

ESTUDO EXPLORATÓRIO DA APLICAÇÃO DO EASYOCR NO RECONHECIMENTO DE PLACAS VEICULARES NOS PADRÕES NACIONAL E MERCOSUL

Vitor Amadeu Souza^{1,†}

¹UniFOA - Centro Universitário de Volta Redonda, Volta Redonda - RJ – vitor.amadeu@foa.org.br

Resumo

O reconhecimento óptico de caracteres (OCR) aplicado à identificação de placas veiculares representa uma tecnologia relevante para o desenvolvimento de sistemas inteligentes de transporte (ITS) no Brasil. Este trabalho apresenta um estudo exploratório da aplicação da biblioteca EasyOCR, combinada com técnicas de processamento de imagens via OpenCV, no reconhecimento de placas brasileiras nos padrões nacional e MERCOSUL. O experimento foi conduzido com um conjunto inicial de seis placas, obtendo-se taxas de confiança variando entre 0,11 e 0,98 e taxa de acerto geral de 66,67%. Os resultados sugerem, como hipótese a investigar, possível desempenho superior do algoritmo para placas no padrão nacional tradicional em comparação ao padrão MERCOSUL, com dificuldades observadas na distinção entre caracteres visualmente similares, como “O” e “0” e “B” e “8”; contudo, o tamanho reduzido da amostra (três placas por padrão) impede qualquer afirmação comparativa conclusiva. Os resultados fornecem indícios preliminares sobre variáveis que influenciam a precisão do reconhecimento automático de placas e subsidiam investigações futuras com amostras mais amplas e condições controladas.

Palavras-chave: Reconhecimento óptico de caracteres; Placas veiculares; EasyOCR; Sistemas inteligentes de transporte; MERCOSUL.

Abstract

Optical Character Recognition (OCR) applied to vehicle license plate identification is a relevant technology for the development of Intelligent Transportation Systems (ITS) in Brazil. This paper presents an exploratory

study on the application of the EasyOCR library, combined with image processing techniques using OpenCV, for the recognition of Brazilian license plates in both the national and MERCOSUR standards. The experiment was conducted on an initial set of six license plates, yielding confidence scores ranging from 0.11 to 0.98 and an overall accuracy rate of 66.67%. The results suggest, as a hypothesis to be investigated, a possible performance advantage of the algorithm for plates following the traditional national standard compared to the MERCOSUR format, with observed difficulties in distinguishing visually similar characters such as “O” and “0” and “B” and “8”; however, the small sample size (three plates per standard) precludes any conclusive comparative claim. The results provide preliminary evidence regarding variables that influence automatic license plate recognition accuracy and support future investigations with larger samples and controlled conditions.

Keywords: Optical Character Recognition; License plates; EasyOCR; Intelligent Transportation Systems; MERCOSUR.

1. INTRODUÇÃO

O reconhecimento automático de placas veiculares (ANPR - Automatic Number Plate Recognition) constitui uma das aplicações mais relevantes da tecnologia de reconhecimento óptico de caracteres (OCR) na atualidade, apresentando impactos relevantes em diversas áreas como segurança pública, controle de tráfego e gestão urbana (Duenas Salazar, 2017; Montazzolli & Jung, 2017; Soares et al., 2020). No contexto brasileiro, essa tecnologia assume especial importância devido à extensão territorial do país e à complexidade do sistema rodoviário nacional, que demanda soluções automatizadas para

monitoramento e fiscalização eficientes (Bernardi, 2015).

A evolução dos algoritmos de processamento de imagens e aprendizado de máquina tem proporcionado avanços consideráveis na precisão e confiabilidade dos sistemas OCR aplicados ao reconhecimento de placas veiculares (El Harraj & Raisouni, 2015; Singh et al., 2024). Segundo Santos (2024), o processo envolve várias etapas, começando pela captura da imagem da placa, seguida pelo pré-processamento, segmentação de caracteres, extração de características e classificação final. Cada etapa apresenta desafios específicos relacionados às condições ambientais, qualidade das imagens e variações nos padrões de placas utilizados no território nacional.

O sistema rodoviário brasileiro, particularmente em rodovias como a BR-101 (Rio-Santos), tem implementado tecnologias OCR para fins de fiscalização e monitoramento de tráfego (Brasil. Departamento Nacional de Infraestrutura de Transportes, 2025; Instituto Nacional de Metrologia, Qualidade e Tecnologia, 2025). Outros serão implantados na mesma rodovia no trecho paulista, demonstrando a crescente adoção dessas tecnologias em âmbito federal (G1, 2024). Esses sistemas operam integrados a equipamentos de fiscalização eletrônica, proporcionando capacidade de processamento em tempo real e alta precisão na identificação veicular (Bernardi, 2015; Soares et al., 2020).

As aplicações comerciais de reconhecimento de placas no Brasil têm se expandido crescentemente, abrangendo desde sistemas completos e inovadores de monitoramento de trânsito, capazes de identificar e rastrear placas automotivas, até soluções específicas para controle de acesso e segurança patrimonial. A diversidade de cenários de aplicação exige que os algoritmos OCR sejam capazes de lidar com diferentes condições de iluminação, ângulos de captura e padrões de placas (Singh et al., 2024).

A literatura científica nacional tem demonstrado crescente interesse no desenvolvimento de soluções OCR adaptadas às características específicas das placas brasileiras (Montazzolli & Jung, 2017). Pesquisas como a conduzida por Duenas Salazar (2017) evidenciam o potencial de desenvolvimento tecnológico nacional nessa área, contribuindo para a redução da dependência de soluções importadas e o aprimoramento de sistemas adequados às particularidades brasileiras.

2. FUNDAMENTAÇÃO TEÓRICA

Esta seção apresenta os fundamentos teóricos e tecnológicos que embasam o desenvolvimento de sistemas de reconhecimento automático de placas veiculares. Inicialmente, são discutidos os princípios do reconhecimento óptico de caracteres (Seção 2.1) e o papel das redes neurais convolucionais em aplicações de OCR (Seção 2.2). Em seguida, são apresentadas as características da biblioteca EasyOCR e sua comparação com o Tesseract OCR (Seção 2.3). Posteriormente, são abordados os padrões de placas veiculares adotados no Brasil (Seção 2.4) e, por fim, os sistemas inteligentes de transporte e a fiscalização eletrônica no contexto nacional (Seção 2.5).

2.1. Reconhecimento Óptico de Caracteres

O reconhecimento óptico de caracteres (OCR) consiste em um conjunto de técnicas computacionais que permitem a conversão de imagens contendo texto em dados alfanuméricos estruturados e processáveis por máquina (Mori et al., 1999). A evolução dessa tecnologia acompanhou o desenvolvimento do processamento digital de imagens e, mais recentemente, das redes neurais profundas, que substituíram progressivamente as abordagens baseadas em regras heurísticas e extração manual de características (LeCun et al., 1998).

Os sistemas OCR modernos operam em um pipeline estruturado que compreende, de forma geral, quatro etapas principais: pré-processamento da imagem, detecção e segmentação das regiões de interesse, extração de características e classificação dos caracteres (Impedovo et al., 1991). Cada uma dessas etapas contribui de maneira distinta para a precisão final do sistema, sendo o pré-processamento particularmente crítico em cenários com variações de iluminação, ruído e distorção geométrica (El Harraj & Raisouni, 2015).

2.2. Redes Neurais Convolucionais Aplicadas ao OCR

As redes neurais convolucionais (CNNs) representam o estado da arte em tarefas de reconhecimento de padrões visuais, incluindo a identificação de caracteres em imagens (LeCun et al., 1998). Sua capacidade de aprender representações hierárquicas de características diretamente dos dados brutos elimina a necessidade de engenharia manual de atri-

butos, tornando-as especialmente adequadas para ambientes não controlados, como os encontrados em sistemas de monitoramento veicular (Goodfellow et al., 2016).

No contexto do reconhecimento de placas veiculares, arquiteturas como YOLO (*You Only Look Once*) e suas variantes têm sido amplamente empregadas para a detecção e localização das regiões de placa nas imagens capturadas (Redmon et al., 2016). Essas arquiteturas permitem o processamento em tempo real, requisito fundamental para aplicações embarcadas em sistemas de fiscalização eletrônica (Santos, 2024; Soares et al., 2020). A combinação de detectores baseados em CNNs com módulos OCR especializados constitui a abordagem predominante na literatura recente para sistemas ANPR de alto desempenho (Montazzolli & Jung, 2017).

2.3. A Biblioteca EasyOCR e sua Comparação com o Tesseract OCR

O EasyOCR é uma biblioteca de código aberto desenvolvida em Python, baseada em arquiteturas de redes neurais profundas, que oferece suporte a mais de oitenta idiomas e é amplamente utilizada em aplicações de reconhecimento de texto em imagens naturais (JaidedAI, 2020). Sua arquitetura combina um detector de texto baseado em CRAFT (*Character Region Awareness for Text Detection*) com um módulo de reconhecimento fundamentado em redes recorrentes do tipo LSTM (*Long Short-Term Memory*), permitindo a identificação de texto em condições variadas de qualidade e orientação (Baek et al., 2019).

O Tesseract OCR, desenvolvido originalmente pela HP e mantido pelo Google, baseia-se em uma arquitetura LSTM treinada predominantemente para documentos textuais formais, o que tende a limitar seu desempenho em imagens capturadas em ambientes externos, como placas veiculares (Vargas Neto, 2023). Avaliações sistemáticas disponíveis na literatura indicam que o EasyOCR apresenta maior acurácia geral em cenários com variação de iluminação e ângulo de captura, ao passo que o Tesseract demonstra menor tempo de processamento, sendo mais adequado para aplicações com restrições computacionais severas (Vedhaviyassh et al., 2022). No contexto brasileiro, Vargas Neto (2023) identificou dificuldades do Tesseract na distinção entre caracteres alfanuméricos similares em placas no padrão MERCOSUL, o que motivou a escolha do EasyOCR como ferramenta principal no presente estudo. A

escolha entre as ferramentas deve considerar o ambiente de implantação, os recursos disponíveis e as características específicas das imagens a serem processadas (Vargas Neto, 2023; Vedhaviyassh et al., 2022).

2.4. Padrões de Placas Veiculares Brasileiras

O Brasil adota dois padrões principais de placas veiculares. O padrão nacional tradicional, vigente desde 1990, é composto por três letras seguidas de quatro dígitos numéricos no formato ABC-1234 (Bernardi, 2015). A partir de 2018, o Brasil passou a adotar progressivamente o padrão MERCOSUL, alinhado aos demais países membros do bloco, que introduz um caractere alfanumérico na quarta posição, resultando no formato ABC1D23 (Duenas Salazar, 2017). Essa transição impõe desafios adicionais aos sistemas OCR, que precisam ser capazes de reconhecer e distinguir corretamente os dois padrões simultaneamente.

A coexistência dos dois formatos no sistema viário nacional exige que os algoritmos de reconhecimento sejam treinados com conjuntos de dados representativos de ambos os padrões, além de incorporarem lógica de validação pós-reconhecimento capaz de identificar e corrigir confusões entre caracteres visualmente similares, como “O” e “0”, “I” e “1”, e “B” e “8” (Bruning, 2024; Vargas Neto, 2023). Essa problemática é amplamente documentada na literatura especializada e constitui um dos principais desafios para a obtenção de altas taxas de acerto em sistemas ANPR aplicados ao contexto brasileiro (Glasenapp et al., 2023; Montazzolli & Jung, 2017).

2.5. Sistemas Inteligentes de Transporte e Fiscalização Eletrônica

Os sistemas inteligentes de transporte (ITS – *Intelligent Transportation Systems*) integram tecnologias de comunicação, sensoriamento e processamento de dados para aprimorar a eficiência, segurança e sustentabilidade do sistema de mobilidade (Sussman, 2005). O reconhecimento automático de placas constitui um dos subsistemas centrais dos ITS modernos, sendo aplicado em funções como controle de acesso, cobrança eletrônica de pedágios, rastreamento de veículos e fiscalização de infrações (Brasil. Departamento Nacional de Infraestrutura de Transportes, 2025; Instituto Nacional de Metrologia, Qualidade e Tecnologia, 2025).

Figura 1. Imagens de placas modelo MERCOSUL e nacional. Fonte: (Embarcados, 2024)

No Brasil, a regulamentação dos equipamentos de fiscalização eletrônica é de competência do Instituto Nacional de Metrologia, Qualidade e Tecnologia (Inmetro), que estabelece requisitos técnicos mínimos para a homologação desses sistemas, incluindo exigências de precisão, confiabilidade e rastreabilidade metrológica (Instituto Nacional de Metrologia, Qualidade e Tecnologia, 2025). A conformidade com esses requisitos é condição necessária para que os dados gerados pelos sistemas OCR possuam validade jurídica no âmbito dos processos de autuação de infratores.

3. METODOLOGIA

A metodologia empregada neste estudo baseia-se na implementação de um sistema de reconhecimento óptico de caracteres utilizando a biblioteca EasyOCR, integrada com OpenCV para processamento de imagens e PyTorch para operações de aprendizado de máquina. O ambiente de desenvolvimento foi configurado no Google Colab, proporcionando acesso a recursos computacionais otimizados para processamento de imagens e algoritmos de inteligência artificial. O processo experimental iniciou-se com a instalação das dependências necessárias, incluindo as bibliotecas EasyOCR, OpenCV e PyTorch com suporte a CUDA quando disponível. A inicialização do leitor EasyOCR foi configurada para reconhecimento em idiomas português e inglês, considerando que as placas brasileiras contêm caracteres alfanuméricos que podem incluir elementos comuns a ambos os idiomas (Soares et al., 2020).

A imagem utilizada nos experimentos foi extraída do artigo “Modelo para identificação dos caracteres da placa”, disponível no portal Embarcados (2024). A figura foi utilizada exclusivamente para fins de

pesquisa e validação do método proposto de Reconhecimento Óptico de Caracteres (OCR), servindo como amostra ilustrativa para o processo de detecção e reconhecimento dos caracteres presentes em placas veiculares. Em conformidade com a Lei Geral de Proteção de Dados (LGPD – Lei n.º 13.709/2018), não foram utilizadas imagens contendo placas associadas a dados pessoais de proprietários ou condutores, não havendo, portanto, tratamento de dados pessoais no âmbito deste estudo.

Para a obtenção das imagens de teste, foi utilizada uma abordagem de coleta via URL, permitindo o acesso a imagens representativas de placas veiculares brasileiras disponíveis em repositórios online. O experimento foi conduzido sobre uma única imagem-fonte contendo seis placas simultaneamente, nos padrões nacional e MERCOSUL, conforme demonstrado na Figura 1. O algoritmo EasyOCR processou a imagem integral e retornou automaticamente as detecções individuais de cada placa, ordenadas sequencialmente. A associação entre cada detecção e a placa original listada na Tabela 1 foi realizada por inspeção manual da saída do algoritmo, confrontando o texto reconhecido e as coordenadas do retângulo delimitador com as placas visíveis na imagem.

O processamento das imagens seguiu uma sequência estruturada de operações: carregamento da imagem através de requisições HTTP, conversão para array NumPy, decodificação utilizando OpenCV e validação da integridade dos dados carregados. Esse procedimento garante a consistência dos dados de entrada e permite o processamento adequado pelas funções subsequentes de reconhecimento óptico (Bruning, 2024; El Harraj & Raisouni, 2015).

A aplicação do algoritmo EasyOCR foi configu-

rada com parâmetros otimizados para detecção de texto em placas veiculares, conforme recomendações de Singh et al. (2024), considerando as características específicas desse tipo de aplicação, como contraste, dimensões típicas dos caracteres e padrões de formatação. O sistema foi programado para retornar não apenas o texto reconhecido, mas também as coordenadas dos retângulos delimitadores e os valores de confiança associados a cada detecção.

A análise dos resultados incluiu a avaliação quantitativa das taxas de confiança obtidas para cada caractere ou grupo de caracteres reconhecidos, bem como a análise qualitativa da precisão das detecções em relação aos padrões esperados para placas brasileiras (Montazzolli & Jung, 2017). A visualização dos resultados foi implementada através da sobreposição de retângulos delimitadores e textos identificados sobre a imagem original, permitindo uma avaliação visual da eficácia do algoritmo.

4. DESCRIÇÃO DO ALGORITMO

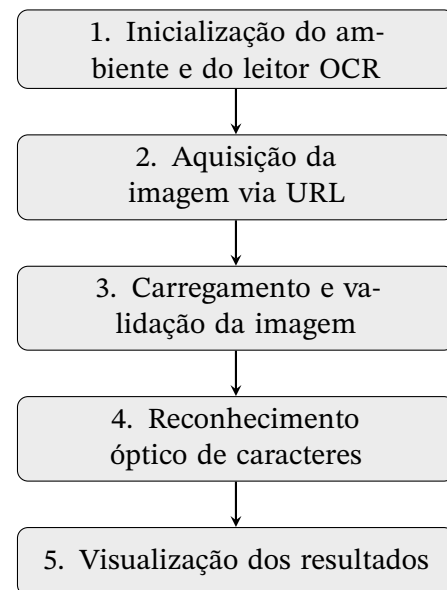
O sistema de reconhecimento automático de placas veiculares desenvolvido neste trabalho é composto por cinco etapas principais: inicialização do ambiente e das dependências, aquisição das imagens, pré-processamento, execução do reconhecimento óptico e visualização dos resultados. As subseções a seguir detalham cada uma dessas etapas, acompanhadas do pseudocódigo correspondente.

A Figura 2 apresenta uma visão geral do pipeline implementado, composto pelas cinco etapas descritas nas subseções a seguir.

4.1. Inicialização do Ambiente

A primeira etapa consiste na configuração do ambiente de execução e na inicialização do leitor OCR. Durante essa etapa, o sistema também verifica a disponibilidade de unidade de processamento gráfico (GPU) com suporte a CUDA, utilizando-a quando disponível para acelerar as operações de inferência das redes neurais (Goodfellow et al., 2016). A estrutura de diretórios necessária para armazenamento local das imagens também é criada nessa fase, garantindo que as etapas subsequentes disponham de um sistema de arquivos adequado.

Figura 2. Fluxograma do pipeline de reconhecimento de placas.



Código 1. Pseudocódigo – Inicialização do ambiente.

```

1 INICIO
2   INSTALAR dependencias:
3     easyocr, opencv, matplotlib
4     , requests
5
6   INICIALIZAR leitor_ocr
7     COM idiomas = ['portugues',
8                   'ingles']
9     COM gpu = VERDADEIRO se
10    disponivel
11
12   CRIAR diretorio local "plates/"
13   SE nao existir
14
15   DEFINIR dicionario image_urls
16     chave: nome_identificador
17     valor: URL_da_imagem
18 FIM
  
```

4.2. Aquisição de Imagens

A segunda etapa compreende a coleta das imagens a serem processadas. A abordagem adotada utiliza requisições HTTP para recuperar imagens diretamente de repositórios online, permitindo a atualização dinâmica do conjunto de dados sem necessidade de intervenção manual (Bruning, 2024). Para cada entrada no dicionário de imagens, o sistema realiza o download do arquivo e o armazena localmente, sobrescrevendo versões anteriores a fim

de garantir que o conteúdo processado reflita sempre a versão mais recente disponível na fonte.

Essa estratégia de aquisição via URL é especialmente adequada para ambientes de desenvolvimento em nuvem, como o Google Colab, onde o armazenamento local é temporário e os dados precisam ser recuperados a cada sessão de execução. A validação da integridade do arquivo baixado é realizada na etapa subsequente, durante o carregamento da imagem pelo OpenCV (El Harraj & Raisouni, 2015).

Código 2. Pseudocódigo – Aquisição de imagem via URL.

```

1 FUNCAO download_imagem(url,
  caminho_local)
2   INICIO
3     resposta <-
4     REQUISICAO_HTTP_GET(url)
5     SE resposta.status == 200
6     ENTAO
7       SALVAR resposta.
8       conteudo EM caminho_local
9       SENA0
10      EXIBIR "Erro ao baixar
11      imagem"
12      FIM
13
14 # Imagem unica contendo multiplas
15 # placas
16 url <- "https://[repositorio]/
17 Placas_Mercosul_2020.jpg"
18 caminho <- "plates/multiple_plates.
19 jpg"
20 CHAMAR download_imagem(url, caminho
21 )

```

4.3. Carregamento e Validação da Imagem

Esta etapa compreende o carregamento da imagem e a validação de sua integridade antes do reconhecimento óptico. A imagem é carregada no formato BGR pelo OpenCV e convertida para o espaço de cores RGB, exigido pelo EasyOCR para o correto funcionamento de seus módulos internos (Baek et al., 2019). Caso o OpenCV não consiga decodificar o arquivo, a execução é interrompida e uma mensagem de erro é exibida, evitando a propagação de falhas para as etapas seguintes.

Ressalta-se que técnicas de pré-processamento mais elaboradas, como binarização, equalização de

histograma, redução de ruído e correção de perspectiva, não foram implementadas neste estudo exploratório. Embora a literatura aponte essas técnicas como relevantes para a qualidade do reconhecimento em condições adversas (El Harraj & Raisouni, 2015), sua incorporação e a medição de seu impacto sobre a taxa de acerto constituem uma das direções recomendadas para investigações futuras.

Código 3. Pseudocódigo – Pré-processamento da imagem.

```

1 FUNCAO carregar_validar_imagem(
2   caminho_arquivo)
3   INICIO
4     imagem_bgr <-
5     CARREGAR_IMAGEM(caminho_arquivo)
6
7     SE imagem_bgr == NULO ENTAO
8     EXIBIR "Falha ao
9     carregar: " + caminho_arquivo
10    RETORNAR NULO
11
12    imagem_rgb <- CONVERTER(
13    imagem_bgr, BGR -> RGB)
14
15    RETORNAR imagem_bgr,
16    imagem_rgb
17    FIM

```

4.4. Reconhecimento Óptico de Caracteres

A etapa central do sistema corresponde à execução do algoritmo de reconhecimento óptico sobre a imagem a ser analisada. O módulo EasyOCR aplica internamente uma arquitetura em dois estágios: o primeiro utiliza o detector CRAFT (*Character Region Awareness for Text Detection*) para identificar as regiões da imagem que contêm texto; o segundo aplica uma rede recorrente LSTM para decodificar os caracteres presentes em cada região detectada (Baek et al., 2019).

Para cada região detectada, o sistema retorna uma tupla contendo as coordenadas do retângulo delimitador (*bounding box*), o texto reconhecido e o valor de confiança associado à predição, expresso em uma escala de 0 a 1 (Vedhaviyassh et al., 2022). Esses valores de confiança são fundamentais para a implementação de limiares de aceitação em sistemas comerciais, nos quais detecções abaixo de um valor mínimo podem ser encaminhadas para validação manual (Vargas Neto, 2023). As coordenadas

do retângulo delimitador são então utilizadas para anotar a imagem original, permitindo a verificação visual das detecções realizadas.

Código 4. Pseudocódigo – Reconhecimento óptico de caracteres.

```

1 FUNCAO executar_ocr(imagem_rgb,
  imagem_bgr)
2   INICIO
3     resultados <- leitor_ocr.
  LER(imagem_rgb)
4
5     SE resultados == VAZIO
  ENTAO
6       EXIBIR "Nenhum texto
  detectado"
7       RETORNAR
8
9     PARA CADA (bbox, texto,
  confianca) EM resultados FAÇA
10      INICIO
11        EXIBIR texto,
  confianca
12
13        pontos <- CONVERTER
  coordenadas de bbox
14
15        DESENHAR_RETANGULO(
  imagem_bgr,
16
17        ponto_superior_esquerdo = pontos
  [0],
18
19        ponto_inferior_direito = pontos
  [2],
20
21        cor = VERDE,
  espessura = 2
22      )
23    FIM
24  RETORNAR imagem_bgr,
  resultados
25  FIM

```

4.5. Visualização dos Resultados

A etapa final do pipeline corresponde à visualização dos resultados obtidos. A imagem anotada, contendo os retângulos delimitadores sobrepostos às regiões de texto detectadas, é exibida por meio da biblioteca Matplotlib (Santos, 2024). A exibição inclui o nome do arquivo processado como título do gráfico e a URL de origem da imagem como legenda

do eixo horizontal, garantindo a rastreabilidade da fonte dos dados analisados.

Essa etapa, embora de caráter predominantemente qualitativo, desempenha papel relevante na avaliação do desempenho do sistema, pois permite identificar visualmente padrões de erro, como detecções em regiões incorretas ou sobreposição de retângulos delimitadores, que podem não ser capturados pelas métricas quantitativas de confiança (Montazzolli & Jung, 2017).

Código 5. Pseudocódigo – Visualização dos resultados.

```

1 FUNCAO visualizar(imagem_bgr,
  nome_arquivo, url_fonte)
2   INICIO
3     imagem_rgb <- CONVERTER(
  imagem_bgr, BGR -> RGB)
4
5     CRIAR figura(largura=12,
  altura=6)
6     EXIBIR imagem_rgb
7     DEFINIR titulo <- "OCR: "
  + nome_arquivo
8     DEFINIR legenda <- "Fonte:
  " + url_fonte
9     OCULTAR eixos
10    RENDERIZAR figura
11  FIM
12
13  # Fluxo principal
14  caminho <- "plates/multiple_plates.
  jpg"
15  imagem_bgr, imagem_rgb <-
  carregar_validar_imagem(caminho)
16  imagem_anotada, resultados <-
  executar_ocr(imagem_rgb,
  imagem_bgr)
17  visualizar(imagem_anotada, "
  multiple_plates", url)

```

4.6. Código-fonte

O código-fonte desenvolvido nesta pesquisa encontra-se disponível publicamente em: <https://github.com/vitor-souza-ime/ocr>.

5. RESULTADOS E DISCUSSÃO

Os resultados obtidos através da aplicação do algoritmo EasyOCR revelam aspectos importantes sobre o desempenho de sistemas de reconhecimento

Tabela 1. Resultado da identificação OCR

| Placa original | Placa identificada | Confiança | Correto? |
|----------------------------|--------------------|-----------|---------------|
| BBM8E78 | BBMBE78 | 0,62 | Não |
| KRS5V89 | KRS5V89 | 0,57 | Sim |
| GJO0V26 | GJ0GV26 | 0,11 | Não |
| CEV-3743 | CEV-3743 | 0,95 | Sim |
| GNZ-0788 | GNZ-0788 | 0,98 | Sim |
| BFC-5955 | BFC-5955 | 0,51 | Sim |
| Predições corretas: | | | 66,67% |

óptico aplicados a placas veiculares brasileiras. A análise dos dados demonstra uma variabilidade relevante nas taxas de confiança, que oscilaram entre 0,11 e 0,98, indicando diferentes níveis de precisão na identificação dos caracteres presentes nas placas analisadas (Soares et al., 2020).

Para os elementos textuais “BRASIL” presentes nas placas nacionais, observaram-se taxas de confiança de 0,43, 0,89 e 0,12 respectivamente, demonstrando inconsistência na identificação de um mesmo elemento textual sob diferentes condições de captura ou processamento. Esta variação pode ser atribuída a fatores como qualidade da imagem, contraste, ângulo de captura e condições de iluminação, aspectos fundamentais que influenciam diretamente a performance de algoritmos OCR conforme destacado por Glasenapp et al. (2023). Os resultados alcançados, assim como a indicação se a predição foi correta ou errada, estão indicados na Tabela 1.

A análise dos resultados obtidos através do sistema OCR para identificação de placas veiculares revela um desempenho heterogêneo, com taxa de acerto geral de 66,67%, evidenciando os desafios inerentes ao reconhecimento automático de caracteres em aplicações práticas (Bernardi, 2015; Montazzoli & Jung, 2017).

O sistema apresentou comportamentos distintos conforme o padrão e características específicas de cada placa analisada. Para as placas no formato Mercosul, observaram-se resultados contrastantes que ilustram as limitações do algoritmo EasyOCR. A placa “BBM8E78” foi incorretamente identificada como “BBMBE78” com confiança de 0,62, demonstrando confusão entre o dígito “8” e a letra “B” na quarta posição. Este tipo de erro é particularmente preocupante em sistemas de monitoramento veicular, pois pode resultar em identificações equivocadas de veículos. Similarmente, a placa “GJO0V26” apresentou o pior desempenho do ex-

perimento, sendo identificada erroneamente como “GJ0GV26” com confiança extremamente baixa de apenas 0,11. Como o número de caracteres permanece igual a sete, trata-se de substituições incorretas: “O” foi trocado por “0” na terceira posição e “0” foi trocado por “G” na quarta posição, evidenciando múltiplas confusões entre caracteres de morfologia próxima (Soares et al., 2020).

A taxa de acerto de 66,67% observada neste estudo exploratório situa-se abaixo dos valores reportados em estudos com amostras maiores utilizando o mesmo algoritmo (Vedhaviyassh et al., 2022), o que pode ser atribuído tanto ao tamanho reduzido da amostra quanto às particularidades visuais das placas brasileiras. Cabe destacar que a comparação entre os padrões nacional e MERCOSUL apoia-se em três placas de cada lado, volume insuficiente para sustentar qualquer afirmação comparativa: o intervalo de confiança binomial para proporções estimadas com $n=3$ é amplamente documentado como excessivamente largo para inferências dessa natureza (Agresti & Coull, 1998). A diferença observada (3/3 de acertos no padrão nacional contra 1/3 no MERCOSUL) deve ser tratada, portanto, como hipótese a investigar em estudos com amostras representativas, e não como achado consolidado. Estudos independentes utilizando o Tesseract OCR em placas brasileiras (Vargas Neto, 2023) reportaram dificuldades semelhantes na distinção entre caracteres alfanuméricos similares, embora conduzidos sobre conjuntos de dados distintos do utilizado neste trabalho. A comparação direta entre as duas ferramentas sobre a mesma amostra não foi realizada neste estudo exploratório, constituindo uma das direções recomendadas para investigações futuras.

Em contrapartida, a placa “KRS5V89” foi corretamente identificada, embora com confiança relativamente baixa de 0,57, sugerindo que mesmo quando o algoritmo produz resultados corretos, pode apresentar incerteza. Esta observação ressalta a impor-

tância de estabelecer limites mínimos de confiança para validação automática dos resultados em sistemas comerciais.

As placas do padrão nacional tradicional (formato ABC-1234) demonstraram desempenho superior e mais consistente. A placa “GNZ-0788” alcançou o melhor resultado do experimento com confiança de 0,98. Este resultado sugere que o modelo possui maior familiaridade com caracteres e padrões presentes neste formato específico, possivelmente devido à prevalência deste tipo de placa nos *datasets* de treinamento utilizados pelo EasyOCR (Vedhavyassh et al., 2022).

A placa “CEV-3743” também apresentou bom desempenho com confiança de 0,95, confirmando a eficácia do sistema para placas do padrão nacional. Contudo, a placa “BFC-5955” obteve confiança de apenas 0,51, embora tenha sido corretamente identificada, indicando que mesmo dentro do mesmo padrão de placa, fatores como qualidade da imagem, condições de iluminação ou características específicas dos caracteres podem influenciar a confiança do algoritmo (El Harraj & Raisouni, 2015).

A variabilidade observada nos níveis de confiança, mesmo para identificações corretas, corrobora com a literatura existente sobre os desafios enfrentados por sistemas OCR em aplicações reais (Duenas Salazar, 2017; Montazzolli & Jung, 2017). Estes resultados sugerem que a implementação de sistemas comerciais de reconhecimento de placas deve incorporar mecanismos robustos de validação e verificação cruzada para maximizar a confiabilidade operacional.

Os resultados obtidos evidenciam a necessidade de abordagens híbridas que combinem múltiplas técnicas de processamento de imagem e validação de resultados, onde sistemas comerciais frequentemente implementam algoritmos de pós-processamento que aplicam regras de validação baseadas nos padrões conhecidos de placas brasileiras, aumentando a precisão final das detecções (Vargas Neto, 2023).

No contexto da aplicação prática em sistemas de monitoramento veicular, como aqueles implementados em rodovias brasileiras, os resultados sugerem que embora a tecnologia OCR seja viável para uso comercial, é fundamental considerar a implementação de mecanismos de correção automática e validação manual para casos de baixa confiança. Segundo dados do DNIT (Brasil. Departamento Nacional de

Infraestrutura de Transportes, 2025), sistemas de Blitz Eletrônica realizam o monitoramento automatizado de veículos através do reconhecimento de placas, demonstrando a viabilidade prática desta tecnologia quando adequadamente implementada.

Com vistas a contextualizar os resultados segundo métricas padronizadas na área, calculou-se a Taxa de Erro de Caractere (*Character Error Rate* – CER) para cada placa analisada. O CER é definido como a distância de edição normalizada entre o texto reconhecido e o texto de referência, expressa pela equação $CER = (S+D+I)/N$, onde *S*, *D* e *I* representam, respectivamente, o número de substituições, deleções e inserções de caracteres, e *N* o total de caracteres na referência (Morris et al., 2004). A Tabela 2 apresenta os valores obtidos para as seis placas do experimento.

Tabela 2. Character Error Rate (CER) por placa

| Placa | S | D | I | CER |
|------------------|---|---|---|-------------|
| BBM8E78 | 1 | 0 | 0 | 0,14 |
| KRS5V89 | 0 | 0 | 0 | 0,00 |
| GJO0V26 | 2 | 0 | 0 | 0,29 |
| CEV-3743 | 0 | 0 | 0 | 0,00 |
| GNZ-0788 | 0 | 0 | 0 | 0,00 |
| BFC-5955 | 0 | 0 | 0 | 0,00 |
| CER médio | | | | 0,07 |

Os resultados indicam que os erros se concentram nas placas do padrão MERCOSUL, com CER de 0,14 e 0,29, enquanto as placas do padrão nacional apresentam CER nulo. O CER médio de 0,07 reflete o impacto limitado dos erros sobre o conjunto total, mas não deve obscurecer o fato de que, em sistemas de monitoramento veicular, qualquer erro de caractere pode comprometer a identificação do veículo (Montazzolli & Jung, 2017).

A análise também revela a importância da qualidade e diversidade dos *datasets* utilizados no treinamento de modelos OCR. A diferença de desempenho entre os formatos de placa sugere que a adaptação de modelos de *deep learning* para características específicas das placas nacionais pode resultar em melhorias na precisão e robustez dos sistemas de reconhecimento, conforme evidenciado por Montazzolli e Jung (2017) em estudos sobre redes neurais convolucionais aplicadas ao reconhecimento de placas veiculares brasileiras.

6. CONCLUSÕES

Este estudo exploratório investigou a aplicação da biblioteca EasyOCR no reconhecimento de placas veiculares brasileiras nos padrões nacional e MERCOSUL, utilizando um conjunto inicial de seis placas como prova de conceito. Os resultados obtidos fornecem indícios preliminares sobre o comportamento do algoritmo frente às particularidades visuais das placas brasileiras, apontando para diferenças de desempenho entre os dois padrões analisados.

A variabilidade observada nas taxas de confiança, que oscilaram entre 0,11 e 0,98, sugere que o desempenho do EasyOCR é sensível a fatores como qualidade da imagem, contraste e características específicas dos caracteres. Embora os resultados indiquem 3/3 de acertos no padrão nacional tradicional (ABC-1234) contra 1/3 no padrão MERCOSUL, o tamanho de subgrupo (três placas por padrão, todas extraídas de uma mesma imagem-fonte) impede qualquer conclusão comparativa entre os dois formatos. Essa diferença deve ser interpretada estritamente como hipótese a investigar: é plausível, e coerente com a literatura (Montazzolli & Jung, 2017; Vargas Neto, 2023), que o padrão MERCOSUL imponha maior dificuldade ao algoritmo em razão da maior frequência de confusões entre caracteres de morfologia próxima, como “8”/“B” e “0”/“O”; contudo, apenas estudos com amostras representativas poderão confirmar ou refutar essa hipótese.

A taxa de acerto geral de 66,67%, embora obtida em uma amostra pequena, situa-se abaixo dos patamares reportados por estudos com *datasets* maiores (Vedhaviyash et al., 2022), reforçando a necessidade de investigações com maior volume amostral para caracterizar com precisão o desempenho do EasyOCR no contexto brasileiro. A comparação com estudos que utilizaram o Tesseract OCR em placas MERCOSUL (Vargas Neto, 2023) indica que a escolha da ferramenta OCR influencia os resultados de forma relevante, e que o EasyOCR apresenta vantagens em cenários com imagens de qualidade variável.

Do ponto de vista prático, os achados sugerem que a adoção do EasyOCR em sistemas de monitoramento veicular é tecnicamente promissora, mas requer a incorporação de mecanismos complementares de validação, como limiares mínimos de confiança, regras de pós-processamento baseadas nos padrões conhecidos de placas brasileiras e rotinas de verificação manual para detecções inconclusivas

(Glaserapp et al., 2023; Vargas Neto, 2023).

Para pesquisas futuras, recomenda-se: (i) ampliar o conjunto de teste para amostras estatisticamente representativas de ambos os padrões; (ii) avaliar o impacto de técnicas de pré-processamento, como normalização de iluminação, correção de perspectiva e aumento de contraste, na taxa de acerto; (iii) conduzir uma comparação experimental direta entre EasyOCR e Tesseract OCR sobre o mesmo conjunto de placas brasileiras; e (iv) investigar abordagens híbridas que combinem detecção por redes convolucionais com módulos OCR especializados para o contexto nacional (Bruning, 2024; Montazzolli & Jung, 2017).

A contribuição deste trabalho reside na documentação sistemática de um pipeline de reconhecimento de placas baseado em EasyOCR e OpenCV, na identificação de padrões de erro específicos ao contexto brasileiro e no estabelecimento de uma base metodológica para estudos futuros com maior escala experimental.

■ Referências

- Agresti, A., & Coull, B. A. (1998). Approximate Is Better than “Exact” for Interval Estimation of Binomial Proportions. *The American Statistician*, 52(2), 119–126. <https://doi.org/10.1080/00031305.1998.10480550>
- Baek, Y., Lee, B., Han, D., Yun, S., & Lee, H. (2019). Character Region Awareness for Text Detection. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 9365–9374. <https://doi.org/10.1109/CVPR.2019.00959>
- Bernardi, E. (2015). *Os sistemas de identificação veicular, em especial o reconhecimento automático de placas* [tese de mestrado, Universidade de São Paulo]. <http://www.teses.usp.br/teses/disponiveis/3/3138/tde-11052016-162646/>
- Brasil. Departamento Nacional de Infraestrutura de Transportes. (2025). Portal de Multas de Trânsito. <https://servicos.dnit.gov.br/multas/informacoes/equipamentos-fiscalizacao>
- Bruning, D. (2024). *Aprendizado por transferência aplicado na detecção de placas de licenciamento de veículos*. <https://repositorio.uces.br/11338/13641>
- Duenas Salazar, J. A. (2017). *Reconhecimento automático de placas veiculares brasileiras em ambientes não controlados* [Dissertação (Mestrado em Engenharia de Automação e Sistemas)]. Uni-

- versidade Federal de Santa Catarina. <https://repositorio.ufsc.br/handle/123456789/186149>
- El Harraj, A., & Raisouni, N. (2015). OCR accuracy improvement on document images through a novel pre-processing approach. <https://arxiv.org/abs/1509.03456>
- Embarcados. (2024). *Modelo para identificação dos caracteres da placa* [Acesso em: 18 abr. 2026]. <https://embarcados.com.br/modelo-para-identificacao-dos-caracteres-da-placa/>
- G1. (2024). Consórcio vence leilão de concessão de rodovias que prevê pedágios no Alto Tietê e litoral paulista. <https://g1.globo.com/sp/mogi-das-cruzes-suzano/noticia/2024/04/16/consorcio-vence-leilao-de-concessao-de-rodovias-que-preve-pedagios-no-alto-tiete-e-litoral-paulista.ghtml>
- Glaserapp, L. A., Hoppe, A. F., Wisintainer, M. A., Sartori, A., & Stefenon, S. F. (2023). OCR Applied for Identification of Vehicles with Irregular Documentation Using IoT. *Electronics*, 12(5), 1083. <https://doi.org/10.3390/electronics12051083>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <https://www.deeplearningbook.org>
- Impedovo, S., Ottaviano, L., & Occhinegro, S. (1991). Optical character recognition – A survey. *International Journal of Pattern Recognition and Artificial Intelligence*, 5(1–2), 1–24. <https://doi.org/10.1142/S0218001491000028>
- Instituto Nacional de Metrologia, Qualidade e Tecnologia. (2025). PSIE - Portal de Serviços: Quais os requisitos específicos mínimos dos sistemas de livre passagem (free flow). <https://www.gov.br/inmetro/pt-br/aceso-a-informacao/perguntas-frequentes/avaliacao-da-conformidade/sistemas-automaticos-nao-metrologicos-de-fiscalizacao-de-transito/quais-os-requisitos-especificos-minimos-dos-sistemas-de-livre-passage-free-flow>
- JaiedAI. (2020). EasyOCR: Ready-to-use OCR with 80+ supported languages. <https://github.com/JaiedAI/EasyOCR>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324. <https://doi.org/10.1109/5.726791>
- Montazzolli, S., & Jung, C. (2017). Real-time Brazilian license plate detection and recognition using deep convolutional neural networks (30^a ed.). *Anais da SIBGRAPI – Conference on Graphics, Patterns and Images*, 55–62. <https://doi.org/10.1109/SIBGRAPI.2017.14>
- Mori, S., Nishida, H., & Yamada, H. (1999). *Optical Character Recognition*. John Wiley & Sons.
- Morris, A. C., Maier, V., & Green, P. (2004). From WER and RIL to MER and WIL: improved evaluation measures for connected speech recognition. *Proceedings of the 8th International Conference on Spoken Language Processing (INTERSPEECH)*, 2765–2768.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779–788. <https://doi.org/10.1109/CVPR.2016.91>
- Santos, H. H. d. (2024). *Desenvolvimento de um sistema embarcado de reconhecimento automático de placas automotivas para gerenciamento de tráfego*. <https://repositorio.ufu.br/handle/123456789/41685>
- Singh, A. R., Nihaya, U., & Yuadi, I. (2024). Text Recognition for Library Collection in Different Light Conditions. *TEM Journal*, 13(1), 266–276. <https://www.ceeol.com/search/article-detail?id=1222876>
- Soares, F., Fernandes, L., Da Rocha, A., Rego, P., Maia, J., & De Souza, J. (2020). Avaliação de Desempenho de Computadores Raspberry Pi com Algoritmos para o Reconhecimento Automático de Placas Veiculares (10^a ed.). *Anais do Simpósio Brasileiro de Engenharia de Sistemas Computacionais (SBESC)*, 33–40. https://doi.org/10.5753/sbesc_estendido.2020.13088
- Sussman, J. M. (2005). *Perspectives on Intelligent Transportation Systems (ITS)*. Springer. <https://doi.org/10.1007/b100342>
- Vargas Neto, A. d. S. (2023). *Reconhecimento automático de placas veiculares do Mercosul utilizando o Tesseract OCR*. <https://repositorio.ifes.edu.br/handle/123456789/3671>
- Vedhaviyassh, D. R., Sudhan, R., Saranya, G., Safa, M., & Arun, D. (2022). Comparative analysis of EasyOCR and TesseractOCR for automatic license plate recognition using deep learning algorithm (6^a ed.). *Anais da International Conference on Electronics, Communication and Aerospace Technology (ICECA)*, 966–971. <https://doi.org/10.1109/ICECA55336.2022.10009215>