PySerial.
6. Acionamento do servo motor SG90 para simulação da cancela.

3.5 Análise estatística

Variáveis e medidas:

A acurácia foi definida como a proporção de leituras corretas por conjunto (n° de leituras corretas / n° total). Para latência, reportou-se média, desvio-padrão (DP), mínimo e máximo em milissegundos (ms).

Intervalos de confiança.

Para proporções (acurácia), foram calculados ICs de 95% pelo método de Wilson. Para a média de latência, utilizou-se IC de 95% baseado na distribuição t de Student ($média \pm t_{0,975,n-1} \cdot DP/\sqrt{n}$).

Comparações entre grupos:

A comparação entre padrões de placa (Mercosul vs. antigo) foi feita por teste do qui-quadrado de independência (2×2), com relato de χ^2 , gl, p e tamanho de efeito ϕ (equivalente a Cramér's V em 2×2). Quando aplicável (ex.: células com expectativa < 5), considerou-se o teste exato de Fisher.

Condições críticas:

As taxas de acerto em cenários adversos (duas placas simultâneas, iluminação adversa/reflexos, ângulo $> 15^\circ$) foram comparadas ao cenário de referência por testes de proporções (qui-quadrado ou Fisher). Em caso de múltiplas comparações, aplicou-se ajuste de Bonferroni.

Pressupostos e alternativas:

Assumiu-se independência entre leituras. Para latência, assumiu-se aproximação normal; caso violada, recomenda-se reportar mediana e IC por *bootstrap* (10.000 reamostragens) como análise de sensibilidade.

Nível de significância e software:

Adotou-se $\alpha = 0,05$, testes bicaudais. As análises foram realizadas em Python 3.10 (NumPy/Pandas/SciPy) e conferidas em planilha eletrônica.

4 RESULTADOS E DISCUSSÕES

4.1 Taxa de Acerto na Leitura das Placas

Foram processadas 500 capturas, abrangendo diferentes condições de iluminação, ângulo de câmera e padrão de placa. Do total, 420 leituras corresponderam exatamente ao texto presente na placa, resultando em uma taxa de acerto global de 84,0 %.

Como mostra a Tabela 2, quando estratificados por padrão de placa, os resultados

indicaram desempenho superior para o modelo Mercosul, com 91,0 % de acertos, em comparação ao modelo antigo, que obteve 79,3 %. Essa diferença foi estatisticamente significativa (qui-quadrado: $\chi^2(1, N=500) \approx 12,15$, $p \approx 0,0005$, $\phi \approx 0,156$), sugerindo que o layout padronizado e o contraste mais elevado das placas Mercosul favorecem o reconhecimento por OCR.

Tabela 2 – Taxa de acerto por tipo de placa

Tipo de placa	Leituras corretas	Leituras incorretas	Total	Taxa de acerto (%)
Mercosul	182	18	200	91,0
Antiga	238	62	300	79,3
Total	420	80	500	84,0

Fonte: Elaborada pelos autores

4.2 Latência de Processamento

O tempo entre a captura da imagem e o acionamento do servo motor apresentou média de 248 ms, com valores mínimos de 190 ms e máximos de 310 ms. A análise da distribuição ($n = 50$) resultou em desvio padrão de 35 ms, com 95 % das observações situadas entre 180–310 ms, confirmando desempenho consistente em condições de quase tempo real. Estes resultados estão organizados na Tabela 3.

Tabela 3 – Estatísticas de latência de processamento

Medida	Valor (ms)
Tempo mínimo	190
Tempo máximo	310
Média	248
Desvio padrão (aprox.)	35
Intervalo de confiança 95 %	[238 – 258]

Fonte: Elaborada pelos autores

4.3 Erros Recorrentes e Causas

Dos 500 testes realizados, aproximadamente 350 ocorreram em condições ideais, enquanto 80 envolveram duas placas simultâneas, 40 sob reflexo ou iluminação adversa, e 30 com inclinação superior a 15°. Essa distribuição permitiu avaliar o desempenho do sistema em diferentes contextos de operação, simulando situações típicas de ambientes reais.

- Interferência entre placas simultâneas – a taxa de acerto caiu para 62,5 %, devido à sobreposição parcial ou à priorização incorreta da região de interesse pelo algoritmo.
- Ângulo de captura – quando o ângulo ultrapassou 15°, a acurácia caiu para cerca de 70,0 %.
- Iluminação desfavorável – em ambientes com reflexos ou luz intensa, a taxa de acerto reduziu-se para aproximadamente 65,0 %.
- Resolução da webcam – caracteres de menor espessura foram mal interpretados, resultando em falsos negativos.

A Tabela 4 mostra a queda de desempenho em condições críticas e valores alinhados com literatura de Plavac *et al.* (2024).

Tabela 4 – Desempenho do sistema em cenários críticos

Cenário	Total de capturas	Leituras corretas	Leituras incorretas	Taxa de acerto (%)
Duas placas simultâneas	80	50	30	62,5
Iluminação adversa/reflexos	40	26	14	65,0
Ângulo > 15°	30	21	9	70,0

Fonte: Elaborada pelos autores

4.4 Comparação entre Placas Mercosul e Modelo Antigo

A análise comparativa revelou diferenças consistentes entre os dois padrões:

- Placas Mercosul: acurácia média de 91,0 %, tempo médio de processamento de 240 ms.
- Placas modelo antigo: acurácia média de 79,3 %, tempo médio de processamento de 260 ms.

Essa diferença reforça que a regularidade do layout Mercosul não apenas aumenta a precisão, mas também reduz a complexidade computacional no pré-processamento. A Tabela 5 compara os padrões das placas.

Tabela 5 – Comparação entre placas Mercosul e modelo antigo

Tipo de placa	Taxa de acerto (%)	Tempo médio (ms)
Mercosul	91,0	240
Antiga	79,3	260

Fonte: Elaborada pelos autores

4.5 Síntese dos Resultados

Em conjunto, os testes apontam que o sistema apresentou taxa de acerto de 84,0 % e latência média de 248 ms, valores compatíveis com aplicações práticas em ambientes controlados. Contudo, a robustez ainda é limitada em cenários de múltiplas placas, reflexos intensos e ângulos acentuados.

Os erros de reconhecimento concentraram-se em caracteres de alta similaridade visual, como “O–0”, “I–1” e “B–8”, amplamente reportados na literatura de ANPR/OCR em cenários reais (Dalarmelina; Teixeira; Meneguette, 2020; Zhao; Yu; Li, 2018).

Esses achados reforçam que, embora a arquitetura empregada seja promissora para aplicações acadêmicas e prototipagem industrial, a adoção em larga escala exigiria melhorias na qualidade das câmeras, algoritmos de segmentação mais robustos e técnicas de correção de perspectiva.

4.6 Discussão comparativa com a literatura

Os resultados obtidos alinham-se a tendências descritas por Laroca *et al.* (2019) e Huang; Cai; Lan (2021) quanto ao ganho de robustez trazido por detectores baseados em CNNs mesmo quando o OCR de base permanece convencional. A vantagem do padrão Mercosul (91,0 % vs. 79,3 %) é coerente com achados sobre a influência de tipografia e contraste no reconhecimento (Jesus *et al.*, 2022), e reforça que decisões de captura

(posicionamento de câmera, iluminação local) têm efeito tão relevante quanto a escolha de algoritmo.

Em condições adversas, as quedas registradas (62,5–70,0 %) reproduzem o padrão descrito por Plavac *et al.* (2024): quando o ruído ou a geometria fogem do domínio de treino, métodos *end-to-end* mantêm melhor desempenho relativo — ainda que, no cenário deste trabalho, a prioridade fosse simplicidade/custo e latência.

Do ponto de vista de avaliação, a separação entre métricas de detecção/leitura e o reporte de tempo fim-a-fim seguem recomendações de Zhao; Yu; Li (2018), contribuindo para comparabilidade. Finalmente, o uso de voto *multi-frame* e limiar dinâmico oferece um compromisso de engenharia: melhora a confiabilidade sem impor dependência de hardware dedicado.

5 CONCLUSÃO

Este trabalho avaliou a viabilidade de um *pipeline* de visão computacional com OCR, apoiado por bibliotecas de código aberto (OpenCV, EasyOCR) e hardware de baixo custo (câmera integrada + ESP32), para reconhecimento automático de placas em cenários de estacionamento e acionamento de cancela. Os resultados obtidos indicam que a solução atende ao objetivo proposto de operar em quase tempo real e com desempenho satisfatório em condições controladas, comprovando seu potencial de aplicação prática em estacionamentos de pequeno e médio porte.

Em termos de acurácia, o sistema alcançou 84,0% no conjunto global de testes (500 leituras), com desempenho superior para placas do padrão Mercosul (91,0%) em relação ao modelo antigo (79,3%). A latência média de ~248 ms entre a captura e o acionamento do servo demonstra capacidade de resposta compatível com o fluxo operacional de controle de acesso. Esses indicadores atendem à proposta de baixa complexidade e custo, mantendo métricas objetivas adequadas para cenários reais com iluminação e ângulos favoráveis.

Por outro lado, experimentos sob condições críticas, duas placas simultâneas, reflexos/baixa iluminação e ângulo >15°, expuseram quedas de desempenho (acurácia entre 62,5% e 70,0%), evidenciando a sensibilidade do pipeline a iluminação, oclusão e geometria da cena. Esses limites não invalidam a proposta, mas indicam a necessidade de ajustes de engenharia para robustez: controle/normatização de iluminação no ponto de captura, melhor posicionamento de câmera, máscara de ROI mais estável, e heurísticas para desambiguar múltiplas placas no quadro.

Do ponto de vista sistêmico, a integração com Google Sheets para registro e o ESP32 para acionamento mostrou-se estável, simplificando telemetria e automação da cancela. Para consolidar a aplicação em ambientes menos controlados, recomenda-se como trabalhos imediatos: (i) refino do pré-processamento (ex.: *deblurring* não cego leve, supressão de reflexos, CLAHE adaptativo por ROI), (ii) validação *multi-frame* com votação temporal para reduzir falsos positivos, (iii) melhorias de decisão via limiar de confiança dinâmico e regras para “releitura” automática, e (iv) curadoria/expansão do *dataset* incluindo variações de clima, ângulo e distância.

Em síntese, os achados confirmam a viabilidade técnica do pipeline proposto para controle de acesso em estacionamentos com baixa barreira de entrada (custo, *setup* e manutenção), atingindo os objetivos de eficiência e automação definidos. Com os aprimoramentos indicados, espera-se elevar a robustez em cenários adversos e aproximar o

desempenho das soluções comerciais, preservando a filosofia de baixo custo + software livre e mantendo a escalabilidade para integrações futuras (pagamento, ocupação de vagas e *analytics*).

Para aprimorar a robustez e ampliar o alcance do sistema, destacam-se as seguintes direções de pesquisas e desenvolvimento futuros:

- Aprendizado profundo (*deep learning*): substituição ou reforço do OCR atual com modelos treinados especificamente para placas brasileiras, aumentando a acurácia em condições adversas.
- Infraestrutura híbrida local + nuvem: balancear processamento rápido no dispositivo com análises avançadas em servidores remotos, conciliando tempo de resposta e escalabilidade.
- Expansão de cenários de teste: incluir variações de clima, iluminação, ângulo de captura, distância e múltiplos veículos simultâneos, aproximando o desempenho do sistema às demandas reais.
- Validação temporal *multi-frame*: reduzir falsos positivos por meio de votação entre capturas sucessivas, garantindo maior confiabilidade.
- Interfaces e dashboards analíticos: desenvolver painéis de monitoramento em tempo real para operadores, agregando relatórios de fluxo, estatísticas de ocupação e indicadores de desempenho.

REFERÊNCIAS

AL-BATAT, R.; ANGELOPOULOU, A.; PREMKUMAR, S.; HEMANTH, J.; KAPETANIOS, E. An end-to-end automated license plate recognition system using YOLO based vehicle and license plate detection with vehicle classification. **Sensors**, v. 22, n. 23, p. 9477, 2022. DOI: <https://doi.org/10.3390/s22239477>.

BRADSKI, G.; KAEHLER, A. **Learning OpenCV: computer vision with the OpenCV library**. Sebastopol, CA: O'Reilly, 2008.

DALARMELINA, N. do V.; TEIXEIRA, M. A.; MENEGUETTE, R. I. A real-time automatic plate recognition system based on optical character recognition and wireless sensor networks for ITS. **Sensors**, v. 20, n. 1, p. 55, 2020. DOI: 10.3390/s20010055.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge, MA: MIT Press, 2016.

HUANG, Q.; CAI, Z.; LAN, T. A single neural network for mixed style license plate detection and recognition. **IEEE Access**, v. 9, p. 21777–21785, 2021. DOI: <https://doi.org/10.1109/ACCESS.2021.3055243>.

INRIX. **2025 Global traffic scorecard**. INRIX Research. 2025. Disponível em: <https://inrix.com/scorecard/>. Acesso em: 1 out. 2025.

JESUS, A. S.; SANTOS JÚNIOR, W. S.; BITAR, N. P. Reconhecimento de placas veiculares em cenários complexos utilizando CNN. *In*: SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS (SBrT). 40., 2022, Santa Rita do Sapucaí. **Anais [...]**. Santa Rita do Sapucaí, 2022. Disponível em: https://www.researchgate.net/publication/364180292_Reconhecimento_de_Placas_Veiculares_em_Cenarios_Complexos_utilizando_o_Metodo_do_Subespaco_Mutuo_e_Redes_Neurais_Convolucionais. Acesso em: 1 out. 2025.

LAROCA, R.; BARROS, R. C.; MENOTTI, D. A robust real-time automatic license plate recognition based on the YOLO detector. *In*: CONFERENCE ON GRAPHICS, PATTERNS AND IMAGES (SIBGRAPI), 32., 2019, Rio de Janeiro. **Proceedins [...]**. Rio de Janeiro, 2019, pp. 194-201. DOI: <https://doi.org/10.1109/SIBGRAPI.2019.00034>.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2015. DOI: <https://doi.org/10.1038/nature14539>.

LUBNA N.; MUFTI, N.& SHAH, S. A. A. Automatic Number Plate Recognition: A Detailed Survey of Relevant Algorithms. **Sensors**, v. 21, n. 9, 2021, p. 3028. Disponível em: <https://www.mdpi.com/1424-8220/21/9/3028>. Acesso em: 1 out. 2025. DOI: <https://doi.org/10.3390/s21093028>

PLAVAC, N.; AMIRSHAHI, S. A.; PEDERSEN, M.; TRIANTAPHILLIDOU, S. Performance of automatic license plate recognition systems on distorted images. **Journal of Imaging Science and Technology**, v. 68, n. 6, p. 060401, 2024. DOI: <https://doi.org/10.2352/J.ImagingSci.Technol.2024.68.6.060401>.

RUSSELL, S.; NORVIG, P. **Artificial intelligence: a modern approach**. 3. ed. Upper Saddle River, NJ: Prentice Hall, 2016.

SILVA, S. M.; JUNG, C. R. License plate detection and recognition in unconstrained scenarios. *In*: EUROPEAN CONFERENCE ON COMPUTER VISION (ECCV), 15., 2018. **Anais [...]**. Munique: Springer Nature, v. 11216p. pp. 580–596, 2018. DOI: https://doi.org/10.1007/978-3-030-01258-8_36.

SZELISKI, R. **Computer vision: algorithms and applications**. London: Springer, 2010.


UFPR-ALPR. **Banco de dados UFPR-ALPR**. Curitiba: Universidade Federal do Paraná, s.d. Disponível em: <https://web.inf.ufpr.br/vri/databases/ufpr-alpr/>. Acesso em: 1 out. 2025.

VARGAS NETO, A. de S. **Reconhecimento automático de placas veiculares do Mercosul utilizando o Tesseract OCR**. 2023. Trabalho de Conclusão de Curso (Engenharia de Controle e Automação) – Instituto Federal do Espírito Santo - IFES, Vitória, 2023. Disponível em: <https://repositorio.ifes.edu.br/handle/123456789/3671>. Acesso em: 1 out. 2025.

ZHAO, Y.; YU, Z.; LI, X. Evaluation methodology for license plate recognition systems and experimental results. **IET Intelligent Transport Systems**, v. 12, p. 375–385, 2018. DOI: <https://doi.org/10.1049/iet-its.2017.0138>.

Sobre os Autores:

ⁱ **Anderson de Jesus Riva**



Engenheiro Mecânico pela Faculdade São Judas Tadeu (2019), Tecnólogo em Manutenção Industrial, pelo Centro Universitário SENAI-SP (2024). Tem experiência na área de inspeção automotiva, com ênfase em laudos e vistorias e na área pedagógica, com ênfase nas disciplinas de matemática e física. É professor do Estado de São Paulo responsável pelas disciplinas de física e tecnologia. ORCID: <https://orcid.org/0009-0008-2849-4774>

ⁱⁱ **João Victor de Angeli Pudo**




Graduando em Tecnologia em Manutenção Industrial pelo centro universitário SENAI-SP, campus “Roberto Simonsen”; Atualmente é estagiário da Escola SESI Suzano. Tem experiência na área de mecânica e eletroeletrônica, com ênfase em Manutenção Industrial. ORCID: <https://orcid.org/0009-0005-1948-6471>

ⁱⁱⁱ **José Firmino Leite da Silva Junior**



Graduado em Tecnologia de Manutenção Industrial, atuando na área de manutenção hidráulica há 18 anos, com ênfase em manutenção e instalações de tubulações industriais. É técnico em manutenção hidráulica há 10 anos na General Motors do Brasil. ORCID: <https://orcid.org/0009-0005-4361-0276>

^{iv} **Rafael de Souza Araujo**



Graduado em Tecnologia de Manutenção Industrial, tem experiência na área de elétrica predial, com ênfase em manutenção e instalações elétricas. É oficial de manutenção no SENAI-SP responsável pelo setor de manutenção elétrica. ORCID: <https://orcid.org/0009-0006-5666-9565>

^v **Ricardo Hovacker Baldaconi**



Mestre em Tecnologia Nuclear pelo IPEN/USP; Especialista em Automação e Controle pelo SENAI -SP; Licenciado pela FATEC-SP; Tecnólogo em Mecatrônica Industrial pela Uninove. Atua a mais de 15 anos como docente, nas áreas de Programação, Microcontroladores, Eletrônica e Robótica; Atualmente é professor do Centro Universitário SENAI – SP, Campus Roberto Simonsen – Brás. ORCID: <https://orcid.org/0009-0003-4110-2900>