



Universidade Federal de Ouro Preto  
Instituto de Ciências Exatas e Aplicadas  
Departamento de Engenharia Elétrica



## **Trabalho de Conclusão de Curso**

# **Identificação de placas de veículos utilizando reconhecimento de caracteres ópticos**

**Matheus Henrique Fernandes**

João Monlevade, MG  
2023

**Matheus Henrique Fernandes**

# **Identificação de placas de veículos utilizando reconhecimento de caracteres ópticos**

Trabalho de Conclusão de Curso apresentado à Universidade Federal de Ouro Preto como parte dos requisitos para obtenção do Título de Bacharel em Engenharia Elétrica pelo Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto.  
Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Sarah Negreiros de Carvalho Leite

**Universidade Federal de Ouro Preto**  
**João Monlevade**  
**2023**

## SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

F363i Fernandes, Matheus Henrique.  
Identificação de placas de veículos utilizando reconhecimento de caracteres ópticos. [manuscrito] / Matheus Henrique Fernandes. - 2023. 64 f.: il.: color., gráf., tab..

Orientadora: Profa. Dra. Sarah Negreiros de Carvalho Leite.  
Monografia (Bacharelado). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia Elétrica .

1. Imagens digitais. 2. Imagens ópticas. 3. Processamento de imagens - Técnicas digitais. 4. Veículos - Placas - Identificação. I. Leite, Sarah Negreiros de Carvalho. II. Universidade Federal de Ouro Preto. III. Título.

CDU 004.932

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



## FOLHA DE APROVAÇÃO

**Matheus Henrique Fernandes**

### Identificação de placas de veículos utilizando reconhecimento de caracteres ópticos

Monografia apresentada ao Curso de Engenharia Elétrica da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Engenharia Elétrica.

Aprovada em 16 de maio de 2023.

#### Membros da banca

Profa. Dra. Sarah Negreiros de Carvalho Leite - Orientadora - Universidade Federal de Ouro Preto  
Profa. Dra. Gilda Aparecida de Assis - Universidade Federal de Ouro Preto  
Prof. Dr. Glauco Ferreira Gazel Yared- Universidade Federal de Ouro Preto

Professora Sarah Negreiros de Carvalho Leite, orientadora do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 17/05/2023.



Documento assinado eletronicamente por **Sarah Negreiros de Carvalho Leite, PROFESSOR DE MAGISTERIO SUPERIOR**, em 17/05/2023, às 22:40, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0527315** e o código CRC **A975C992**.

*Dedico este trabalho a todos os engenheiros e engenheiras, que assim como os estudantes de engenharia, trabalham arduamente para tornar o mundo um lugar melhor para todos.*

---

## *Agradecimentos*

---

Agradeço a todos os meus familiares, amigos, professores e instituições que tornaram esta caminhada mais leve e gratificante.

*“Talvez não tenha conseguido fazer o melhor, mas lutei para que o melhor fosse feito.  
Não sou o que deveria ser, mas Graças a Deus, não sou o que era antes.”*  
*Marthin Luther King*

# Resumo

Atualmente o controle de tráfego é importante tanto em vias públicas como privadas. A identificação de placas veiculares é necessária para implementar várias aplicações, como controle de entrada e saída de veículos da cidade ou do país, monitoramento de estacionamentos e praças de pedágio, fiscalização de velocidade e passagem em semáforos. Essa identificação pode ser feita por meio do reconhecimento ótico de caracteres, convertendo os dados da placa veicular de uma foto para o formato de texto. Existem diversas técnicas para tratar a imagem e identificar os caracteres das placas de automóveis, como a aplicação de filtros de cor, redimensionamento, suavização e detecção de contornos. Este estudo avaliou dois protocolos experimentais com diferentes combinações de técnicas de tratamento de imagem considerando duas bases de dados distintas com fotos de placas de veículos. A base de dados 1 é de domínio público e contém 201 fotos, enquanto que a base de dados 2 é fruto deste trabalho e contém 105 imagens. Aplicando somente o filtro de cor em escala de cinza, que é o procedimento típico, a acurácia alcançada nas bases de dados 1 e 2 foi de 13,43% e 6,67%, respectivamente. Entretanto, aplicando o protocolo experimental proposto neste estudo foi possível atingir uma acurácia de 28,86% e 33,33% para as bases de dados 1 e 2, respectivamente. Apesar da melhoria substancial na taxa de acerto, quando comparado à metodologia clássica de reconhecimento de caracteres óticos, o desempenho é ainda insatisfatório para aplicações comerciais.

**Palavras-chave:** Reconhecimento de Caracteres Óticos, Processamento de imagens, Placas Veiculares.

# Abstract

*Nowadays, traffic control is important in both public and private roadways. The identification of vehicle license plates is necessary for implementing various applications, such as controlling vehicle entrance and exit from cities or countries, monitoring parking lots and toll plazas, and enforcing speed limits and red light violations. This identification can be done through optical character recognition, converting the data from a photo of the license plate to text format. There are various techniques for processing the image and identifying the characters on car license plates, such as applying color filters, resizing, smoothing, and contour detection. This study evaluated two experimental protocols with different combinations of image processing techniques, considering two distinct databases with photos of vehicle license plates. The first database is publicly available and contains 201 images, while the second database was created for this study and contains 105 images. Applying only the grayscale filter, which is the typical procedure, the accuracy achieved in databases 1 and 2 was 13,43% and 6,67%, respectively. However, applying the experimental protocol proposed in this study, an accuracy of 28,86% and 33,33% was achieved for databases 1 and 2, respectively. Despite the substantial improvement compared to the classical methodology of optical character recognition, the performance is still unsatisfactory for commercial applications.*

**Keywords:** *Optical Character Recognition, Image Processing, Vehicle License Plates.*

# Lista de ilustrações

Figura 1.1 – Modelos de placas aplicadas no Brasil. . . . .	15
Figura 2.1 – Procedimento padrão de pré processamento digital da imagem. . . . .	19
Figura 2.2 – Diagrama de fluxo de aplicação de OCR em placas veiculares. . . . .	20
Figura 3.1 – Exemplo de placas veiculares com diferentes padronizações. . . . .	22
Figura 3.2 – Exemplo de placas de diferentes tipografias. . . . .	23
Figura 3.3 – Exemplo de placas com distintos problemas. . . . .	23
Figura 3.4 – Placas excluídas manualmente desta base de dados. . . . .	24
Figura 3.5 – Placa Exemplo. . . . .	25
Figura 3.6 – Fluxograma de testes realizados. . . . .	30
Figura 3.7 – Teste 1 de leitura com três diferentes metodologias. . . . .	31
Figura 3.8 – Teste 2 de leitura com três diferentes metodologias. . . . .	31
Figura 3.9 – Teste 3 de leitura com três diferentes metodologias. . . . .	32
Figura 3.10 – Exemplo de aplicação do filtro de suavização. . . . .	32
Figura 3.11 – Exemplo 2 de aplicação do filtro de desfoque. . . . .	33
Figura 3.12 – OCR com aplicação combinada de filtros. . . . .	33
Figura 3.13 – Fluxograma de testes realizados do protocolo experimental base. . . . .	34
Figura 3.14 – Comparação dos filtros de binarização na ‘Placa Exemplo’. . . . .	36
Figura 3.15 – Comparação dos filtros de detecção de borda na ‘Placa Exemplo’. . . . .	37
Figura 3.16 – Fluxograma de testes realizados do protocolo experimental aprimorado. . . . .	37
Figura 4.1 – Exemplo do retorno do algoritmo em 3 diferentes cenários que apresentam uma mesma taxa de assertividade. . . . .	42
Figura 4.2 – Exemplo do retorno do algoritmo em 3 diferentes cenários que apresentam uma mesma taxa de assertividade. . . . .	43
Figura 4.3 – Apresentação de teste em uma placa específica, com três metodologias diferentes com mesma taxa de assertividade. . . . .	43
Figura 4.4 – Imagens lidas corretamente nos 16 cenários. . . . .	44
Figura 4.5 – Imagem considerada ‘ideal’, mas não lida corretamente em todos os 16 cenários. . . . .	44
Figura 4.6 – Placas com a mesma sequência alfanumérica, porém com diferentes taxas de retorno. . . . .	44
Figura 4.7 – Placas de mesma identificação, porém com diferentes taxas de retorno. . . . .	45
Figura 4.8 – Fluxograma de testes realizados considerando os 16 cenários. . . . .	47
Figura 4.9 – Comparação de taxa de assertividade dos cenários propostos pelos protocolos experimentais aplicados à base de dados pública. . . . .	59
Figura 4.10 – Comparação de taxa de assertividade dos cenários propostos pelo protocolo experimental base aplicado à base de dados própria. . . . .	60

Figura 4.11–Comparação de taxa de assertividade dos cenários propostos pelo protocolo experimental aprimorado aplicado à base de dados própria. . . .	61
Figura 5.1 – Fotografias semelhantes, com leituras distintas. . . . .	63

# Lista de tabelas

Tabela 4.1 – Tabela comparativa de cenários do protocolo experimental base considerando a base de dados pública. . . . .	41
Tabela 4.2 – Tabela comparativa de cenários do protocolo experimental aprimorado da base de dados pública. . . . .	46
Tabela 4.3 – Tabela comparativa de cenários do protocolo experimental base aplicada aos veículos da base própria. . . . .	50
Tabela 4.4 – Análise da leitura incorreta de caracteres semelhantes, considerando letras e números. . . . .	50
Tabela 4.5 – Tabela comparativa de cenários do protocolo experimental base aplicada aos veículos com placas de modelo Mercosul da base própria, corrigida. . . . .	51
Tabela 4.6 – Tabela comparativa de cenários do protocolo experimental base aplicada aos veículos com placas de modelo brasileiro da base própria, com código corretor de erro. . . . .	52
Tabela 4.7 – Caracteres que são lidos de modo incorreto, mas que não podem ser corrigidos considerando somente o padrão de posicionamento de letras e números. . . . .	53
Tabela 4.8 – Tabela comparativa de cenários do protocolo experimental aprimorado aplicada aos veículos da base própria. . . . .	54
Tabela 4.9 – Tabela comparativa de cenários do protocolo experimental aprimorado aplicada aos veículos com placas no padrão Mercosul da base própria, corrigida. . . . .	56
Tabela 4.10–Tabela comparativa de cenários do protocolo experimental aprimorado aplicada aos veículos com placas de modelo brasileiro da base própria, corrigida. . . . .	57
Tabela 4.11–Tabela comparativa de cenários do protocolo experimental base e do protocolo experimental aprimorado aplicada as placas da base de dados pública. . . . .	58
Tabela 4.12–Tabela comparativa de cenários do protocolo experimental base e do protocolo experimental aprimorado aplicada as placas da base de dados própria. . . . .	58

---

## *Lista de abreviaturas e siglas*

---

<b>ABNT</b>	Associação Brasileira de Normas Técnicas
<b>ALPR</b>	<i>Automatic License Plate Recognition</i>
<b>IBGE</b>	Instituto Brasileiro de Geografia e Estatística
<b>ICEA</b>	Instituto de Ciências Exatas e Aplicadas
<b>DPI</b>	<i>Digital Image Processing</i>
<b>MERCOSUL</b>	Mercado Comum do Sul
<b>MINFRA</b>	Ministério da Infraestrutura
<b>OCR</b>	<i>Optical Character Recognition</i>
<b>PDI</b>	Processamento Digital de Imagens
<b>RGB</b>	<i>Red Green Blue</i>
<b>SNT</b>	Secretaria Nacional de Trânsito
<b>TCC</b>	Trabalho de Conclusão de Curso
<b>UFOP</b>	Universidade Federal de Ouro Preto
<b>YOLO</b>	<i>You Only Look Once</i>

# Sumário

<b>1</b>	<b>Introdução</b>	<b>14</b>
1.1	Considerações iniciais	14
1.2	Motivação e objetivos	16
1.3	Organização do trabalho	17
<b>2</b>	<b>Revisão Bibliográfica</b>	<b>18</b>
<b>3</b>	<b>Materiais e Métodos</b>	<b>22</b>
3.1	Descrição da base de dados	22
3.1.1	Base de dados pública	22
3.1.2	Base de dados própria	24
3.2	Ambiente de programação e técnicas empregadas	25
3.3	Protocolo experimental	29
3.3.1	Protocolo experimental base	29
3.3.2	Protocolo experimental aprimorado	35
<b>4</b>	<b>Resultados</b>	<b>40</b>
4.1	Resultado da base de dados pública	40
4.1.1	Protocolo experimental base	40
4.1.2	Protocolo experimental aprimorado	45
4.2	Resultados da base de dados própria	49
4.2.1	Protocolo experimental base	49
4.2.2	Protocolo experimental aprimorado	54
4.3	Comparação dos resultados do protocolo experimental base <i>vs.</i> protocolo experimental aprimorado	58
<b>5</b>	<b>Conclusões e Propostas de Melhorias</b>	<b>62</b>
5.1	Considerações finais	62
5.2	Propostas de melhorias	63
	<b>Referências</b>	<b>65</b>

---

## *Introdução*

---

### 1.1 Considerações iniciais

Com a expansão das cidades e industrialização do país, cada vez mais os meios de transportes se fazem necessários, conectando longas distâncias físicas de forma mais rápida e a um custo pertinente. Segundo o levantamento do Instituto Brasileiro de Geografia e Estatística (IBGE) de 2021 (MINFRA; SNT, 2021), o Brasil conta com mais de 111 milhões de automóveis registrados na frota brasileira.

O controle do fluxo de trânsito pode ser realizado por meio manual, utilizando a mão de obra humana. Mas dado o crescimento da frota e a dimensão da malha rodoviária, o meio eletrônico de controle e fiscalização, por meio de radares, cancelas ou câmeras de monitoramento, se torna uma opção cada vez mais conveniente. Estes dispositivos capturam as imagens dos veículos e extraem um recorte da sua placa de identificação, de modo que é possível registrar sua passagem ou presença e recuperar as informações pertinentes associadas ao veículo (ULLAH et al., 2019). Com estes dados, é possível alimentar diversas aplicações, como controle de entrada e saída em estabelecimentos, passagem por pedágios, emissão de infrações de trânsito, dentre outras.

Entretanto, a captura da imagem pode apresentar inúmeros dificultadores (DU et al., 2012), como baixa luminosidade, resolução ruim, desfoque, pouca nitidez, problemas de enquadramento, objetos que interferem na captura, avaria da imagem ou do equipamento, perda de coloração, dentre outros. Além disto, o ambiente no qual os veículos estão sendo monitorados e o equipamento de registro das imagens geram variações que podem dificultar no reconhecimento dos caracteres da placa. Outro ponto que também deve ser considerado é a falta de padronização universal das placas veiculares, o que impede a elaboração de códigos corretores de erros mais eficazes nos sistemas de identificação.

Os problemas mais comumente encontrados podem ser elencados como segue:

1. Variações de placas:

- localização: podem existir placas em diferentes partes de uma imagem;
- quantidade: uma imagem pode conter mais do que apenas uma placa de veículo;
- tamanho: as placas podem estar em varias distâncias da câmera, alterando o tamanho da mesma na fotografia;
- cor: as placas podem ter diferentes cores, assim como seus caracteres;
- fonte: placas de diferentes localidades podem ter distintas topografias;
- padrão *versus* design: o padrão de posicionamento de letras e números nas placas, como por exemplo, o Brasil atualmente tem dois diferentes padrões, como o modelo Mercosul (AAA0A00) e o modelo antigo (AAA0000), como mostrado na Figura 1.1;

Figura 1.1 – Modelos de placas aplicadas no Brasil.



Fonte: (DONALD, 2021).

- oclusão: as placas podem conter caracteres bloqueados ou obscurecidas por sujeira, por exemplo;
  - inclinação: as placas podem estar inclinadas, de acordo com a angulação do veículo em transito ou da fotografia em si;
  - outros: além dos caracteres, uma placa pode conter objetos, como parafusos ou incluir molduras, por exemplo.
2. Variações do ambiente:
- iluminação: as fotografias podem apresentar distintos níveis e tonalidades de iluminação, devido a iluminação artificial de faróis de veículos terceiros, por exemplo;

- fundo: o fundo da imagem pode conter padrões semelhantes a placas, de modo que a mesma se 'camufle' entre as simbologias da fotografia, como por exemplo, números carimbados em um veículo, pára-choques com padrões verticais e pisos texturizados, dificultando seu reconhecimento.

### 3. Qualidade do equipamento de aquisição de imagens:

- sensor: equipamentos mais atuais tem sensores mais robustos, resultando um melhor poder computacional e de aquisição de imagem;
- lente: a amplitude da lente interfere diretamente na quantidade de luz recebida pelo sensor, de modo a se ter imagens mais nítidas e de melhor qualidade, além claro, da limpeza destes materiais;
- zoom: o equipamento pode apresentar zoom real, pela extensão do diafragma, ou zoom digital, sendo que este, resulta em apenas a ampliação digital da imagem sem melhora de sua qualidade, gerando ruídos na imagem capturada;
- estabilidade: um equipamento com estabilidade ótica possibilita a captura de imagens sem tremores, tendo deste modo imagens mais focadas.

Diante do exposto, fica claro que realizar o reconhecimento óptico dos caracteres (OCR, do inglês *Optical Character Recognition*) de placas automotivas é uma tarefa complexa, que envolve dificuldades tanto na captura da imagem quanto no processamento digital das mesmas. Essa complexidade pode levar a uma taxa de assertividade baixa, o que pode desencadear problemas nas aplicações que estão sendo gerenciadas, tais como bloqueio de acesso em sistemas de cancelas ou emissão de multas erradas, por exemplo.

## 1.2 Motivação e objetivos

Um sistema de reconhecimento automático de placas pode trazer diversas vantagens e benefícios para diferentes setores, como segurança pública, transporte, logística e comércio. Ao automatizar a leitura das placas veiculares, é possível melhorar o controle de acesso em estacionamentos, pedágios e áreas restritas, identificar veículos roubados ou suspeitos, monitorar o tráfego de veículos e otimizar a gestão de frotas. Além disso, esse tipo de sistema pode contribuir para a redução de acidentes de trânsito, ao identificar veículos que estejam em excesso de velocidade ou cometendo infrações de trânsito. O desenvolvimento de um sistema de reconhecimento automático de placas pode, portanto, trazer importantes benefícios para a sociedade.

Atualmente, existem softwares pagos, como o *Open ALPR (Automatic License Plate Recognition)* da Rekor (REKOR, 2022) e *Plate Recognizer (PLATE RECOGNIZER)*, 2022), nenhuma das duas empresas apresenta a taxa de assertividade de seus sistemas, mas seus algoritmos são empregados em âmbito global.

Este projeto visa compreender as etapas envolvidas no desenvolvimento de um sistema de detecção automático dos caracteres de placas veiculares, propondo uma solução em código aberto e não comercial que utilize técnicas de processamento digital de imagens, visão computacional e aprendizado de máquinas.

Para atingir este objetivo geral, foram definidos os seguintes objetivos específicos:

1. Realizar uma revisão bibliográfica para compreender as técnicas e as problemáticas relacionadas ao processamento de imagens de placas veiculares.
2. Determinar as principais dificuldades na caracterização de placas veiculares por meio de identificação de caracteres óticos.
3. Encontrar os principais sistemas comerciais de reconhecimento de caracteres óticos em placas veiculares em uso e como são aplicados na prática.
4. Estudar e implementar técnicas de processamento de imagens.
5. Encontrar e/ou criar uma base de dados de placas veiculares.
6. Implementar um sistema de identificação de placas de veículos utilizando reconhecimento de caracteres óticos e aplicar na base de dados.
7. Comparar o desempenho na identificação dos caracteres nas placas utilizando diferentes técnicas de processamento de imagens.

### 1.3 Organização do trabalho

Este trabalho está organizado em 5 capítulos da seguinte maneira. No primeiro Capítulo é apresentada a introdução do trabalho, com a problemática, objetivos, motivação e justificativa. No Capítulo 2 é apresentada a revisão bibliográfica, abordando os principais estudos que serviram de base para o presente trabalho. No Capítulo 3 é descrito o protocolo experimental executado durante a desenvoltura e solução da problemática. O quarto Capítulo apresenta os resultados, o nível de satisfação e confiabilidade do sistema, comparando os resultados esperados com os obtidos em trabalhos similares de outros autores. No Capítulo 5 são apresentados as considerações finais e as propostas de melhorias que possam vir a ser implementadas para ampliar a taxa de assertividade do sistema.

---

## *Revisão Bibliográfica*

---

Uma das principais referências na área de Processamento Digital de Imagens é o livro ‘Processamento de imagens digitais’ (GONZALEZ; WOODS, 2000) que apresenta de forma simplificada técnicas de filtragem e tratamento de imagens digitais.

O trabalho de Filho et al. (2019) aplica o reconhecimento de caracteres óticos para identificação das placas de veículos para gerenciar o acesso a um condomínio residencial em um sistema de cancelamento, realizando uma comparação do resultado obtido com a base de dados coletada, onde, em caso de similaridade, o acesso do veículo à localidade é permitido e as cancelas levantadas. Ele propões o tratamento da imagem e valida o template obtido através de *Template Matching* utilizando coeficiente de correlação de Pearson, alcançando 97% de taxa de sucesso.

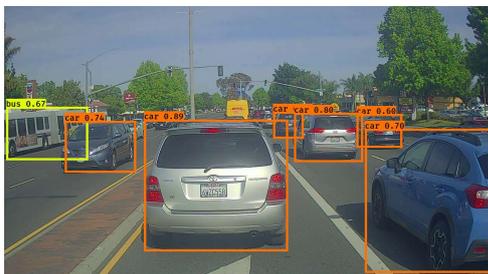
Em (ULLAH et al., 2019) os autores descrevem uma aplicação que também realiza o controle de acesso de veículos com cancela. Eles comparam diferentes técnicas de classificadores de OCR e indicam a técnica de utilização de percepção de multicamadas como classificador da rede neural como sendo a melhor dentre as testadas, obtendo uma taxa de assertividade de 93,02% no projeto desenvolvido.

O procedimento experimental tipicamente realizado nos trabalhos estudados consiste na identificação do veículo em uma imagem, seguido da localização da placa, estas etapas constituem o pré-processamento do sistema que permite obter a imagem da placa veicular. Na sequência, a imagem da placa veicular é processada para que possa ser feito o reconhecimento dos caracteres óticos, como apresentado na Figura 2.1.

O procedimento de reconhecimento dos automóveis nas fotografias, das bibliografias estudadas se baseiam em utilizar a plataforma YOLO, reconhecendo objetos via fragmentação de pequenas partes da imagem, avaliando os limites de cada quadro, classificando-as e através dos treinamentos de suas bases de dados, encontrando as bordas limitadoras, de forma a se prever a classificação das próximas bordas (REDMON et al., 2016), assim, reconhecendo objetos em vídeos.

Pensando no objetivo geral deste trabalho, a tese de mestrado '*An efficient and*

(a) Exemplo de identificação de carros utilizando YOLO.



Fonte: (LODAYA, 2018)

(b) Exemplo de identificação da localização da placa.



Fonte: (BUFF, 2021)

Figura 2.1 – Procedimento padrão de pré processamento digital da imagem.

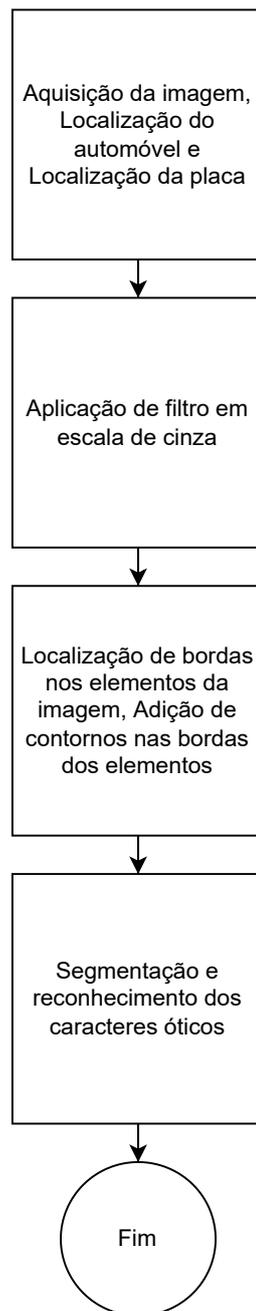
*layout-independent automatic license plate recognition system based on the YOLO detector*' (LAROCA et al., 2021) cria um sistema de reconhecimento de placas veiculares, coletando imagens de placas de veículos durante o trânsito dos mesmos, realizando o processamento digital de suas imagens e, por fim, reconhecendo seus caracteres óticos. Neste trabalho, o autor utiliza como base o código YOLO para reconhecimento dos carros e consegue uma taxa de eficácia de 64.9%. Em testes, aplicando a mesma base de dados na estrutura do Open ALPR, o autor teve como retorno uma taxa de assertividade de 50.9%, deste modo, projetando um sistema mais eficiente que o sistema comercial mais conhecido do mercado. O autor desenvolveu também outros trabalhos (LAROCA et al., 2018), (GONÇALVES et al., 2018), (GONÇALVES et al., 2019), (LAROCA et al., 2022a), (LAROCA et al., 2022b), (LAROCA et al., ) que aprimoram e embasam o sistema desenvolvido por ele.

Apesar do problema da identificação dos caracteres das placas veiculares envolverem estes processos preliminares, a base de dados adotada neste trabalho já apresenta as imagens das placas veiculares recortadas, possibilitando o tratamento do processamento digital de imagem focado no reconhecimento óptico de caracteres (OCR).

Neste caso, o procedimento mais utilizado consiste em aplicar um filtro de colorimetria em escala de cinza, tornando a imagem mais suscetível ao reconhecimento de caracteres. Para tal, se realiza a aplicação de localização de bordas na imagem e então localização dos contornos dos elementos da imagem, segmentação dos caracteres e, por fim, a leitura e identificação individual de cada carácter.

Desta forma, o único procedimento para realização do tratamento da imagem é a etapa 2 do diagrama representado na Figura 2.2. Entretanto, neste trabalho são propostas alterações no procedimento de tratamento de imagem, a fim de aumentar a eficácia do sistema. Para isto, a biblioteca *Pytesseract* foi utilizada no processo de OCR aplicado neste trabalho. Ela permite que informações de uma determinada imagem sejam transcritas em formato de string, após o tratamento das imagens. Como descrito em seu manual online

Figura 2.2 – Diagrama de fluxo de aplicação de OCR em placas veiculares.



(TESSERACT..., 2022), em alguns casos se faz necessário um maior tratamento das imagens, para melhorar a taxa de assertividade. Neste manual também é recomendado a aplicação da binarização - que torna as imagens coloridas, em preto e branco -, remoção de ruídos, aumento ou diminuição da espessura dos caracteres e rotação das imagens. Estes procedimentos dependem da imagem que está sendo tratada, podendo aprimorar ou prejudicar a acurácia do sistema.

Em Coelho (2018), o autor utiliza como método de tratamento de imagem, a aplicação de um filtro que se baseia no operador laplaciano, buscando melhorar a nitidez da fotografia. Aplicando a limiarização e dilatando a figura, seu método obteve uma taxa

de retorno de 78% em placas brasileiras.

Rodrigues (2018) utiliza redes neurais para reconhecer os caracteres em placas e obtêm uma taxa de assertividade de 49,22%. Ele utiliza fotografias recortadas manualmente, sem problemas de angulação ou cor da placa automotiva. Enquanto que, Formentin (2020) desenvolveu um aplicativo para leitura e validação de placas veiculares utilizando a tecnologia ALPR aplicada na fiscalização em tempo real de veículos, de forma a facilitar e tornar mais eficazes as abordagens policiais. Ambos os trabalhos utilizaram uma base de dados com fotografias de placas brasileiras no padrão brasileiro (AAA-9999), ou seja, 3 letras seguidas por 4 algarismos. A existência de um padrão facilita a identificação e correção de erros comuns, como a confusão entre a letra 'S' e o número '5', ou da letra 'I' e do número '1'.

O trabalho de (MENON; OMMAN, 2018) traz uma metodologia diferente, apresentando uma imagem com várias placas automotivas para serem identificadas. Desta forma, as comparações e correções são realizadas ao se avaliar as placas de mesmo padrão presente na mesma imagem, facilitando o processo de ajustes.

---

## *Materiais e Métodos*

---

### 3.1 Descrição da base de dados

Neste trabalho foram utilizadas duas base de dados. A primeira base, se trata de uma base de dados pública, contendo placas indianas e sem padronização. Já a segunda base, se trata de uma base de dados de coleta própria, considerando placas de automóveis brasileiros do padrão antigo e do padrão Mercosul, conforme mostrado na Figura 1.1.

#### 3.1.1 Base de dados pública

A base de dados pública empregada neste trabalho está disponível na plataforma online Kaggle (KAGGLE, 2021). Ela tem um total de 209 fotos de placas de veículos indianos. As fotos não estão padronizadas, possuindo diferentes angulações, proximidade da câmera, nível de luminosidade, foco e nitidez. Além disso, o padrão das placas veiculares na Índia variam entre as diversas regiões do país, além de alterarem a quantidade de letras e números e a ordem destas, também alteram a fonte dos caracteres e as cores. A Figura 3.1 ilustra modelos de placas veiculares que compõem a base de dados.

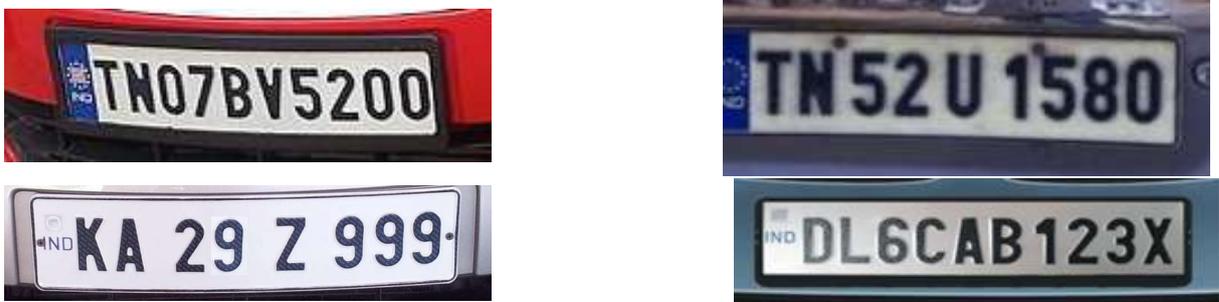


Figura 3.1 – Exemplo de placas veiculares com diferentes padronizações.

Além dos mais distintos modelos, as amostras da base de dados apresenta placas com diferentes tipografias, como apresentado pela Figura 3.2.



Figura 3.2 – Exemplo de placas de diferentes tipografias.

Como um dificultador, as amostras da base de dados ainda apresentam diversos problemas de nitidez, iluminação, angulações e interferências, como exemplificados na Figura 3.3.



(d) Placa com baixa nitidez.

Figura 3.3 – Exemplo de placas com distintos problemas.

Como pode ser observado, as fotos apresentam tamanhos distintos entre si. Além disto, apresentam diversas peculiaridades, que são problemas comuns de serem encontrados nas fotografias de placas de automóveis circulando, de modo que a base de dados utilizada pode ser considerada representativa da realidade.

Estes problemas devem ser tratados, pois dificultam a tarefa de reconhecimento dos caracteres e podem reduzir a eficácia do sistema.

Após uma análise manual das fotografias desta base de dados, oito imagens foram descartadas, pois apresentavam caracteres ocultos devido há algum obstáculo ou por recorte da foto, impossibilitando a sua identificação. As imagens descartadas são apresentadas na Figura 3.4.



(a) Placa com caracteres obstruídos.



(c) Placa cortada.



(e) Placa com caracteres obstruídos.



(g) Placa fora do padrão legislativo.



(b) Placa com caracteres obstruídos.



(d) Placa cortada.



(f) Placa cortada.



(h) Placa com caracteres obstruídos.

Figura 3.4 – Placas excluídas manualmente desta base de dados.

### 3.1.2 Base de dados própria

A base de dados própria foi coletada através de um celular Xiaomi Redmi Note 7, que utiliza uma câmera Samsung ISOCELL GM1 Ultra Clear de 1/2", com captura de

imagens de 48 Mp com angulo de abertura de F 1.8 e tamanho de pixel de  $0,8 \mu\text{m}$ .

Foram capturadas fotografias de 105 veículos, sendo 66 placas veiculares no padrão brasileiro e e 39 placas veiculares do padrão Mercosul.

A Figura 3.5 apresenta uma amostra de fotografia da base de dados própria. Esta placa foi adotada como a ‘Placa Exemplo’, para fins de demonstração a aplicação dos filtros aplicados ao longo do trabalho.



Figura 3.5 – Placa Exemplo.

Por se tratar de capturas manuais realizadas em diferentes ambientes é difícil manter uma padronização das fotografias. Desta forma, as fotos apresentam variações de angulação, proximidade, diferente luminosidade e sombreamento. Além disso, como a base foi coletada em João Monlevade/Minas Gerais, que é uma cidade de extração e trabalho com minério de ferro, diversas placas sujeiras e avarias, o que dificulta sua leitura correta. Entretanto, não há variação da tipografia, ocorrem somente os dois tipos presentes em cada padrão, e não há obstrução nem corte dos caracteres.

## 3.2 Ambiente de programação e técnicas empregadas

O sistema de reconhecimento dos caracteres foi desenvolvido utilizando a linguagem aberta Python no ambiente online do Google Colab (GOOGLE, 2022), que fornece uma maior capacidade de processamento.

A principal biblioteca empregada foi a *cv2* (OPENCV, 2022), que permite carregar a imagem e realizar o seu tratamento. As cinco metodologias de tratamento de imagem empregadas foram:

### 1. Redimensionamento do tamanho da imagem:

Para o redimensionamento do tamanho da imagem, a função realiza uma interpolação dos seus pixels, avaliando e determinando o melhor método de interpolação aplicável, sendo em suma, interpolação por área interna ou interpolação linear, de modo que sua resultante atenda as especificações da função.

## 2. Aplicação de filtro de colorimetria em escala de cinza:

Na aplicação do filtro de colorimetria, a função avalia os pixels da imagem como pixels RGB, avaliando a intensidade das cores vermelha, verde e azul em cada pixel. Então, seus valores são decrescidos, aproximando-os de 0, o que implicaria na cor preta. As seguintes equações, representam a normalização dos valores tricromáticos, utilizando uma média ponderada, referente às quantidades de pixels RGB naquele ponto.

$$r = \frac{R}{R + G + B} \quad (3.1)$$

$$g = \frac{G}{R + G + B} \quad (3.2)$$

$$b = \frac{B}{R + G + B} \quad (3.3)$$

A cor definida em cada ponto pode ser expressa pela expressão:

$$C_l = r.R + g.G + b.B \quad (3.4)$$

de modo a considerar a quantidade de pixels RGB, bem como seus valores normalizados.

Dessa forma, o filtro realiza uma aproximação individual para cada pixel, calculando o valor do índice de cor em relação ao valor RGB zero, que representa a cor preta. Isso resulta em uma imagem final com em tonalidades de cinza, permitindo que as características da imagem sejam preservadas e visíveis, embora as cores originais sejam perdidas.

## 3. Suavização da imagem:

O filtro de suavização consiste na aplicação de filtros passa-baixas na imagem, onde a função aplicada determina um pixel base, definindo-o como *kernel*, e então se avalia os 25 pixels abaixo deste *kernel*, calculando uma média entre todos estes pixels, como apresentado pela Equação 3.5 .

$$K = \frac{1}{25} \times \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix} \quad (3.5)$$

O pixel central recebe o valor resultante deste cálculo. Este processo é realizado para cada pixel da imagem, de modo que o resultado final implica na suavização de todos os pixels da imagem, gerando um desfoque.

#### 4. Binarização da imagem:

A binarização da imagem consiste na conversão de uma imagem com níveis de cinza para uma imagem com representação binária (dois tons), puramente branco e puramente preto, de modo a destacar os objetos de análise do fundo da imagem, segmentando os caracteres óticos a partir de um ponto de corte. Neste trabalho foram inicialmente consideradas duas técnicas a binarização e a binarização Gaussiana.

#### 5. Filtro de detecção de bordas de objetos:

Diferentes filtros podem ser empregados para realizar a detecção de contornos na imagem.

- O filtro Sobel calcula o gradiente da intensidade da imagem em cada ponto, dando a direção da maior variação entre claro e escuro e a quantidade de variação nessa direção, deste modo, compreende-se a variação da luminosidade em cada ponto, de forma mais suave ou abrupta, sendo este, a detecção de bordas de objetos, como por exemplo, os caracteres óticos das imagens.

A saída é definida pela raiz quadrada da soma dos quadrados de duas matrizes  $3 \times 3$  que são convoluídas com a imagem original para calcular aproximações das derivadas horizontais e verticais.

$$G_x = \begin{bmatrix} -1 & 0 & +1 \\ -2 & 0 & +2 \\ -1 & 0 & +1 \end{bmatrix} \times \text{imagem} \quad (3.6)$$

$$G_y = \begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \times \text{imagem} \quad (3.7)$$

$$|G| = \sqrt{G_x^2 + G_y^2} \quad (3.8)$$

Se a magnitude calculada  $G$  for maior do que o menor valor de entrada, o pixel é considerado um pixel de borda.

Já a direção do gradiente da borda, perpendicular a direção da borda, pode ser definido da seguinte forma.

$$\alpha = \text{arctg}(G_y/G_x) \quad (3.9)$$

- O filtro de Roberts é uma versão simplificada do filtro de Sobel. Neste método se calcula o gradiente da intensidade da imagem em cada ponto, dando a direção da maior variação entre claro e escuro e a quantidade de variação nessa direção, deste modo, compreende-se a variação da luminosidade em cada ponto, de forma mais suave ou abrupta, sendo este, a detecção de bordas de objetos, como por exemplo, os caracteres óticos das imagens.

A saída é definida pela raiz quadrada da soma dos quadrados de duas matrizes 2x2 que são convoluídas com a imagem original para calcular aproximações das derivadas horizontais e verticais

$$G_x = \begin{bmatrix} 0 & +1 \\ -1 & 0 \end{bmatrix} \times \text{imagem} \quad (3.10)$$

$$G_y = \begin{bmatrix} +1 & 0 \\ 0 & -1 \end{bmatrix} \times \text{imagem} \quad (3.11)$$

$$|G| = \sqrt{G_x^2 + G_y^2} \quad (3.12)$$

Se a magnitude calculada  $G$  for maior do que o menor valor de entrada, o pixel é considerado um pixel de borda.

Já a direção do gradiente da borda, perpendicular a direção da borda, pode ser definido da seguinte forma.

$$\alpha = \arctg(G_y/G_x) \quad (3.13)$$

Por se tratar de matrizes menores, é um filtro mais simples e menos custoso computacionalmente, porém, seus resultados são menos precisos e mais suscetíveis aos ruídos da imagem, quando comparados ao filtro Sobel.

- O filtro Canny uniformiza o ruído e localiza as bordas. Porém, tem um custo computacional mais alto, sendo mais eficiente no processamento de imagens com ruídos ou com bordas difusas.

A Equação:

$$G_x = \frac{1}{\sqrt{2\pi\sigma^2}} * e^{-\frac{x^2}{2\sigma^2}} \quad (3.14)$$

determina os estudos de bordas ideais da imagem, dado por  $G$ , enquanto  $\sigma$  é o desvio padrão;

A primeira derivada da equação, em relação a  $x$ , suaviza os ruídos e localiza as bordas, sendo esta aplicada à imagem, resulta na utilização do filtro de Canny.

$$G'_x = \frac{-x}{\sqrt{2\pi\sigma^3}} * e^{-\frac{x^2}{2\sigma^2}} \quad (3.15)$$

Estas técnicas de processamento de imagens foram combinadas em diferentes cenários e após a aplicação delas a imagem foi submetida as funções de leitura da biblioteca do *pytesseract* (TESSERACT... , 2022). Na sequência, a saída da função de transformação da imagens em texto era avaliada pela função *re.sub*, responsável por excluir os caracteres não alfanuméricos que estivessem na string. Este processo é importante para se remover os espúrios das leituras do OCR. Esta função também foi utilizada para retirar informações desnecessárias lidas, como a informação de cidade e estado, no caso das placas de modelo brasileiro antigas, ou ainda, remover erros de leitura em placas padronizadas.

### 3.3 Protocolo experimental

Este Capítulo descreve o protocolo experimental base contendo 16 cenários de testes e o protocolo experimental aprimorado que incorporou outras técnicas e contém 21 cenários de testes para identificação de caracteres óticos, em ambas as bases de dados.

#### 3.3.1 Protocolo experimental base

Para realização do reconhecimento dos caracteres óticos, em uma primeira análise, poderia ser aplicada a função *image\_to\_string* da biblioteca *pytesseract* diretamente na imagem sem tratamento algum, realizando assim a leitura dos caracteres. Este consistiu no primeiro cenário de teste.

Como as fotos dos veículos contém os problemas discutidos na Seção 3.1, é necessário realizar o tratamento digital da imagem, de forma a se melhorar a acurácia do reconhecimento de caracteres óticos. De acordo com a literatura estudada (LAROCA et al., 2021), o procedimento padrão aplicado prevê a aplicação da colorização da imagem em escalas de cinza, por meio de um filtro em escala de cinza na base de dados de imagens com tamanhos padronizadas.

Uma vez que as imagens da base de dados pública tem diferentes dimensões, surgem duas possibilidades: o redimensionamento das imagens para uniformização deve ser realizado antes ou depois da aplicação do filtro de colorimetria em escala de cinza?

Neste trabalho, foram testadas ambas as situações e mensurada a acurácia do sistema de identificação veicular em cada uma delas. Desta forma, foram definidos três procedimentos esquematizados na Figura 3.6. No primeiro caso, se aplica somente o filtro em escala de cinza. No segundo caso, se aplica o filtro em escala de cinza e na sequência se realiza o redimensionamento da imagem. No terceiro caso, é realizado o redimensionamento da imagem e depois aplicado o filtro em escala de cinza.

Apesar de semelhantes, para algumas placas somente uma destas sequências de técnicas permite a identificação correta dos caracteres. Para ilustrar melhor, são apresentados três testes empregando placas da base de dados pública.

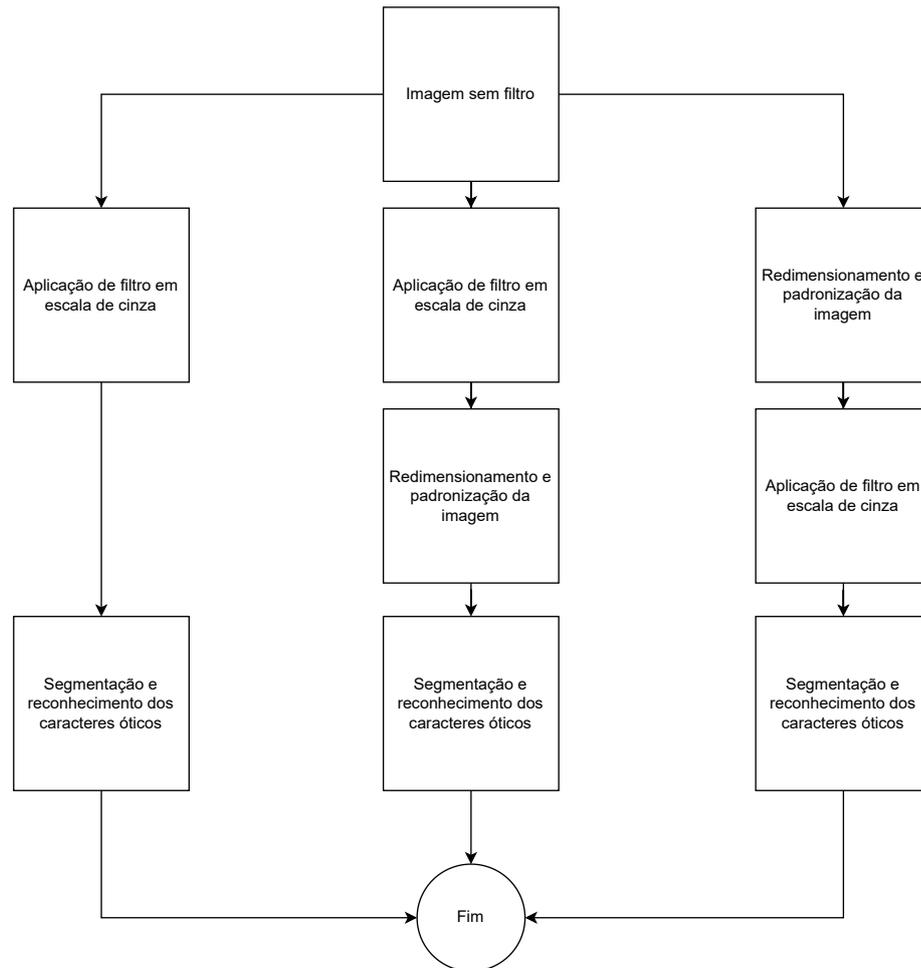


Figura 3.6 – Fluxograma de testes realizados.

1. **Teste 1:** No caso da placa mostrada na Figura 3.7, os três procedimentos são capazes de realizar a leitura dos caracteres corretamente.
2. **Teste 2:** Entretanto, a placa mostrada na Figura 3.8 é identificada corretamente somente quando é realizado o primeiro procedimento, com a aplicação do filtro em escala de cinza, sem redimensionamento da imagem.
3. **Teste 3:** A placa apresentada na Figura 3.9 exige que o segundo procedimento seja realizado para que ocorra a correta identificação dos símbolos.



(a) Imagem Original



(c) Filtro de cinza e redimensionamento.  
Leitura: HR26BP3543



(b) Filtro de cinza.  
Leitura: HR26BP3543



(d) Redimensionando e filtro de cinza.  
Leitura: HR26BP3543

Figura 3.7 – Teste 1 de leitura com três diferentes metodologias.



(a) Imagem Original.



(c) Filtro de cinza e redimensionamento.  
Leitura: NHR26BR9044



(b) Filtro de cinza.  
Leitura: HR26BR9044



(d) Redimensionando e filtro de cinza.  
Leitura: NEHR26BR9044

Figura 3.8 – Teste 2 de leitura com três diferentes metodologias.

Com os testes ilustrados nas Figuras 3.7, 3.8 e 3.9 fica claro que algumas placas veiculares precisam de um tratamento mais específico para serem lidas corretamente. Portanto, é necessário ter cuidado com o procedimento metodológico adotado para se garantir uma maior acurácia do sistema de identificação dos caracteres.

Apesar de a metodologia aplicada nos trabalhos estudados utilizarem basicamente a aplicação de filtros na escala de cinza para realizar o tratamento da imagem, como por



Figura 3.9 – Teste 3 de leitura com três diferentes metodologias.

exemplo em (ALMERON, 2016) e (RODRIGUES, 2018), neste trabalho, outros filtros foram avaliados, para verificar a hipótese da melhoria do reconhecimento dos caracteres das placas veiculares.

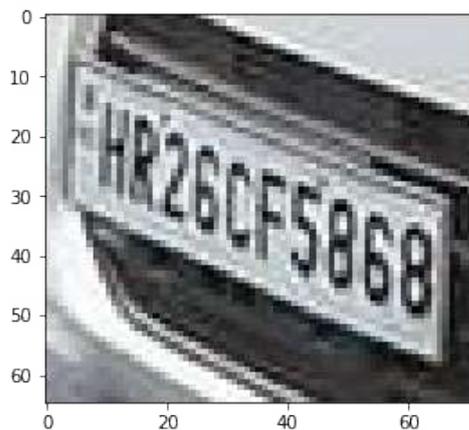
Em imagens de placas de baixa definição, uma estratégia que pode ser adotada consiste em aplicar um filtro de suavização que causa um leve embaçamento na fotografia, de forma que a imagem se torne menos pixelada, e ainda assim, legível, conforme mostra a Figura 3.10.



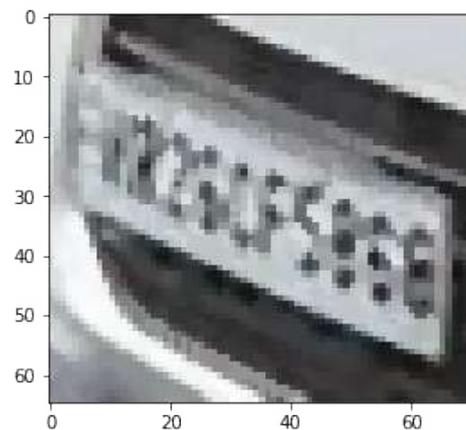
Figura 3.10 – Exemplo de aplicação do filtro de suavização.

Entretanto, dependendo da qualidade da imagem, a aplicação deste filtro pode prejudicar a realização do OCR, como pode ser apresentado pela Figura 3.11.

Ainda, a aplicação dos filtros de suavização e de escala de cinza, em uma determinada ordem específica, pode resultar na leitura dos caracteres óticos de modo correto ou não. A Figura 3.12 apresenta quatro casos nos quais se aplica a função *image\_to\_string* do *pytesseract* para se obter os caracteres das placas veiculares. No caso da imagem original (Figura 3.12 (a)) não ocorre a identificação de nenhum caracter. Nos casos em que é realizado o redimensionamento da imagem (Figura 3.12 (b)) e o redimensionamento da



(a) Imagem Original.



(b) Imagem com filtro de desfoque.

Figura 3.11 – Exemplo 2 de aplicação do filtro de desfoque.

imagem seguido da aplicação do filtro de suavização (Figura 3.12 (c)) ocorre a identificação dos caracteres da placa, mas com erros. Entretanto, se for feito o redimensionamento da imagem, seguido pelo filtro de suavização e pelo filtro em escala de cinza, obtêm-se o resultado esperado (Figura 3.12 (d)). Ou seja, a ordem em que os filtros são aplicados pode impactar no resultado obtido pelo OCR em determinadas imagens de placas veiculares.



(a) Imagem Original.  
Leitura: Sem leitura



(b) Imagem redimensionada.  
Leitura: OLCNY2231



(c) Imagem redimensionada com filtro de suavização.  
Leitura: 130172731



(d) Imagem redimensionada com filtro de suavização e filtro em escala de cinza.  
Leitura: DL3CAY2231

Figura 3.12 – OCR com aplicação combinada de filtros.

O protocolo experimental base considera portanto, as possibilidades de sequencia de aplicações de três técnicas de processamento de imagens:

- Filtro em escala de cinza;
- Redimensionamento;
- Filtro de desfoque;

A combinação de aplicação destas técnicas em diferentes ordens, acrescido do caso em que não se aplica nenhuma técnica, resultou em 16 cenários de teste, conforme mostra a Figura 3.13.

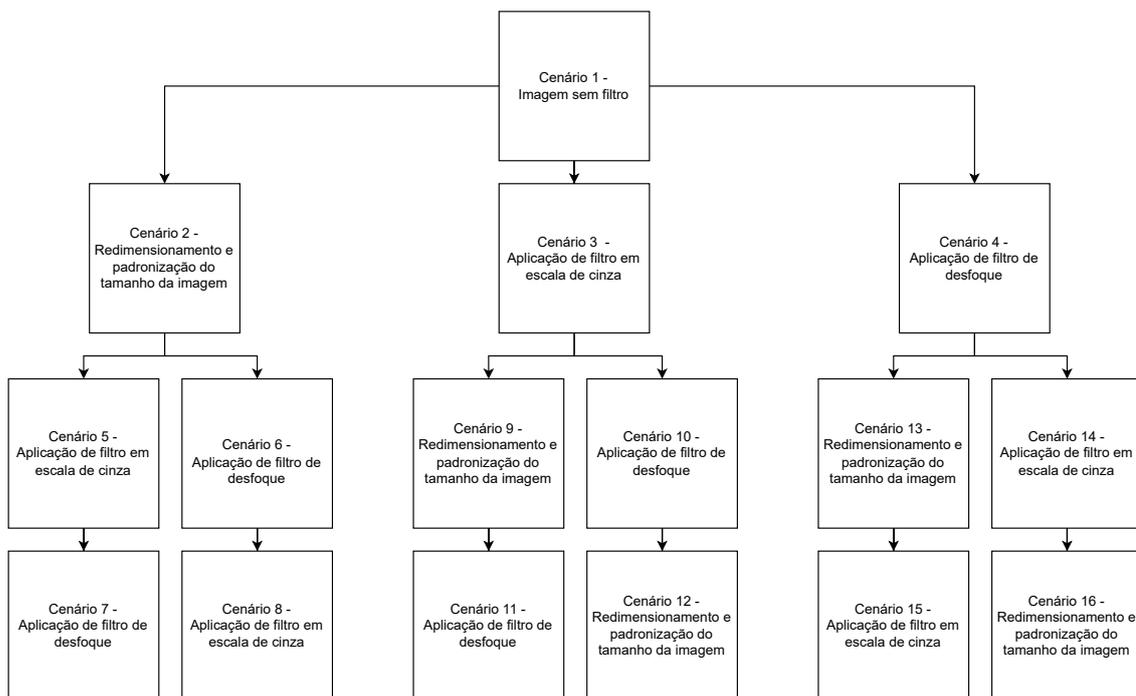


Figura 3.13 – Fluxograma de testes realizados do protocolo experimental base.

Nesta metodologia, cada imagem da base de dados segue passando por todos os blocos de processamento de sinais, até que a sequência de caracteres desejada seja lida, ou até que não haja outra possibilidade. Apesar de algumas sequências de filtros e técnicas serem mais promissoras, são testados todos os procedimentos, pois em casos específicos, algumas sequencias de técnicas são as únicas que permitem a correta identificação dos caracteres.

#### Descrição dos cenários do protocolo experimental base:

- **Cenário 1:** Imagem sem nenhum filtro.
- **Cenário 2:** Redimensionamento para padronização do tamanho da imagem.
- **Cenário 3:** Aplicação de filtro em escala de cinza.
- **Cenário 4:** Aplicação de filtro de suavização.

- **Cenário 5:** Redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.
- **Cenário 6:** Redimensionamento para padronização do tamanho da imagem e então aplicação de filtro de suavização.
- **Cenário 7:** Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação de filtro de suavização.
- **Cenário 8:** Redimensionamento para padronização do tamanho da imagem, aplicação de filtro de suavização e então aplicação de filtro em escala de cinza.
- **Cenário 9:** Aplicação de filtro em escala de cinza e então redimensionamento para padronização do tamanho da imagem.
- **Cenário 10:** Aplicação de filtro em escala de cinza e então aplicação de filtro de suavização.
- **Cenário 11:** Aplicação de filtro em escala de cinza, redimensionamento para padronização do tamanho da imagem e então aplicação de filtro de suavização.
- **Cenário 12:** Aplicação de filtro em escala de cinza, aplicação de filtro de suavização e então redimensionamento para padronização do tamanho da imagem.
- **Cenário 13:** Aplicação de filtro de suavização e então redimensionamento para padronização do tamanho da imagem.
- **Cenário 14:** Aplicação de filtro de suavização e então aplicação de filtro em escala de cinza.
- **Cenário 15:** Aplicação de filtro de suavização, redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.
- **Cenário 16:** Aplicação de filtro de suavização, aplicação de filtro em escala de cinza e então redimensionamento para padronização do tamanho da imagem.

### 3.3.2 Protocolo experimental aprimorado

O protocolo experimental aprimorado foi proposto para complementar o protocolo experimental base, nele foram consideradas as seguintes novas técnicas de processamento de imagem:

- Binarização da imagem;
- Binarização Gaussiana da imagem;
- Filtro Roberts de detecção de bordas de objetos;

- Filtro Canny de detecção de bordas de objetos;

As técnicas binarização e binarização Gaussiana tem como propósito transformar uma imagem colorida (RGB) em preto e branco, desta forma, foram realizados testes preliminares para verificar a eficácia de ambas as binarizações quando aplicadas à base de dados própria. Após uma análise preliminar, foi escolhida a técnica de binarização, que apresentou um melhor retorno.

A título de exemplo, é apresentada na Figura 3.14 o resultado da aplicação da binarização e da binarização Gaussiana na ‘Placa Exemplo’. É possível notar que a binarização da imagem permite uma adaptação melhor na sua visualização, permitindo uma melhor identificação dos caracteres.

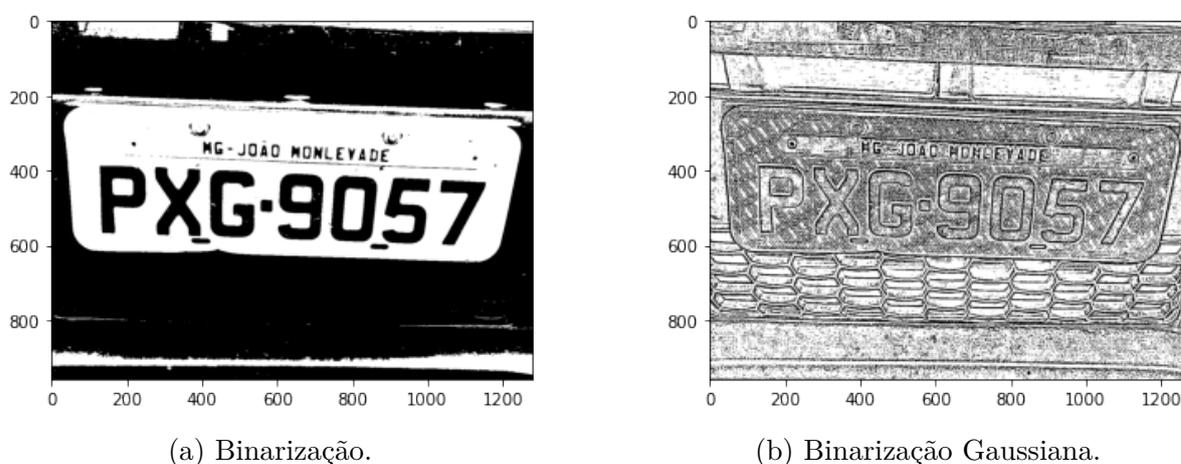


Figura 3.14 – Comparação dos filtros de binarização na ‘Placa Exemplo’.

Deste modo, a técnica de binarização gaussiana é removida do protocolo experimental base em detrimento da binarização padrão.

Com relação aos filtros de borda, foi comparado o efeito da aplicação do filtro Roberts e do filtro Canny. Para exemplificação, considere a Figura 3.15, que apresenta a ‘Placa Exemplo’ submetida a ambos os filtros. Percebe-se que o filtro de borda acaba causando a perda de informações úteis da imagem, prejudicando a sua visualização, mesmo após o bom efeito da binarização. Deste modo, o OCR ficou prejudicado. Assim, optou-se por não incluir esta técnica no protocolo experimental aprimorado.

Após todas as análises, o protocolo experimental aprimorado considerou as técnicas do protocolo base acrescido da binarização de imagens, totalizando quatro técnicas de processamento de imagens. Além disso, para viabilizar o protocolo e torná-lo aplicável, dada a elevada quantidade de possibilidades de combinações entre as técnicas, foi fixada a seguinte condição, seguindo a literatura estudada (LAROCA et al., 2021):

- A binarização da imagem é aplicada imediatamente após a aplicação do filtro de colorimetria em escala de cinza.

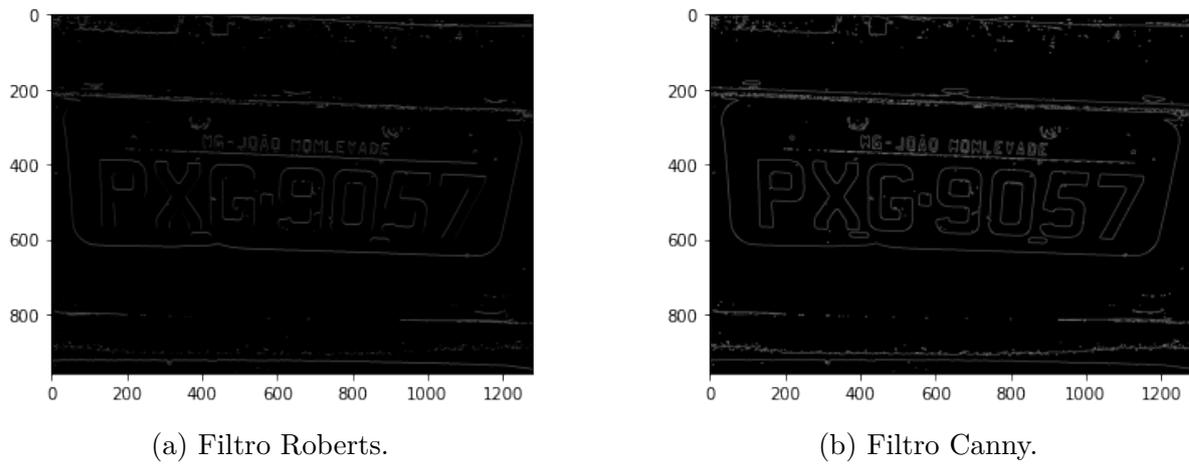


Figura 3.15 – Comparação dos filtros de detecção de borda na ‘Placa Exemplo’.

Desta forma, o protocolo experimental aprimorado considera 21 cenários, conforme mostra a Figura 3.16.

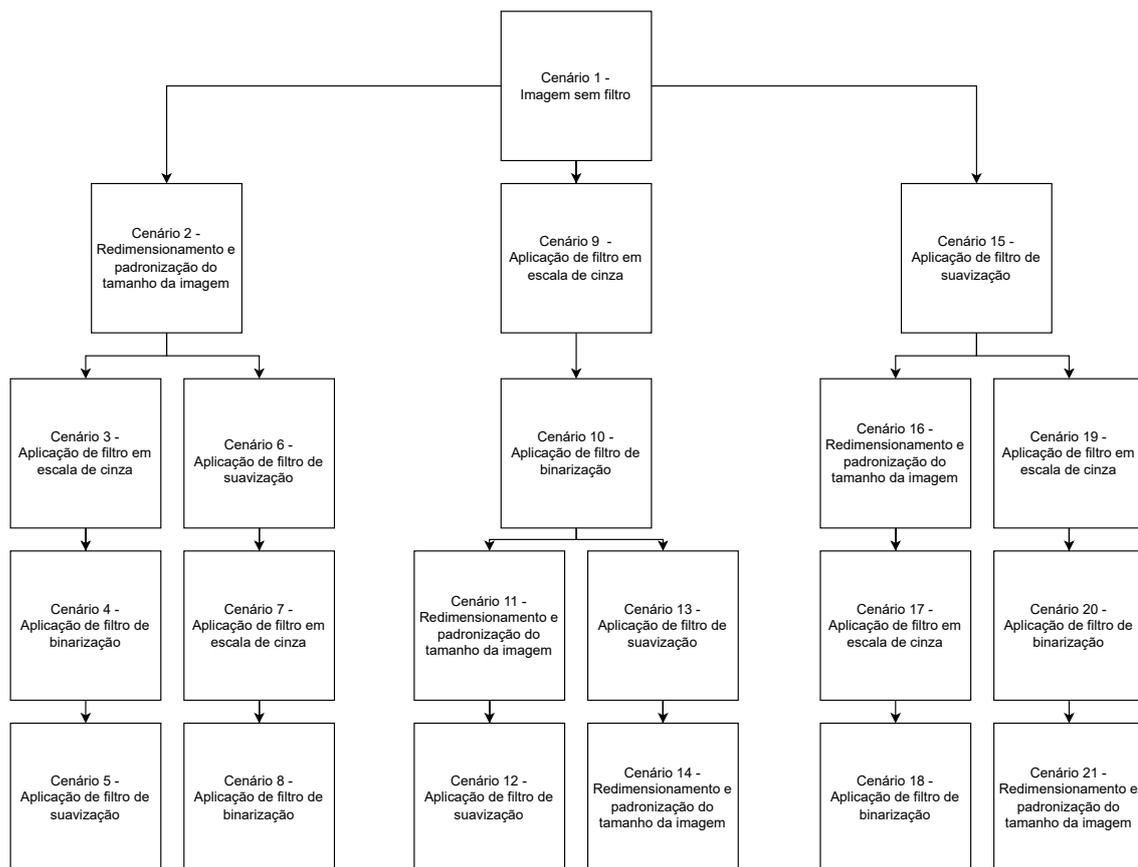


Figura 3.16 – Fluxograma de testes realizados do protocolo experimental aprimorado.

Nesta metodologia cada imagem da base de dados passa por todos os blocos de processamento de imagens, até que a sequência de caracteres desejada seja lida, ou até que não haja outra possibilidade. Apesar de algumas sequências de filtros e técnicas serem mais promissoras, são testados todos os procedimentos, pois em casos específicos, algumas sequencias de técnicas são as únicas que permitem o OCR.

### Descrição dos cenários do protocolo experimental aprimorado:

- **Cenário 1:** Imagem sem nenhum filtro.
- **Cenário 2:** Redimensionamento para padronização do tamanho da imagem.
- **Cenário 3:** Redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.
- **Cenário 4:** Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.
- **Cenário 5:** Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza, aplicação da binarização e então suavização da imagem.
- **Cenário 6:** Redimensionamento para padronização do tamanho da imagem e então suavização da imagem.
- **Cenário 7:** Redimensionamento para padronização do tamanho da imagem, suavização da imagem e então aplicação de filtro em escala de cinza.
- **Cenário 8:** Redimensionamento para padronização do tamanho da imagem, suavização da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.
- **Cenário 9:** Aplicação de filtro em escala de cinza.
- **Cenário 10:** Aplicação de filtro em escala de cinza e então aplicação da binarização.
- **Cenário 11:** Aplicação de filtro em escala de cinza, aplicação da binarização e então redimensionamento para padronização do tamanho da imagem.
- **Cenário 12:** Aplicação de filtro em escala de cinza, aplicação da binarização, redimensionamento para padronização do tamanho da imagem e então suavização da imagem.
- **Cenário 13:** Aplicação de filtro em escala de cinza, aplicação da binarização e então suavização da imagem.
- **Cenário 14:** Aplicação de filtro em escala de cinza, aplicação da binarização, suavização da imagem e então redimensionamento para padronização do tamanho da imagem.
- **Cenário 15:** Suavização da imagem.

- **Cenário 16:** Suavização da imagem e então redimensionamento para padronização do tamanho da imagem.
- **Cenário 17:** Suavização da imagem, redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.
- **Cenário 18:** Suavização da imagem, redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.
- **Cenário 19:** Suavização da imagem e então aplicação de filtro em escala de cinza.
- **Cenário 20:** Suavização da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.
- **Cenário 21:** Suavização da imagem, aplicação de filtro em escala de cinza, aplicação da binarização e então redimensionamento para padronização do tamanho da imagem.

Devido às mudanças nos cenários propostos, com remoção de alguns cenários e a adição de outros, a padronização do número de cada cenário foi alterada do protocolo experimental base para o protocolo experimental aprimorado.

---

## *Resultados*

---

Este Capítulo apresenta e discute os resultados obtidos utilizando diferentes técnicas para o reconhecimento de caracteres óticos.

### 4.1 Resultado da base de dados pública

A base de dados pública apresenta um total de 209 fotos de placas automotivas. Após a eliminação manual de fotos que apresentavam cobertura parcial ou total dos caracteres, a base de dados ficou com 201 imagens que foram testadas neste trabalho.

#### 4.1.1 Protocolo experimental base

A Tabela 4.1 apresenta os resultados alcançados com o protocolo experimental base. Os testes foram realizados em todos os 16 cenários (ver Figura 3.13) comparando o retorno apresentado pela função *image\_to\_string* da biblioteca *pytesseract*, com a leitura manual humana. O resultado foi considerado correto somente quando a função retornava uma sequência de caracteres idêntica a realizada pela leitura manual humana. Qualquer diferença entre a string retornada pela função e a string gerada pela leitura manual foi considerado como um erro de OCR.

É possível notar que o Cenário 1 (sem filtros) e o Cenário 3 (filtro de colorimetria em escala de cinza) retornam a leitura correta dos caracteres de 27 fotos, representando uma taxa de assertividade de 13,43%. O Cenário 10 (filtro de colorimetria seguido pelo filtro de suavização) ficou em terceiro lugar no ranking tendo operado a leitura correta de 25 placas, ou seja, cerca de 12,43% das amostras. Aplicando o filtro de suavização e então aplicação do filtro de colorimetria em escala de cinza (Cenário 14), tem-se uma leitura de 24 placas corretas, resultando em 11,44% de assertividade.

Três diferentes metodologias retornam uma taxa de 11,44% de acerto, sendo elas, o método de aplicação do filtro de suavização na imagem original(Cenário 4); a aplicação

Ranking	Cenário	Descrição	Número de placas lidas corretamente	% de taxa de assertividade
1	1	Imagem original sem filtros	27	13,43
1	3	Aplicando do filtro de colorimetria em escala de cinza	27	13,43
3	10	Aplicação do filtro de colorimetria e logo após, se realiza a aplicação do filtro de suavização	25	12,43
4	4	Aplicação do filtro de suavização na imagem original	23	11,44
4	13	Aplicação do filtro de suavização e então redimensionamento da imagem	23	11,44
4	14	Aplicação do filtro de suavização e então aplicação do filtro de colorimetria em escala de cinza	23	11,44
7	12	Aplicando filtro de colorimetria cinza, filtro de suavização e redimensionando a imagem	20	9,95
8	6	Redimensionando a imagem e então aplicando o filtro de suavização	19	9,45
9	9	Aplicação do filtro de colorimetria e então redimensionando a imagem	18	8,96
9	11	Aplicação do filtro de colorimetria, redimensionando a imagem e então aplicando o filtro de suavização	18	8,96
9	16	Aplicação do filtro de suavização, aplicando o filtro de colorimetria, e então redimensionando a imagem	18	8,96
12	8	Redimensionamento da imagem, seguido pela aplicação do filtro de suavização e então aplicação do filtro em escala de cinza	17	8,46
12	7	Redimensionamento da imagem, seguido pela aplicação do filtro em escala de cinza e então a aplicação do filtro de suavização	17	8,46
12	15	Aplicação do filtro de suavização, redimensionamento da imagem e então aplicação do filtro em escala de cinza	17	8,46
15	5	Redimensionar a imagem e aplicação do filtro de colorimetria	16	7,96
15	2	Apenas redimensionar a imagem original	16	7,96

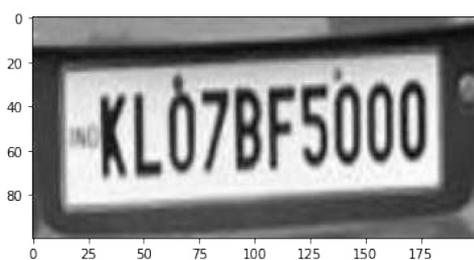
Tabela 4.1 – Tabela comparativa de cenários do protocolo experimental base considerando a base de dados pública.

do filtro de suavização e então redimensionamento da imagem (Cenário 13); e o Cenário 14 (Aplicação do filtro de suavização seguido pelo filtro de colorimetria). Nestes casos, os três cenários leram as mesmas placas corretamente.

Aplicando filtro de colorimetria, filtro de suavização e redimensionando a imagem (Cenário 12) obteve-se a 7<sup>a</sup> melhor metodologia testada, apresentando uma leitura correta de 20 placas, que corresponde a uma taxa de acerto de 9,95%.

Redimensionando a imagem e então aplicando o filtro de suavização (Cenário 6), a metodologia retorna uma taxa de assertividade de 9,45%, o que correspondendo a 19 placas lidas corretamente.

Três diferentes metodologias retornam uma taxa de 8,96% de acerto, sendo elas, o método de aplicação do filtro de colorimetria e então redimensionando a imagem (Cenário 9); o método de aplicação do filtro de colorimetria, redimensionando a imagem e então aplicando o filtro de suavização (Cenário 11); o método de aplicação do filtro de suavização, aplicando o filtro de colorimetria, e então redimensionando a imagem (Cenário 16); lendo corretamente 18 fotografias. Neste caso, os cenários 9, 11 e 16, leram corretamente placas diferentes, como apresentado pela Figura 4.1.



- (a) Aplicando filtro de colorimetria em escala de cinza e redimensionando a imagem.

Leitura: LO7BES000



- (b) Aplicando filtro de colorimetria em escala de cinza, redimensionando a imagem e aplicando filtro de suavização.

Leitura: LO7BES000



- (c) Aplicando filtro de suavização, filtro de cinza e então redimensionando a imagem.

Leitura: KL07BF5000

Figura 4.1 – Exemplo do retorno do algoritmo em 3 diferentes cenários que apresentam uma mesma taxa de assertividade.

Três diferentes metodologias retornam uma taxa de 8,46% de acerto, sendo elas, o método de redimensionamento da imagem, seguido pela aplicação do filtro de suavização e então aplicação do filtro em escala de cinza (Cenário 8); o método de redimensionamento da imagem, seguido pela aplicação do filtro em escala de cinza e então a aplicação do filtro de suavização (Cenário 7); o método de aplicação do filtro de suavização, redimensionamento da imagem e então aplicação do filtro em escala de cinza (Cenário 15), lendo corretamente 17 fotografias. Apesar de apresentarem um mesmo número de leituras corretas, as placas identificadas foram diferentes, como exemplifica a Figura 4.2.

Por fim, duas diferentes metodologias retornam uma taxa de 7,96% de acerto, sendo elas, o método de redimensionar a imagem e aplicação do filtro de colorimetria (Cenário 5); e o método de redimensionar a imagem (Cenário 2); lendo corretamente 16 fotografias de placas, sendo estes, o retorno com menor taxa de assertividade, para esta base de dados.

Apesar de ter a mesma taxa de assertividade nesta base de dados, as placas lidas corretamente nestas duas metodologias funcionam em diferentes casos, como apresentado pela Figura 4.3.

Como demonstrado pela Tabela 4.1, pode ser avaliado de forma detalhada e coesa, um comparativo entre todos os 16 testes realizados neste trabalho para a base de dados



- (a) Redimensionando a imagem, aplicando filtro de suavização e então aplicando filtro de colorimetria cinza.

Leitura: HH12JC2813



- (b) Redimensionando a imagem, aplicando filtro de colorimetria cinza e então aplicando filtro de suavização.

Leitura: MH12JC2813



- (c) Aplicando filtro de suavização, redimensionando a imagem e então aplicando filtro de colorimetria cinza.

Leitura: AH12JC2813

Figura 4.2 – Exemplo do retorno do algoritmo em 3 diferentes cenários que apresentam uma mesma taxa de assertividade.



- (a) Redimensionando a imagem e então aplicando filtro de colorimetria cinza.

Leitura: HR26D



- (b) Apenas redimensionando a imagem.

Leitura: HR26DA0471

Figura 4.3 – Apresentação de teste em uma placa específica, com três metodologias diferentes com mesma taxa de assertividade.

abordada.

Após analisar todas as placas veiculares da base de dados considerando os 16 cenários, observou-se que 2 placas são lidas corretamente em quaisquer dos 16 casos, sendo as fotografias apresentadas pela Figura 4.4.

Pode se observar que ambas as placas tem boa qualidade de imagem, caracteres



Figura 4.4 – Imagens lidas corretamente nos 16 cenários.

pretos em fundo branco e mesma tipografia, com espaçamento bem definido, sendo assim, o modelo ideal de fotografia para garantir a melhor eficiência do sistema. Outras placas veiculares que também observam estas características, foram lidas corretamente em menos cenários. A Figura 4.5 apresenta um exemplo de placa que é identificada corretamente apenas quando se usa a metodologia dos Cenários 4, 13 e 14.



Figura 4.5 – Imagem considerada ‘ideal’, mas não lida corretamente em todos os 16 cenários.

De fato, as leituras incorretas são geralmente próximas ao valor correto, errando apenas 1 carácter, como no caso da Figura 4.5, onde os cenários que retornam leituras incorretas confundem o carácter ‘D’ com o carácter ‘0’, por exemplo. Este tipo de erro poderia ser resolvido facilmente se houvesse um padrão de posicionamento das letras e números na placa. De modo que, caso haja a leitura de número na posição de uma letra, como ocorre ao retornar ‘0’ quando se deveria retornar ‘D’, o sistema identificaria o erro de caracteres similares e corrigiria o problema.

Outro problema ocorre no reconhecimento de placas de tipografias distintas. Por exemplo, a Figura 4.6 apresenta duas placas com a mesma sequência alfanumérica porém, com tipografias diferentes. A primeira imagem foi lida corretamente em 7 dos 16 cenários testados, enquanto que a segunda não foi lida corretamente em nenhum dos cenários.



(a) Placa lida corretamente em 7 dos 16 cenários.



(b) Placa não lida corretamente em nenhum dos 16 cenários.

Figura 4.6 – Placas com a mesma sequência alfanumérica, porém com diferentes taxas de retorno.

A angulação e a qualidade da fotografia da placa também impacta na dificuldade de leitura, como evidencia a Figura 4.7.



(a) Placa não lida corretamente em nenhum dos 16 cenários.



(c) Placa lida corretamente em 10 cenários.



(b) Placa lida corretamente em 2 cenários.



(d) Placa lida corretamente somente em 1 cenário.

Figura 4.7 – Placas de mesma identificação, porém com diferentes taxas de retorno.

Neste trabalho, desenvolveu-se um único código que unificava os testes dos 16 cenários utilizando uma programação sequencial. Cada metodologia foi testada individualmente, da mais assertiva à menos, apenas nos casos nos quais a metodologia testada não retornava o valor esperado, a imagem seguia para os testes com os cenários seguintes, conforme exemplifica a Figura 4.8.

Seguindo esta metodologia, onde caso a leitura correta ocorra, o programa já finaliza, não há a possibilidade de se perder a leitura correta, aplicando algum conjunto de filtros incompatíveis com uma determinada fotografia.

Esta metodologia resultou em 25,86% de retorno, sendo a melhor taxa de assertividade, lendo corretamente um total de 52 fotografias da base de dados pública. Isto representa um resultado 92,51% melhor que o caso da leitura da imagem sem aplicação de filtros. Entretanto, mesmo neste protocolo, cerca de 149 fotografias não puderam ser lidas corretamente. Nessas situações, a resposta retornada pelo sistema corresponde a leitura realizada pelo Cenário 1, que tem a melhor taxa de acerto.

#### 4.1.2 Protocolo experimental aprimorado

Aplicando o protocolo experimental aprimorado, alcança-se os resultados demonstrados na Tabela 4.2.

Nos cenários que são iguais entre o protocolo experimental base e o protocolo experimental, os resultados se mantiveram. Neste protocolo os dois melhores cenários são o Cenário 1 (sem filtragem) e o Cenário 9 (filtro de colorimetria em escala de cinza).

Ranking	Cenário	Descrição	Número de placas lidas corretamente	% de taxa de assertividade
1	1	Imagem original sem filtros.	27	13,43
1	9	Aplicação de filtro em escala de cinza.	27	13,43
3	19	Suavização da imagem e então aplicação de filtro em escala de cinza.	24	11,94
4	15	Suavização da imagem.	23	11,44
5	10	Aplicação de filtro em escala de cinza e então aplicação da binarização.	22	10,95
6	6	Redimensionamento para padronização do tamanho da imagem e então suavização da imagem.	19	9,45
7	7	Redimensionamento para padronização do tamanho da imagem, suavização da imagem e então aplicação de filtro em escala de cinza.	17	8,46
7	13	Aplicação de filtro em escala de cinza, aplicação da binarização e então suavização da imagem.	17	8,46
7	17	Suavização da imagem, redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.	17	8,46
10	2	Redimensionamento para padronização do tamanho da imagem.	16	7,96
10	3	Redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.	16	7,96
10	20	Suavização da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	16	7,96
13	16	Suavização da imagem e então redimensionamento para padronização do tamanho da imagem.	15	7,46
14	12	Aplicação de filtro em escala de cinza, aplicação da binarização, redimensionamento para padronização do tamanho da imagem e então suavização da imagem.	14	6,97
15	5	Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza, aplicação da binarização e então suavização da imagem.	12	5,97
15	8	Redimensionamento para padronização do tamanho da imagem, suavização da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	12	5,97
15	21	Suavização da imagem, aplicação de filtro em escala de cinza, aplicação da binarização e então redimensionamento para padronização do tamanho da imagem.	12	5,97
18	11	Aplicação de filtro em escala de cinza, aplicação da binarização e então redimensionamento para padronização do tamanho da imagem.	11	5,47
18	14	Aplicação de filtro em escala de cinza, aplicação da binarização, suavização da imagem e então redimensionamento para padronização do tamanho da imagem.	11	5,47
20	4	Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	10	4,98
21	18	Suavização da imagem, redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	8	3,98

Tabela 4.2 – Tabela comparativa de cenários do protocolo experimental aprimorado da base de dados pública.

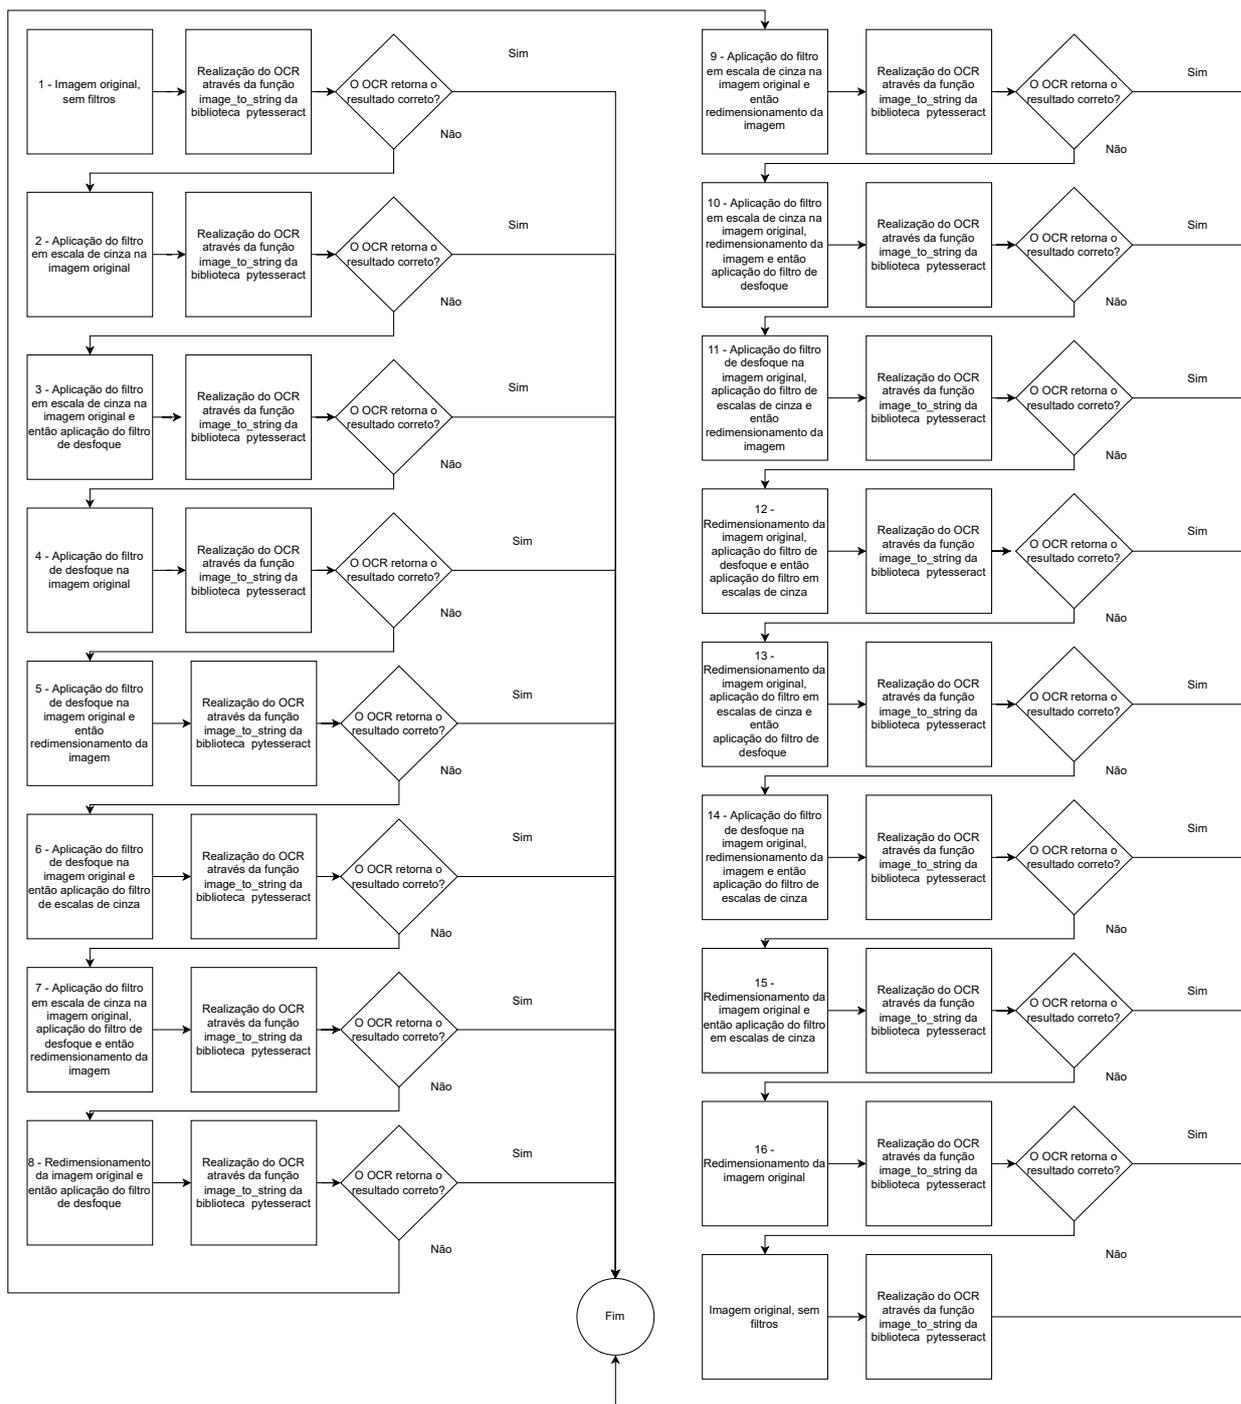


Figura 4.8 – Fluxograma de testes realizados considerando os 16 cenários.

Observe que o protocolo experimental aprimorado conta com a técnica de binarização que foi incluída somente após o filtro de colorimetria, assim, não há um paralelo entre a numeração dos cenários do protocolo base e do protocolo aprimorado.

No protocolo experimental aprimorado o terceiro melhor cenário é a aplicação do filtro de suavização, seguido do filtro de colorimetria em escala de cinza (Cenário 19) que acerta o OCR em 11,94% das fotografias, ou seja, 24 placas.

A seguir, estão o Cenário 15, Cenário 10 e o Cenário 6, que respectivamente apre-

sentam uma taxa de acerto de 11,44%, 10,95% e 9,45%.

Três diferentes cenários apresentam uma taxa de assertividade de 8,46%, representando a 7<sup>a</sup> metodologia com maior taxa de assertividade, sendo elas, o redimensionamento da imagem, seguido pela aplicação de suavização e então aplicação do filtro de colorimetria em escala de cinza (Cenário 7); aplicação de filtro de colorimetria em escala de cinza, seguido de binarização da imagem e então aplicação do filtro de suavização (Cenário 13); aplicação do filtro de suavização e então aplicação do filtro de colorimetria em escala de cinza (Cenário 17).

Outras três distintas metodologias (Cenários 2, 3 e 20) empataram ocupando o décimo lugar com taxa de acerto de 7,96%, ou seja, realizando a leitura correta de 16 placa automotivas.

Em sequência, apresenta-se o Cenário 16 e o Cenário 12, que respectivamente representam, a aplicação de filtro de suavização, seguido do redimensionamento da imagem, com uma taxa de assertividade de 7,46% e a aplicação de filtro de colorimetria em escala de cinza, binarização da imagem, redimensionamento, e então aplicação do filtro de suavização, resultando um retorno de 6,97% das fotografias lidas corretamente.

Três diferentes metodologias apresentam uma taxa de assertividade de 5,97%, representando a 15<sup>a</sup> metodologia com maior taxa de assertividade, sendo elas, o redimensionamento da imagem, seguido pela aplicação do filtro de colorimetria em escala de cinza, binarização da imagem e então aplicação do filtro de suavização (Cenário 5); redimensionando a imagem, seguido da aplicação de filtro de suavização, aplicação de filtro de colorimetria em escala de cinza e então a binarização da imagem (Cenário 8); aplicação do filtro de suavização e então aplicação do filtro de colorimetria em escala de cinza, a binarização da imagem e então o redimensionamento da imagem (Cenário 21).

Os Cenários 11 e 14 ocuparam a posição 18 no ranking, tendo lido corretamente 11 placas automotivas (5,47%).

Por fim, apresenta-se o Cenário 4 e o Cenário 18, que respectivamente representam, o redimensionamento da imagem, seguido pela aplicação do filtro de colorimetria em escala de cinza e então binarização da imagem, com uma taxa de assertividade de 4,98% e a aplicação do filtro de suavização, seguido redimensionamento da imagem, a aplicação do filtro de colorimetria em escala de cinza e então a binarização da imagem, resultando um retorno de 3,98% das fotografias lidas corretamente.

Como ocorreu durante o protocolo experimental base, para o protocolo experimental aprimorado também desenvolveu-se um único código que unificava os testes dos 21 cenários, utilizando uma programação sequencial. Cada metodologia foi testada individualmente, da mais assertiva à menos, apenas nos casos nos quais a metodologia testada não retornava o valor esperado, a imagem seguia para os testes com os cenários seguintes, de maneira semelhante a exemplificada pela Figura 4.8 do protocolo experimental base, porém, desta vez incluindo também os demais cenários incluídos no procedimento

experimental aprimorado. Seguindo esta metodologia, onde caso a leitura correta ocorra, o programa já finaliza, não há a possibilidade de se perder a leitura correta, aplicando algum conjunto de filtros incompatíveis com uma determinada fotografia.

Esta metodologia resultou em uma taxa de acerto de 28,86%, lendo corretamente um total de 58 fotografias da base de dados utilizada. Isto representa um resultado 114,81% melhor que o caso em que não há aplicação de filtros. Entretanto, cerca de 143 fotografias não puderam ser lidas corretamente. Nestes casos, o sistema retorna a leitura incorreta dada pelo Cenário 1.

## 4.2 Resultados da base de dados própria

A base de dados coletada durante este estudo apresenta um total de 124 fotos de placas veiculares, sendo 105 de automóveis e 19 de motos. Neste trabalho, foram avaliadas somente as placas de veículos, destas 66 placas estão no padrão brasileiro e 39 no padrão Mercosul.

Todas as amostras da base passaram pelos testes dos cenários especificados pelos dois protocolos experimental, conforme mostram as Figuras 3.13 e 3.16.

### 4.2.1 Protocolo experimental base

Aplicando o protocolo experimental base, foram obtidos os resultados apresentados na Tabela 4.3.

A metodologia combinada resultou em uma taxa de acerto de 24,76% , lendo corretamente um total de 26 fotografias da base de dados utilizada. Isto representa um resultado 188,91% melhor que o melhor caso obtido anteriormente com a aplicação do filtro de suavização. Como ocorre na base de dados pública, algumas letras e números são confundidos no processo de realização do OCR na base própria. Estes erros estão catalogados na Tabela 4.4.

Como se trata de uma base padronizada, onde as letras e números tem posições fixas pré-determinadas, foi desenvolvido um código corretor que analisa a posição do caractere e verifica se deve ser uma letra ou um número. Para tal, a base de dados é dividida entre as placas de padrão brasileiro e as placas de padrão Mercosul, uma vez que a disposição de letras e números é distinta em cada modelo. Realizando tais separações da base de dados, alcança-se os resultados demonstrados a pelas Tabelas 4.5 e 4.6, referente às placas do modelo Mercosul e do modelo brasileiro, respectivamente, após a aplicação do código corretor que segue as associações apresentadas pela Tabela 4.4.

Aplicando esta metodologia para os veículos com placas no padrão Mercosul da base de dados própria, obteve-se uma taxa de acerto de 25,64%, que representa a leitura correta de 10 fotografias dentre as 39 da base de dados. Esta metodologia combinada teve

Ranking	Cenário	Descrição	Número de placas lidas corretamente	% de taxa de assertividade
1	4	Aplicação do filtro de suavização na imagem original	9	8,57
1	13	Aplicação do filtro de suavização e então redimensionamento da imagem	9	8,57
3	10	Aplicação do filtro de colorimetria e logo após, se realiza a aplicação do filtro de suavização	8	7,62
4	3	Aplicando o filtro de colorimetria em escala de cinza	7	6,67
4	8	Redimensionamento da imagem, seguido pela aplicação do filtro de suavização e então aplicação do filtro em escala de cinza	7	6,67
6	1	Imagem original sem filtros	6	5,71
6	14	Aplicação do filtro de suavização e então aplicação do filtro de colorimetria em escala de cinza	6	5,71
6	7	Redimensionamento da imagem, seguido pela aplicação do filtro em escala de cinza e então a aplicação do filtro de suavização	6	5,71
9	6	Redimensionando a imagem e então aplicando o filtro de suavização	5	4,76
10	9	Aplicação do filtro de colorimetria e então redimensionando a imagem	4	3,81
10	11	Aplicação do filtro de colorimetria, redimensionando a imagem e então aplicando o filtro de suavização	4	3,81
10	5	Redimensionar a imagem e aplicação do filtro de colorimetria	4	3,81
13	12	Aplicando filtro de colorimetria cinza, filtro de suavização e redimensionando a imagem	3	2,86
13	16	Aplicação do filtro de suavização, aplicando o filtro de colorimetria, e então redimensionando a imagem	3	2,86
13	15	Aplicação do filtro de suavização, redimensionamento da imagem e então aplicação do filtro em escala de cinza	3	2,86
13	2	Apenas redimensionar a imagem original	3	2,86

Tabela 4.3 – Tabela comparativa de cenários do protocolo experimental base aplicada aos veículos da base própria.

Leitura incorreta de caracteres	
Leitura Correta (Letra)	Leitura Errada Realizada (Número)
C	0
D	0
G	6
T	7
Leitura Correta (Número)	Leitura Errada Realizada (Letra)
0	O
0	G
1	T
2	Z
2	D
4	H
5	S
8	B

Tabela 4.4 – Análise da leitura incorreta de caracteres semelhantes, considerando letras e números.

Ranking	Cenário	Descrição	Número de placas lidas corretamente	% de taxa de assertividade
1	8	Redimensionamento da imagem, seguido pela aplicação do filtro de suavização e então aplicação do filtro em escala de cinza	4	10,26
2	7	Redimensionamento da imagem, seguido pela aplicação do filtro em escala de cinza e então a aplicação do filtro de suavização	3	7,69
2	15	Aplicação do filtro de suavização, redimensionamento da imagem e então aplicação do filtro em escala de cinza	3	7,69
4	4	Aplicação do filtro de suavização na imagem original	2	5,13
4	13	Aplicação do filtro de suavização e então redimensionamento da imagem	2	5,13
4	12	Aplicando filtro de colorimetria cinza, filtro de suavização e redimensionando a imagem	2	5,13
4	16	Aplicação do filtro de suavização, aplicando o filtro de colorimetria, e então redimensionando a imagem	2	5,13
4	2	Apenas redimensionar a imagem original	2	5,13
9	3	Aplicando do filtro de colorimetria em escala de cinza	1	2,56
9	6	Redimensionando a imagem e então aplicando o filtro de suavização	1	2,56
9	9	Aplicação do filtro de colorimetria e então redimensionando a imagem	1	2,56
9	11	Aplicação do filtro de colorimetria, redimensionando a imagem e então aplicando o filtro de suavização	1	2,56
9	5	Redimensionar a imagem e aplicação do filtro de colorimetria	1	2,56
14	1	Imagem original sem filtros	0	0
14	10	Aplicação do filtro de colorimetria e logo após, se realiza a aplicação do filtro de suavização	0	0
14	14	Aplicação do filtro de suavização e então aplicação do filtro de colorimetria em escala de cinza	0	0

Tabela 4.5 – Tabela comparativa de cenários do protocolo experimental base aplicada aos veículos com placas de modelo Mercosul da base própria, corrigida.

um resultado 149,90% melhor que o melhor caso anterior, obtido com a leitura da imagem após redimensionamento da imagem, seguido pela aplicação do filtro de suavização e então aplicação do filtro em escala de cinza.

Já para os dados referentes às placas de modelo brasileiro para os veículos da base de dados própria, esta metodologia resultou em uma taxa de acerto de 30,30%, lendo corretamente um total de 20 fotografias das 66 da base de dados utilizada. Esta metodologia combinada teve um resultado 150,00% melhor que o antigo melhor caso, obtido com a leitura da imagem ao aplicar o filtro de colorimetria e logo após, se realizar a aplicação do filtro de suavização.

Entretanto, as leituras entre caracteres incorretos de mesma classe, letra por letra, ou número por número, como demonstrado pela Tabela 4.7, não podem ser corrigidos, uma vez que os caracteres estão em posições válidas, sendo impossível saber *à priori* se a leitura está realmente correta ou se há de fato um erro neste ponto.

Ranking	Cenário	Descrição	Número de placas lidas corretamente	% de taxa de assertividade
1	10	Aplicação do filtro de colorimetria e logo após, se realiza a aplicação do filtro de suavização	8	12,12
2	4	Aplicação do filtro de suavização na imagem original	7	10,61
2	13	Aplicação do filtro de suavização e então redimensionamento da imagem	7	10,61
4	1	Imagem original sem filtros	6	9,09
4	3	Aplicando do filtro de colorimetria em escala de cinza	6	9,09
4	14	Aplicação do filtro de suavização e então aplicação do filtro de colorimetria em escala de cinza	6	9,09
7	8	Redimensionamento da imagem, seguido pela aplicação do filtro de suavização e então aplicação do filtro em escala de cinza	5	7,58
7	7	Redimensionamento da imagem, seguido pela aplicação do filtro em escala de cinza e então a aplicação do filtro de suavização	5	7,58
9	6	Redimensionando a imagem e então aplicando o filtro de suavização	4	6,06
10	9	Aplicação do filtro de colorimetria e então redimensionando a imagem	3	4,55
10	11	Aplicação do filtro de colorimetria, redimensionando a imagem e então aplicando o filtro de suavização	3	4,55
10	5	Redimensionar a imagem e aplicação do filtro de colorimetria	3	4,55
13	12	Aplicando filtro de colorimetria cinza, filtro de suavização e redimensionando a imagem	2	3,03
13	16	Aplicação do filtro de suavização, aplicando o filtro de colorimetria, e então redimensionando a imagem	2	3,03
13	15	Aplicação do filtro de suavização, redimensionamento da imagem e então aplicação do filtro em escala de cinza	2	3,03
13	2	Apenas redimensionar a imagem original	2	3,03

Tabela 4.6 – Tabela comparativa de cenários do protocolo experimental base aplicada aos veículos com placas de modelo brasileiro da base própria, com código corretor de erro.

<b>Leitura incorreta de caracteres</b>	
<b>Leitura Correta (Letra)</b>	<b>Leitura Errada Realizada (Letra)</b>
G	C
G	O
J	I
J	S
M	N
M	H
M	W
N	H
N	W
O	G
Q	O
R	A
V	W
V	Y
<b>Leitura Correta (Número)</b>	<b>Leitura Errada Realizada (Número)</b>
1	4
1	5
2	9
3	9
6	5

Tabela 4.7 – Caracteres que são lidos de modo incorreto, mas que não podem ser corrigidos considerando somente o padrão de posicionamento de letras e números.

### 4.2.2 Protocolo experimental aprimorado

Aplicando o protocolo experimental aprimorado obtém-se os resultados apresentados pela Tabela 4.8.

Ranking	Cenário	Descrição	Número de placas lidas corretamente	% de taxa de assertividade
1	15	Suavização da imagem.	9	8,57
2	5	Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza, aplicação da binarização e então suavização da imagem.	8	7,62
2	8	Redimensionamento para padronização do tamanho da imagem, suavização da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	8	7,62
4	7	Redimensionamento para padronização do tamanho da imagem, suavização da imagem e então aplicação de filtro em escala de cinza.	7	6,67
4	9	Aplicação de filtro em escala de cinza.	7	6,67
4	10	Aplicação de filtro em escala de cinza e então aplicação da binarização.	7	6,67
7	1	Imagem original sem filtros.	6	5,71
7	12	Aplicação de filtro em escala de cinza, aplicação da binarização, redimensionamento para padronização do tamanho da imagem e então suavização da imagem.	6	5,71
7	19	Suavização da imagem e então aplicação de filtro em escala de cinza.	6	5,71
10	6	Redimensionamento para padronização do tamanho da imagem e então suavização da imagem.	5	4,76
11	3	Redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.	4	3,81
11	13	Aplicação de filtro em escala de cinza, aplicação da binarização e então suavização da imagem.	4	3,81
11	20	Suavização da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	4	3,81
14	2	Redimensionamento para padronização do tamanho da imagem.	3	2,86
14	16	Suavização da imagem e então redimensionamento para padronização do tamanho da imagem.	3	2,86
14	17	Suavização da imagem, redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.	3	2,86
14	18	Suavização da imagem, redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	3	2,86
18	11	Aplicação de filtro em escala de cinza, aplicação da binarização e então redimensionamento para padronização do tamanho da imagem.	2	1,90
19	14	Aplicação de filtro em escala de cinza, aplicação da binarização, suavização da imagem e então redimensionamento para padronização do tamanho da imagem.	1	0,95
19	21	Suavização da imagem, aplicação de filtro em escala de cinza, aplicação da binarização e então redimensionamento para padronização do tamanho da imagem.	1	0,95
21	4	Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	0	0,00

Tabela 4.8 – Tabela comparativa de cenários do protocolo experimental aprimorado aplicada aos veículos da base própria.

Este procedimento resultou em uma taxa de acerto de 33,33%, lendo corretamente um total de 35 fotografias da base de dados utilizada. Isto representa um resultado

288,91% melhor que o antigo melhor caso, que consistia na leitura da imagem ao se aplicar o filtro de suavização.

Como ocorre no protocolo experimental base, algumas letras e números são confundidos no processo de realização do OCR na base própria. Estes erros são demonstrados pela Tabela 4.4. De mesmo modo ao protocolo experimental base, como se trata de uma base padronizada, onde as letras e números tem posições fixas pré-determinadas, há a possibilidade de construir um código corretor para o protocolo experimental aprimorado, onde se corrige a leitura nestes pontos específicos, de forma que, quando a leitura é realizada de maneira errada, na posição específica, como representado pela segunda coluna, é imediatamente corrigida pela informação da primeira coluna. Para tal, a base de dados foi dividida entre as placas do padrão brasileiro e do padrão Mercosul, uma vez que a disposição das letras e números é distinta em cada modelo. Desta forma, obteve-se os resultados apresentados nas Tabelass 4.9 e 4.10.

Seguindo a metodologia, onde caso a leitura correta ocorra, o programa já finaliza, não há a possibilidade de se perder a leitura correta, aplicando algum conjunto de filtros incompatíveis com uma determinada fotografia. Aplicando esta metodologia para os veículos com placas no padrão Mercosul da base de dados própria, obtém-se uma taxa de acerto de 30,77%, que corresponde a leitura correta de 12 fotografias da base de dados. Esta metodologia combinada, teve um resultado 359,04% melhor que o antigo melhor caso, a leitura da imagem após redimensionamento da imagem, seguido pela aplicação do filtro de suavização e então aplicação do filtro em escala de cinza.

Já para os dados referentes às placas de modelo brasileiro para os veículos da base de dados própria, esta metodologia resultou em 39,39% de retorno, sendo a melhor taxa de assertividade, lendo corretamente um total de 26 fotografias da base de dados utilizada. Esta metodologia combinada, teve um resultado 225,00% melhor que o antigo melhor caso, a leitura da imagem após redimensionar o tamanho da imagem, aplicar o filtro de colorimetria em escala de cinza e em sequência, binarizar a imagem.

Entretanto, como demonstrado anteriormente pela tabela 4.7, as leituras entre caracteres incorretos de mesma classe, letra por letra, ou número por número, não podem ser corrigidos, uma vez que os caracteres são de mesma posição, é impossível saber *à priori*, se a leitura está realmente correta ou se há de fato um erro neste ponto.

Ranking	Cenário	Descrição	Número de placas lidas corretamente	% de taxa de assertividade
1	7	Redimensionamento para padronização do tamanho da imagem, suavização da imagem e então aplicação de filtro em escala de cinza.	4	8,57
2	17	Suavização da imagem, redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.	3	8,57
3	2	Redimensionamento para padronização do tamanho da imagem.	2	7,62
3	5	Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza, aplicação da binarização e então suavização da imagem.	2	6,67
3	11	Aplicação de filtro em escala de cinza, aplicação da binarização e então redimensionamento para padronização do tamanho da imagem.	2	6,67
3	15	Suavização da imagem.	2	5,71
7	3	Redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.	1	5,71
7	6	Redimensionamento para padronização do tamanho da imagem e então suavização da imagem.	1	5,71
7	8	Redimensionamento para padronização do tamanho da imagem, suavização da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	1	4,76
7	9	Aplicação de filtro em escala de cinza.	1	3,81
7	10	Aplicação de filtro em escala de cinza e então aplicação da binarização.	1	3,81
7	12	Aplicação de filtro em escala de cinza, aplicação da binarização, redimensionamento para padronização do tamanho da imagem e então suavização da imagem.	1	3,81
7	14	Aplicação de filtro em escala de cinza, aplicação da binarização, suavização da imagem e então redimensionamento para padronização do tamanho da imagem.	1	2,86
7	16	Suavização da imagem e então redimensionamento para padronização do tamanho da imagem.	1	2,86
7	21	Suavização da imagem, aplicação de filtro em escala de cinza, aplicação da binarização e então redimensionamento para padronização do tamanho da imagem.	1	2,86
16	1	Imagem original sem filtros.	0	0
16	4	Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	0	0
16	13	Aplicação de filtro em escala de cinza, aplicação da binarização e então suavização da imagem.	0	0
16	18	Suavização da imagem, redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	0	0
16	19	Suavização da imagem e então aplicação de filtro em escala de cinza.	0	0
16	20	Suavização da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	0	0

Tabela 4.9 – Tabela comparativa de cenários do protocolo experimental aprimorado aplicada aos veículos com placas no padrão Mercosul da base própria, corrigida.

Ranking	Cenário	Descrição	Número de placas lidas corretamente	% de taxa de assertividade
1	8	Redimensionamento para padronização do tamanho da imagem, suavização da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	8	12,12
2	5	Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza, aplicação da binarização e então suavização da imagem.	7	10,61
2	15	Suavização da imagem.	7	10,61
4	1	Imagem original sem filtros.	6	9,09
4	9	Aplicação de filtro em escala de cinza.	6	9,09
4	10	Aplicação de filtro em escala de cinza e então aplicação da binarização.	6	9,09
4	12	Aplicação de filtro em escala de cinza, aplicação da binarização, redimensionamento para padronização do tamanho da imagem e então suavização da imagem.	6	9,09
4	19	Suavização da imagem e então aplicação de filtro em escala de cinza.	6	9,09
9	7	Redimensionamento para padronização do tamanho da imagem, suavização da imagem e então aplicação de filtro em escala de cinza.	5	7,58
10	6	Redimensionamento para padronização do tamanho da imagem e então suavização da imagem.	4	6,06
10	13	Aplicação de filtro em escala de cinza, aplicação da binarização e então suavização da imagem.	4	6,06
10	20	Suavização da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	4	6,06
13	3	Redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.	3	4,55
13	18	Suavização da imagem, redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	3	4,55
15	2	Redimensionamento para padronização do tamanho da imagem.	2	3,03
15	16	Suavização da imagem e então redimensionamento para padronização do tamanho da imagem.	2	3,03
15	17	Suavização da imagem, redimensionamento para padronização do tamanho da imagem e então aplicação de filtro em escala de cinza.	2	3,03
18	11	Aplicação de filtro em escala de cinza, aplicação da binarização e então redimensionamento para padronização do tamanho da imagem.	1	1,52
19	4	Redimensionamento para padronização do tamanho da imagem, aplicação de filtro em escala de cinza e então aplicação da binarização.	0	0,00
19	14	Aplicação de filtro em escala de cinza, aplicação da binarização, suavização da imagem e então redimensionamento para padronização do tamanho da imagem.	0	0,00
19	21	Suavização da imagem, aplicação de filtro em escala de cinza, aplicação da binarização e então redimensionamento para padronização do tamanho da imagem.	0	0,00

Tabela 4.10 – Tabela comparativa de cenários do protocolo experimental aprimorado aplicada aos veículos com placas de modelo brasileiro da base própria, corrigida.

### 4.3 Comparação dos resultados do protocolo experimental base vs. protocolo experimental aprimorado

Comparando de forma visual a taxa de assertividade dos cenários propostos pelos protocolos experimentais, torna-se claro que cada base de dados, ou melhor, cada fotografia apresenta características próprias que demanda um tratamento personalizado. A Figura 4.9 apresenta o número de placas da base de dados pública lidas corretamente utilizando cada um dos cenários de ambos os protocolos experimentais. Apesar de não haver um paralelo entre a numeração dos cenários nos dois protocolos experimentais, observa-se que a distribuição da taxa de acerto varia mais no protocolo experimental aprimorado.

Comparando os resultados do protocolo experimental base e o protocolo experimental aprimorado considerando cada cenário individualmente e a metodologia sequencial de aplicação dos cenários, em ambas as bases de dados, são nítidas as melhorias apresentadas quando se aplica o processo sequencial, como demonstrado pelas Tabelas 4.11 e 4.12.

	Protocolo Experimental Base (Média)	Protocolo Experimental Base (Sequencial)	Protocolo Experimental Aprimorado (Média)	Protocolo Experimental Aprimorado (Sequencial)
Placas de modelos Variados (Base de dados pública)	10,11%	25,86%	8,20%	28,86%

Tabela 4.11 – Tabela comparativa de cenários do protocolo experimental base e do protocolo experimental aprimorado aplicada as placas da base de dados pública.

	Protocolo Experimental Base (Média)	Protocolo Experimental Base (Sequencial)	Protocolo Experimental Aprimorado (Média)	Protocolo Experimental Aprimorado (Sequencial)
Placas de ambos os padrões	5,18%	24,76%	4,40%	33,33%
Placas no padrão Mercosul (com código corretor de erros)	4,01%	25,64%	3,81%	30,77%
Placas no padrão brasileiro (com código corretor de erros)	6,73%	30,30%	5,92%	39,39%
Média Total	5,31%	26,90%	4,71%	34,50%

Tabela 4.12 – Tabela comparativa de cenários do protocolo experimental base e do protocolo experimental aprimorado aplicada as placas da base de dados própria.

De fato, o protocolo experimental aprimorado, que combina as técnicas em 21 cenários distintos, não apresentou melhorias significativas com relação ao protocolo experimental base, considerando individualmente o desempenho de cada cenário. Entretanto, considerando a análise das placas de modo sequencial entre os cenários, o desempenho é superior para os dois protocolos experimentais testados, sendo o ganho de desempenho maior no protocolo experimental aprimorado.

Outro ponto de análise, é que as placas do padrão brasileiro da base de dados própria tiveram um melhor retorno quando comparadas às placas do padrão Mercosul, sendo mais adaptáveis aos protocolos experimentais implementados neste trabalho.

Analisando a Figura 4.10, é interessante destacar a diferença de desempenho obtida aplicando-se o Cenário 10 no OCR de placas no padrão brasileiro e no padrão Mercosul.

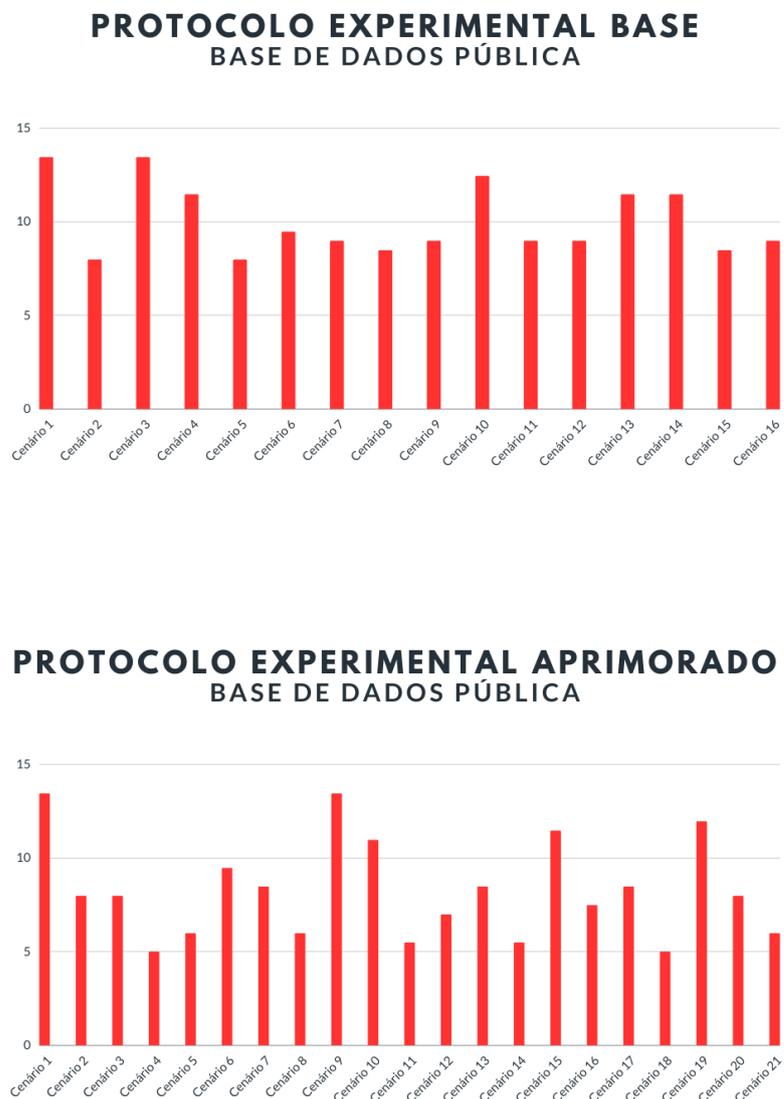
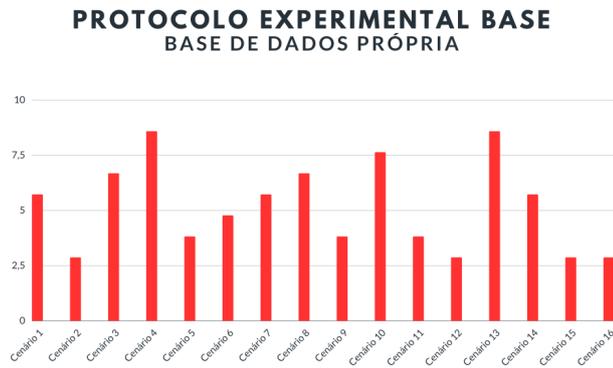


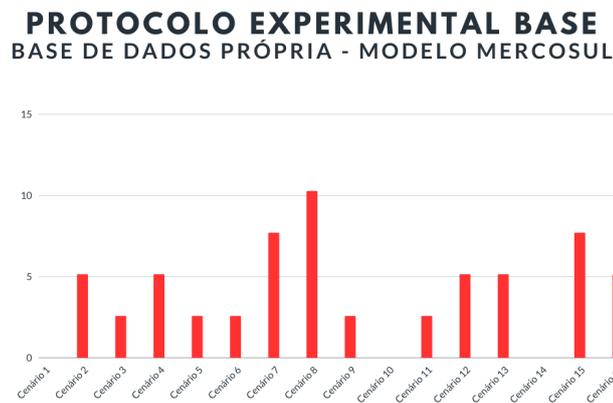
Figura 4.9 – Comparação de taxa de assertividade dos cenários propostos pelos protocolos experimentais aplicados à base de dados pública.

No padrão Mercosul, nenhuma placa foi corretamente identificada com ele, enquanto que para as placas no padrão antigo brasileiro, este foi o cenário com maior taxa de acerto.

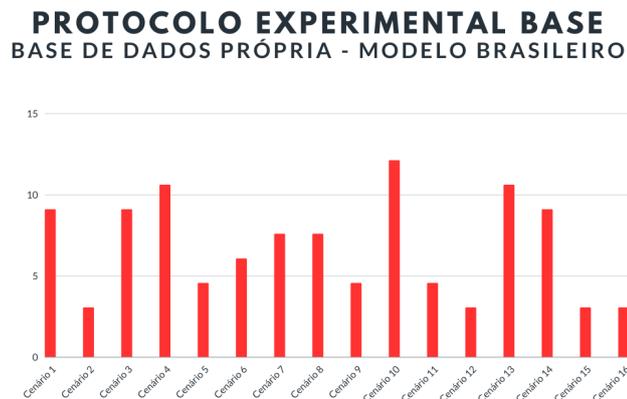
Esta análise também pode ser feita ao analisar graficamente as taxas de assertividade dos cenários propostos pelo protocolo experimental aprimorado, como evidenciado pela Figura 4.11.



(a) Base de dados própria - todas as placas.



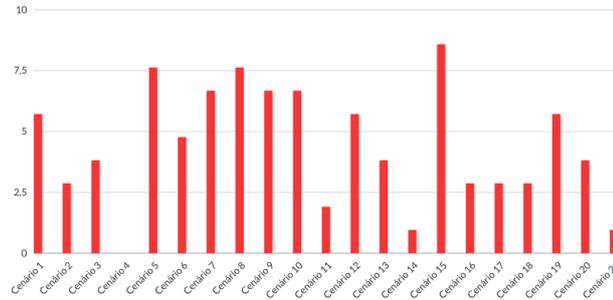
(b) Base de dados própria - Modelo Mercosul, com código corretor de erros.



(c) Base de dados própria - Modelo Brasileiro, com código corretor de erros.

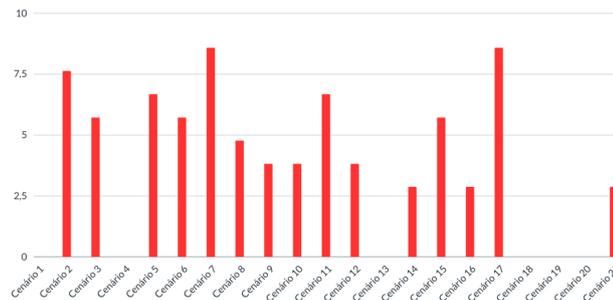
Figura 4.10 – Comparação de taxa de assertividade dos cenários propostos pelo protocolo experimental base aplicado à base de dados própria.

**PROTOCOLO EXPERIMENTAL APRIMORADO  
BASE DE DADOS PRÓPRIA**



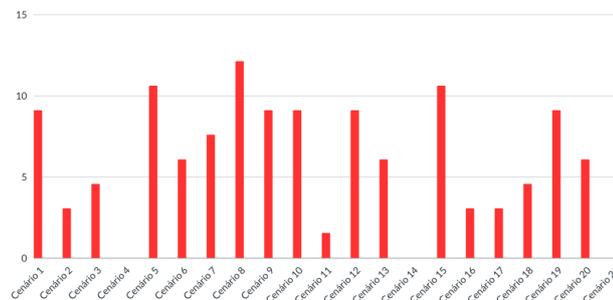
(a) Base de dados própria - todas as placas.

**PROTOCOLO EXPERIMENTAL APRIMORADO  
BASE DE DADOS PRÓPRIA - MERCOSUL**



(b) Base de dados própria - Modelo Mercosul, com código corretor de erros.

**PROTOCOLO EXPERIMENTAL APRIMORADO  
BASE DE DADOS PRÓPRIA - BRASILEIRO**



(c) Base de dados própria - Modelo Brasileiro, com código corretor de erros).

Figura 4.11 – Comparação de taxa de assertividade dos cenários propostos pelo protocolo experimental aprimorado aplicado à base de dados própria.

---

## *Conclusões e Propostas de Melhorias*

---

Este Capítulo apresenta as considerações finais avaliando o resultado encontrado e apresentando as propostas de melhorias do trabalho.

### 5.1 Considerações finais

Com base nos resultados obtidos nos testes dos protocolos experimentais, modelo base e modelo aprimorado, tanto em execução sequencial quanto paralela dos cenários propostos, não foi alcançado o resultado esperado de uma taxa de assertividade comparável aos sistemas comerciais de identificação de caracteres óticos de placas automotivas já disponíveis no mercado. Essa taxa de assertividade insatisfatória torna insuficiente o uso desses modelos para o desenvolvimento de aplicações robustas e confiáveis. Entretanto, foram encontrados resultados interessantes.

O primeiro deles foi a elucidação de que a aplicação de diversas metodologias de processamento digital de imagens implicam em diferentes desempenhos e retornos de leitura no OCR. O método proposto na literatura clássica, que consiste na aplicação do filtro de colorimetria em escala de cinza e a extração de caracteres individualmente, após binarização da imagem, por muitas vezes apresentou resultados substancialmente inferiores as outras metodologias testadas neste trabalho.

Foi notado que o Cenário 10 do protocolo experimental base teve um desempenho bem divergente na identificação dos caracteres nas placas do padrão Mercosul e do padrão antigo brasileiro. Desta forma, este trabalho ressalta a importância de uma análise preliminar cuidadosa para se estabelecer um protocolo único de tratamento da imagem antes do OCR.

## 5.2 Propostas de melhorias

Como proposta de melhorias, recomenda-se implementar e testar novas metodologias de processamento de imagens, a fim de se garantir uma maior taxa de assertividade.

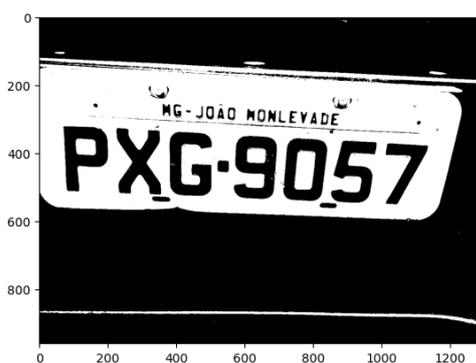
A implementação do filtro de detecção de borda pode ser novamente considerado juntamente com um aumento de largura de borda, quando se pretende realizar a segmentação e leitura individual dos caracteres das placas veiculares, seguindo o roteiro da literatura estudada, visando aumentar a taxa de assertividade à níveis comerciais.

Neste ponto, pode-se construir um sistema de reconhecimento de padrões que permita classificar cada um dos caracteres individualmente em um sistema previamente treinado para o padrão de placa correspondente.

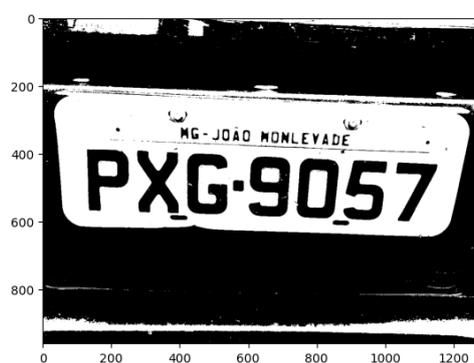
Outro ponto importante para aprimorar a taxa de assertividade, seria atuar diretamente nos desafios que envolvem a captura e pré-processamento da imagem. Padronizar a fotografia realizada, no que se diz respeito à distância da câmera com a placa, angulação da câmera, com o apoio de um suporte, altura deste suporte e por fim, padronização da intensidade de luz da placa, através do uso de iluminação artificial, a utilização de um equipamento de captura de imagens de maior qualidade aumentaria muito a taxa de assertividade do sistema.

Um outro ponto de melhoria interessante, seria a análise da placa através de fotos sequenciais. Fotos distintas, mesmo que minimamente diferentes, podem em alguns casos, apresentar retorno totalmente distinto.

Ainda, considerando o contexto brasileiro, também seria interessante criar identificador de padrão de placa, que detecta se ela está no padrão antigo brasileiro ou no padrão Mercosul e aplica o respectivo código corretor de erro, de modo a aumentar a flexibilidade do sistema automático de identificação.



(a) Leitura encontrada: EXG9057.



(b) Leitura encontrada: PXG9057.

Figura 5.1 – Fotografias semelhantes, com leituras distintas.

A Figura 5.1 apresenta duas fotografias resultantes da aplicação do filtro de colorimetria em escala de cinza e da binarização, apesar de serem muito semelhantes, o algoritmo de identificação dos caracteres retorna informações diferentes.

Deste modo, em casos onde um carácter distinto é lido de forma incorreta em cada uma das fotografias, o modelo de OCR aplicado em fotos sequências poderia gerar um outro código corretor de error que permitiria decidir melhor sobre o caractere correto.

Com estas melhorias, espera-se que a eficiência do sistema seja aprimorada, se aproximando da taxa de eficácia de um sistema comercial já implementado, semelhante a taxa de acerto do sistema *Open ALPR* ou da *Plate Recognizer*, por exemplo.

---

## Referências

---

- ALMERON, C. P. Estudo em processamento de imagens digitais aplicado ao reconhecimento de placas de veículos automotores brasileiros. 2016. 32
- BUFF, M. L. *What is optical character recognition*. 2021. Disponível em: <<https://buffml.com/what-is-optical-character-recognition/>>. 19
- COELHO, C. V. Um estudo sobre reconhecimento de placas de veículos fim-a-fim. Universidade Federal Fluminense, 2018. 20
- DONALD, J. *Validar Placas de Veículos com python (Padrão antigo e mercosul)*. 2021. Disponível em: <<https://josephdonald.wordpress.com/2021/05/20/verificar-placas-de-veiculos-com-python-inclui-o-padrão-mercosul/>>. 15
- DU, S. et al. Automatic license plate recognition (alpr): A state-of-the-art review. *IEEE Transactions on circuits and systems for video technology*, IEEE, v. 23, n. 2, p. 311–325, 2012. 14
- FILHO, A. W. L. O. et al. Reconhecimento de placas de carro para o controle de acesso a um condomínio residencial. Universidade do Estado do Amazonas, 2019. 18
- FORMENTIN, L. A. Smart cop: aplicativo para leitura e validação de placas veiculares utilizando a tecnologia alpr aplicada na fiscalização em tempo real de veículos durante uma abordagem policial. Universidade do Extremo Sul Catarinense, 2020. 21
- GONÇALVES, G. R. et al. Real-time automatic license plate recognition through deep multi-task networks. In: IEEE. *2018 31st SIBGRAPI conference on graphics, patterns and images (SIBGRAPI)*. [S.l.], 2018. p. 110–117. 19
- GONÇALVES, G. R. et al. Multi-task learning for low-resolution license plate recognition. In: SPRINGER. *Iberoamerican Congress on Pattern Recognition*. [S.l.], 2019. p. 251–261. 19
- GONZALEZ, R. C.; WOODS, R. E. *Processamento de imagens digitais*. [S.l.]: Editora Blucher, 2000. 18
- GOOGLE. *Google Colaboratory*. 2022. Disponível em: <<https://research.google.com/colaboratory/faq.html>>. 25
- KAGGLE. *License Plate Characters - Detection OCR*. 2021. Disponível em: <<https://kaggle.com/datasets/francescopettini/license-plate-characters-detection-ocr/>>. 22

- LAROCA, R. et al. On the cross-dataset generalization in license plate recognition. *arXiv preprint arXiv:2201.00267*, 2022. 19
- LAROCA, R. et al. A first look at dataset bias in license plate recognition. *arXiv preprint arXiv:2208.10657*, 2022. 19
- LAROCA, R. et al. A robust real-time automatic license plate recognition based on the yolo detector. In: IEEE. *2018 international joint conference on neural networks (ijcnn)*. [S.l.], 2018. p. 1–10. 19
- LAROCA, R. et al. An efficient and layout-independent automatic license plate recognition system based on the yolo detector. arxiv 2019. *arXiv preprint arXiv:1909.01754*. 19
- LAROCA, R. et al. An efficient and layout-independent automatic license plate recognition system based on the yolo detector. *IET Intelligent Transport Systems*, Wiley Online Library, v. 15, n. 4, p. 483–503, 2021. 19, 29, 36
- LODAYA, T. *YOLO model in car detection*. 2018. Disponível em: <<https://github.com/tejaslodaya/car-detection-yolo/>>. 19
- MENON, A.; OMMAN, B. Detection and recognition of multiple license plate from still images. In: IEEE. *2018 International Conference on Circuits and Systems in Digital Enterprise Technology (ICCSDET)*. [S.l.], 2018. p. 1–5. 21
- MINFRA; SNT. *Frota de Veículos*. 2021. Disponível em: <<https://cidades.ibge.gov.br/brasil/pesquisa/22/28120/>>. 14
- OPENCV. *Cv2 Manual*. 2022. Disponível em: <<https://docs.opencv.org/4.x/index.html>>. 25
- PLATE RECOGNIZER. *Melhor que OPEN ALPR*. 2022. Disponível em: <<https://platerognizer.com/better-than-openalpr/>>. 16
- REDMON, J. et al. You only look once: Unified, real-time object detection. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 779–788. 18
- REKOR. *Reconhecimento automático de placas facilitado*. 2022. Disponível em: <<https://br.openalpr.com/>>. 16
- RODRIGUES, D. A. Deep learning e redes neurais convolucionais: reconhecimento automático de caracteres em placas de licenciamento automotivo. Universidade Federal da Paraíba, 2018. 21, 32
- TESSERACT User Manual. 2022. Disponível em: <<https://tesseract-ocr.github.io/tessdoc/>>. 20, 29
- ULLAH, F. et al. Barrier access control using sensors platform and vehicle license plate characters recognition. *Sensors*, MDPI, v. 19, n. 13, p. 3015, 2019. 14, 18