

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Cyro Marleudo Gondim Sabóia

**Uma eficaz abordagem para classificação, detecção e reconhecimento
de placas veiculares brasileiras do novo modelo Mercosul**

Fortaleza – CE

08 de fevereiro de 2023

Cyro Marleudo Gondim Sabóia

Uma eficaz abordagem para classificação, detecção e reconhecimento de placas veiculares brasileiras do novo modelo Mercosul

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Processamento Digitais de Sinais e Imagens

Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

8 de fevereiro de 2023

Dados Internacionais de Catalogação na Publicação
Instituto Federal do Ceará - IFCE
Sistema de Bibliotecas - SIBI
Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

- S113e Sabóia, Cyro.
Uma eficaz abordagem para classificação, detecção e reconhecimento de placas veiculares brasileiras do novo modelo Mercosul / Cyro Sabóia. - 2023.
81 f. : il. color.
- Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Ciência da Computação, Campus Fortaleza, 2023.
Orientação: Prof. Dr. Pedro Pedrosa Rebouças Filho.
Coorientação: Prof. Dr. Pedro Pedrosa Rebouças Filho.
1. Detecção de placas veiculares. 2. Ajuste de perspectiva. 3. Reconhecimento de caracteres. 4. Detectron2. 5. Haar Cascade,. I. Título.

CDD 004

Agradecimentos

Agradeço a Deus pelo apoio em momentos de agústia e por me guiar sempre pelos melhores caminhos. Sou muito grato.

Agradeço a minha família e amigos, por todo apoio dado, pela paciência e entendimento de que o esforço é necessário para a conquista.

Agradeço ao meu Orientador Prof. Dr. Pedro Pedrosa Rebouças Filho, pela oportunidade, incentivo e por ter me inserido num meio de pessoas tão amigas e comprometidas com o que fazem. Aos amigos de laboratório; Fabrício, Adriell, Jerovane, Aldísio, Daniel, Lucas e Mateus pelas trocas de ideias e experiências na qual, assim como meu Orientador Prof^o Dr. Pedro Pedrosa, contribuíram para minha formação acadêmica.

Agradecer finalmente ao Laboratório de Processamento de Imagens, Sinais e Computação aplicada (LAPISCO), pela experiência e apredizado adiquirido e pelas conquistas que tanto buscamos e nos orgulhamos.

“O próprio senhor irá à sua frente e estará com você; Ele nunca o deixará, nunca o abandonará. Não tenha medo! Não desanime!”

Deuteronômio 31:8

Resumo

O reconhecimento automático de placas veiculares (ALPR) é uma combinação de diferentes etapas, onde a partir de uma imagem de entrada, há a detecção do objeto de interesse, a criação de uma nova imagem apenas com essa região de interesse e finalmente a identificação e classificação das partes internas da imagem, ou seja o reconhecimento dos caracteres. Atualmente, com o amadurecimento das técnicas de reconhecimento de placas veiculares (LPR), o uso dessas tecnologias vêm ganhando notoriedade. Com o surgimento de novas tecnologias do trânsito, como carros autônomos, sinais inteligentes e demais aplicações envolvendo o uso de imagens de trânsito, é de fundamental importância o desenvolvimento de sistemas robustos capazes de detectar de maneira automática os analíticos de trânsito, como fluxo e principalmente as informações contidas nas placas de veículos. O Brasil está passando atualmente por uma gradual mudança de formato de suas placas do modelo brasileiro antigo para o novo modelo Mercosul. Diante desse desafio, este trabalho propõe um estudo baseado na classificação de placas entre modelo antigo e o novo utilizando a rede *Detectron2*, detecção por meio do método *Haar Cascade*, *Tesseract-OCR* para o reconhecimento de caracteres, bem como o ajuste de perspectiva da angulação das placas nas imagens. Os resultados mostram uma acurácia de 95.48% para a classificação do tipo de placa, obtendo resultados de detecção satisfatórios com 98.00% de acurácia com o método de ajuste de perspectiva, contra 93.00% sem o ajuste, e 87.71% e 87.46% de reconhecimento dos caracteres sem e com ajuste de perspectiva respectivamente. O estudo proposto aborda um método totalmente automático, com uso da rede *Detectron2* para classificação dos tipos de placas, combinado ao método *Haar Cascade* para detecção da região de interesse, e o método de ajuste de perspectiva para alinhamento das placas com uso de *Tesseract-OCR* para reconhecimento dos caracteres. Apresentando assim, grande eficácia comparada a trabalhado encontrados na literatura.

Palavras-chave: Detecção de placas veiculares, Ajuste de perspectiva, Reconhecimento de caracteres, *Detectron2*, *Haar Cascade*, *Tesseract OCR*.

Abstract

Automatic License Plate Recognition (ALPR) is a combination of different steps, where from an input image, there is the detection of the object of interest, the creation of a new image only with that region of interest, and finally, the identification and classification of the internal parts of the segmented image, i.e., character recognition. Currently, with the maturation of license plate recognition (LPR) techniques, these technologies have been gaining notoriety. With the development of new traffic technologies, such as autonomous cars, intelligent signs, and other applications involving traffic images, it is essential to develop robust systems capable of automatically detecting traffic analytics, such as flow and especially information on license plates. Brazil is undergoing a gradual change in the format of its license plates from the old Brazilian model to the new Mercosur model. Faced with this challenge, this work proposes a study based on the classification of license plates between the old and new models using Detectron2, detection using the Haar Cascade method, and character recognition using perspective adjustment. The results show an accuracy of 95.48% for classifying the type of plaque, obtaining satisfactory detection results with 98.00% accuracy with the perspective adjustment method, against 93.00% without the adjustment, and 87.71% and 87.46 % character recognition without and with perspective adjustment respectively. The proposed study addresses a fully automatic method, using the Detectron2 network for classifying the types of plaques, combined with the Haar Cascade method for detecting the region of interest and the perspective adjustment method for aligning the plaques using Tesseract-OCR for character recognition. Thus presenting great effectiveness compared to the work found in the literature.

Keywords: License Plate Detection, Perspective Adjustment, Character Recognition, Detectron2, Haar Cascade, Tesseract OCR.

Lista de ilustrações

Figura 1 – Diferentes modelos de placas atualmente em circulação no Brasil. Fonte: Adaptadas da internet.	26
Figura 2 – Pseudocódigo do algoritmo de heurística	39
Figura 3 – Figura que ilustra a metodologia proposta por este estudo. Etapa 01 - Classificação da Placa: Classifica se a placa é um modelo brasileiro antigo ou um modelo novo do Mercosul. Etapa 02 - Ajuste de Perspectiva: Ajuste de inclinação usando a transformada de hough. Etapa 03 - Detecção de Placas: Detecção pelo modelo treinado com Haar Cascade. Etapa 04 - Reconhecimento de placas: Reconhecimento de caracteres usando Tesseract OCR. Etapa 05 - Heurística: Algoritmo heurístico para ajustar erros nas posições entre letras e dígitos. Fonte: O próprio autor.	43
Figura 4 – Exemplos de detecção de placas nos veículos	48
Figura 5 – Exemplo do pré-processamento das imagens detectadas.	49
Figura 6 – Exemplo de placas detectadas	49
Figura 7 – Exemplo de placas detectadas e removendo as bordas e mantendo apenas a região de interesse onde estão os dígitos.	49
Figura 8 – OCR Result.	49
Figura 9 – Fluxograma da metodologia proposta. A imagem ilustra o método proposto por este estudo. Nove etapas apresentam o modelo; são eles: Etapa 1 - Placas de Imagens do Mercosul Real, Etapa 2 - Classificador em Cascata de Imagens Sintéticas, Etapa 3 - Segmentação, Etapa 4 - Ajuste de Perspectiva, Etapa 5 - Pré-processamento, Etapa 6 - Tesseract OCR, Etapa 7 - Saída de Texto, Etapa 8 - Heurística e Etapa 9 - Saída de texto.	51
Figura 10 – Ilustração da Etapa de Treinamento: A. Conjunto de dados sintéticos, B. Treinamento e C. Modelos treinados com base em imagens sintéticas.	53
Figura 11 – Ilustração do estágio de segmentação: imagens contando apenas a placa do veículo gerada a partir da imagem original.	54
Figura 12 – Ilustração do estágio de ajuste de perspectiva: novas imagens geradas pela correção de inclinação das placas.	54
Figura 14 – Imagem do resultado do reconhecimento de caracteres gerado pelo Tesseract-OCR.	56
Figura 15 – Imagem com o resultado do reconhecimento de caracteres após passar pelo algoritmo de heurística.	57
Figura 16 – Exemplo de perspectiva das imagens sintéticas.	59

Figura 17 – Exemplo de perspectiva das imagens reais	59
Figura 18 – Figura baseada na Tabela 8, mostrando os diferentes valores obtidos depois do ajuste de perspectiva.	62
Figura 19 – Amostras de imagens de conjuntos de dados reais de diferentes veículos.	64
Figura 20 – Amostra da detecção em diferentes placas.	64
Figura 21 – Amostra de ajuste de perspectiva em diferentes placas. Compare com a Figura 20	65
Figura 22 – Pré-processamento: imagem suavizada, binarizada e operações morfoló- gicas aplicadas em diferentes placas.	65
Figura 23 – Resulta do reconhecimento de caracteres em diferentes placas.	65
Figura 24 – Imagem com o resultado do reconhecimento de caracteres após passar pelo algoritmo de heurística.	66
Figura 25 – Figura ilustrando o resultado do ajuste de perspectiva.	69
Figura 26 – Representação gráfica dos modelos de detecção de placas e seus respec- tivos resultados.	72
Figura 27 – Uma representação de plotagem dos resultados de detecção sem ajuste e com ajuste de perspectiva da Tabela 18.	76
Figura 28 – Uma representação de plotagem dos resultados de reconhecimento de caracteres sem ajuste e com ajuste de perspectiva da Tabela 18.	76

Lista de tabelas

Tabela 1 –	Quantidades e tamanho das imagens utilizadas nos treinamentos	48
Tabela 2 –	Apresentação de Diferentes modelos de detecção de placas com os respectivos resultados.	50
Tabela 3 –	Apresentação dos resultados do reconhecimento de caracteres.	50
Tabela 4 –	Tabela de substituições do algoritmo de heurística.	56
Tabela 5 –	Apresentação de diferentes resultados de detecção de placas.	58
Tabela 6 –	Comparação dos modelos de detecção - Imagens sintéticas e reais . . .	60
Tabela 7 –	Comparação dos modelos de reconhecimento de caracteres usando Tesseract OCR - Imagens sintéticas e reais.	61
Tabela 8 –	Apresenta a divisão do dataset UFC-LRP.V1: contendo 1 mil amostras de diferentes placas reais de Mercosul - Resultado da detecção.	62
Tabela 9 –	Apresenta a divisão do UFC-LRP.V1: contendo 100 amostras de diferentes placas reais do Mercosul - Resultado do Reconhecimento.	62
Tabela 10 –	Trainamento do Haar-Cascade.	64
Tabela 11 –	Modelos de detecção e seus respectivos resultados.	67
Tabela 12 –	Character Recognition models Comparison using Tesseract OCR - Real and synthetic images.	67
Tabela 13 –	Trainamento Haar-Cascade.	70
Tabela 14 –	Classificação de placas brasileiras com Detectron2.	71
Tabela 15 –	Modelos de detecção de placas e seus respectivos resultados.	72
Tabela 16 –	Comparação dos modelos de reconhecimento de caracteres usando Tesseract OCR - Imagens reais e sintéticas.	74
Tabela 17 –	Evolução dos treinamentos com imagens sintéticas e reais.	74
Tabela 18 –	Resultados dos experimentos	75

Lista de abreviaturas e siglas

ALPR	Reconhecimento Automático de Placas Veiculares(<i>Automatic License Plate Recognition</i>)
CCA	Análise de Componentes conectados(<i>Connected Component Analysis</i>)
CNN	Rede neural convolucional(<i>Convolutional neural network</i>)
DCNN	Rede neural convolucional profunda(<i>Deep convolutional neural network</i>)
FAIR	Pesquisa de inteligência artificial do Facebook(<i>Facebook AI Research</i>)
FPS	Quadros por segundo(<i>Frames per second</i>)
HG	Geração de hipóteses(<i>Hypotheses generation</i>)
HV	Verificação de hipóteses(<i>Hypotheses verification</i>)
IA	Inteligência Artificial
LBP	Padrão binário local (<i>Local binary pattern</i>)
LPR	Reconhecimento de Placas Veiculares(<i>License Plate Recognition</i>)
Mask R-CNN	Redes Neurais Convolucionais baseadas em Regiões com Máscara
Mercosul	Mercado Comum do Sul
OCR	Reconhecimento óptico de caracteres(<i>Optical Character Recognition</i>)
RNA	Redes Neurais Artificiais
R-CNN	Redes Neurais Convolucionais baseadas em Regiões
SVM	Máquina de vetores de suporte(<i>Support Vector Machine</i>)

Sumário

1	INTRODUÇÃO	23
1.1	Motivação para a Dissertação	25
1.2	Descrição do problema	26
1.3	Objetivo Geral e Específicos	27
1.4	Produção científica	27
1.5	Estrutura da Dissertação	29
2	TRABALHOS RELACIONADOS	31
3	FUNDAMENTAÇÃO TEÓRICA	35
3.1	Machine Learning	35
3.2	Deep Learning	36
3.3	Detectron2	36
3.4	Haar-Cascade	37
3.5	Ajuste de Perspectiva	37
3.6	Tesseract-OCR	37
3.7	Algoritmo de Heurística	38
3.8	Métrica de Avaliação	40
3.8.1	Precisão - (<i>Accuracy</i>)	40
4	METODOLOGIA	41
4.1	Conjunto de Dados	41
4.1.1	Primeiro dataset	41
4.1.2	Segundo dataset	41
4.1.3	Terceiro dataset	42
4.1.4	Quarto dataset	42
4.1.5	Quinto dataset	42
4.2	Método Proposto	42
4.2.1	Etapa 01 - Classificação	43
4.2.2	Etapa 02 - Ajuste de perspectiva	44
4.2.3	Etapa 03 - Detecção	44
4.2.4	Etapa 04 - Reconhecimento	44
4.2.5	Etapa 05 - Heurística	44
5	RESULTADOS E DISCUSSÃO	47
5.1	Experimento 1	47

5.1.1	Detecção das placas	47
5.1.2	Reconhecimento de caracteres das placas	48
5.1.3	Resultados e discussões	49
5.2	Experimento 2	51
5.2.1	Etapa de treinamento	52
5.2.2	Etapa de testes	52
5.2.2.1	Etapa 1 - Placas reais do novo modelo Mercosul	52
5.2.2.2	Etapa 2 - Modelo <i>Haar Cascade</i> treinado em imagens sintéticas	53
5.2.2.3	Etapa 3 - Detecção	53
5.2.2.4	Etapa 4 - Ajuste de perspectiva	54
5.2.2.5	Etapa 5 - Pré-processamento	54
5.2.2.6	Etapa 6 - Tesseract OCR	55
5.2.2.7	Etapa 7 - Resultado do reconhecimento de caracteres	55
5.2.2.8	Etapa 8 - Heurística	55
5.2.2.9	Stage 9 - Resultado do reconhecimento	56
5.2.3	Resultados e discussões	57
5.2.3.1	Detecção e reconhecimento de caracteres (Testes em placas sintéticas)	57
5.2.3.2	Detecção e reconhecimento de caracteres (Testes em placas reais e Placas Sintéticas)	58
5.2.3.3	Valiação dos resultados no dataset de imagens reais	61
5.3	Experimento 3	63
5.3.0.1	Etapa 1 - Imagens de Entrada do Conjunto de Dados com Imagens Reais	64
5.3.0.2	Etapa 2 - Modelo Haar-Cascade Treinado	64
5.3.0.3	Etapa 3 - Detecção das Placas	64
5.3.0.4	Etapa 4 - Ajuste de Perspectiva	64
5.3.0.5	Etapa 5 - Pré-processamento das Imagens	65
5.3.0.6	Etapa 6 - Reconhecimento de Caracteres	65
5.3.0.7	Etapa 7 - Resultado do reconhecimento da Imagem em Texto	65
5.3.0.8	Etapa 8 - Algoritmo de Heurística	65
5.3.0.9	Etapa 9 - Resultado Final do Reconhecimento de Caracteres	66
5.3.1	Resultados e Discussões	66
5.3.1.1	Detecção	66
5.3.1.2	Reconhecimento de Caracteres	67
5.4	Experimento 4	68
5.4.1	Etapa 01 - Classificação das placas (Modelo brasileiro antigo e Novo modelo Mercosul)	69
5.4.2	Etapa 02 - Ajuste de perspectiva	69
5.4.3	Etapa 03 - Detecção das placas	70
5.4.4	Etapa 04 - Reconhecimento de caracteres	70
5.4.5	Etapa 05 - Algoritmo de heurística	71

5.4.6	Resultados e discussões	71
5.4.6.1	Classificação	71
5.4.6.2	Detecção	72
5.4.6.3	Reconhecimento de caracteres	73
5.5	Discussão	74
5.5.1	Detecção	75
5.5.2	Reconhecimento de Caracteres	76
6	CONCLUSÃO	77
	REFERÊNCIAS	79

1 Introdução

Atualmente o uso de veículos está aumentando rapidamente (KESSENTINI et al., 2019), as vias de tráfego estão sendo cada vez mais monitoradas pelas autoridades para diversos interesses, como controle de velocidade, detecção de veículos pendentes de impostos, detecção de veículos roubados ou com pendências administrativas, identificação de faixa de pedestres, identificação de pedestres utilizando a faixa de pedestres, auxiliar câmeras fixas e de carros autônomos a detectar a velocidade permitida na via e demais sinalizações, entre outras possibilidades (FERNANDES et al., 2020; IBADOV et al., 2017; SALIMULLINA; BUDANOV, 2022; CIUNTU; FERDOWSI, 2020; GLADENCE et al., 2022). Além das aplicações no setor público, a detecção e o reconhecimento automático de placas também podem ser aplicados no setor privado (NETO et al., 2015), como autorizações de acesso de estacionamento de condomínio, registros de acesso de estacionamento por hora ou fração, etc.

Esse aumento da quantidade de veículos nas ruas e rodovias fazem também aumentar os desafios para a gestão e segurança de tráfego nas cidades. Como consequência desse aumento e da evolução tecnológica que passamos nos dias atuais, o monitoramento das ruas e rodovias segue acompanhando essa tendência de crescimento, tendo cada vez mais câmeras de controle e segurança de tráfego espalhadas por diversos pontos de uma cidade.

Os radares estão entre os sensores mais conhecidos na contínua atividade de fiscalização nas vias de trânsito, seja o radar fixo, que consiste em sensores magnéticos colocados no asfalto capazes de acionar uma câmera de captura de imagem do veículo; ou o radar móvel, que realiza a detecção do veículo através da percepção de ondas eletromagnéticas emitidas na sua direção. Estes dispositivos possuem a finalidade de detectar e identificar o veículo no momento de sua passagem, seja para fiscalização de velocidade de deslocamento ou pelo rastreamento de veículos. É importante ressaltar que a placa de identificação do veículo é obtida a partir da imagem capturada de uma câmera acionada por esses sensores (HILPERT et al., 2019).

Entretanto, a utilização do radar de trânsito se torna inviável em aplicações mais abrangentes de rastreamento de veículo ou coleta de informações por imagem, isto se deve pelo alto custo do equipamento, pelas limitações de captura, como a perspectiva, iluminação e posicionamento no momento da captura da imagem (XU et al., 2018), principalmente no que diz respeito às condições de captura das placas do veículo, uma problemática bastante discutida na literatura (MOLINA-MORENO; GONZALEZ-DIAZ; MARIA, 2018). Dessa forma, torna-se fundamental a existência de aplicações capazes de coletar informações das placas dos veículos através de câmeras, sejam câmeras fixas instaladas estrategicamente

nas vias, seja por câmeras localizadas diretamente em veículos, como em aplicações com carros autônomos (LUNA et al., 2022).

A discussão da detecção de placas de maneira automática amadureceu com o surgimento de técnicas de LPR, que realiza a detecção automática das placas alfanumérica a partir da imagem fornecida por câmeras de vídeos, viabilizando aplicações mais complexas e em tempo real. Com o aumento do número de possibilidades e o amadurecimento das técnicas de visão computacional, o desenvolvimento de sistemas de detecção e reconhecimento de placas torna-se necessário para a vigilância e comodidade da sociedade, criando um ambiente favorável para pesquisas sobre *Automatic License Plate Recognition* (ALPR), gerando resultados cada vez mais robustos e confiáveis (LEE; HALIM; WAHAB, 2022).

Além disso, o surgimento de novas tecnologias do trânsito, como carros autônomos, sinais inteligentes e demais aplicações envolvendo o uso de imagens de trânsito, torna de fundamental importância o desenvolvimento de sistemas robustos capazes de detectar de maneira automática os analíticos de trânsito, como fluxo, a classe, e principalmente as informações contidas nas placas de veículos. Esses sistemas inteligentes de reconhecimento pode ajudar a economizar recursos humanos e de materiais, melhora na coleta de informações dos veículos, no rastreamento e no mapeamento das condições de tráfego (ZHANG et al., 2021).

Com o avanço das tecnologias de tráfego, sistemas inteligentes de detecção e reconhecimento de imagens de tráfego se tornam cada vez mais críticas para o auxílio ao gerenciamento de rodovias, melhorando a coleta de informações e mapeamento das condições de tráfego (ZHANG et al., 2021). Tecnologias para detecção e reconhecimento de placas, sejam elas de vias ou de veículos, ainda são objetos de relevantes estudos no campo de visão computacional, seja para aplicações de segurança rodoviária, estacionamento, pedágios, rastreamento de veículos roubados, controle de fronteiras, monitoramento de velocidade, etc (BENSOUILAH; ZENNIR; TAFFAR, 2021; VI; FAUDZI, 2022; SBORZ et al., 2019).

Além do amadurecimento das técnicas de LPR, uma boa infraestrutura de rede, armazenamento e envio de dados para aplicações em tempo real também se faz necessária. Trabalhos mais atuais buscam a integração de seus sistemas de para o reconhecimento de placa com sistemas computação em nuvem (JAIN; GUPTA; ABRAHAM, 2021), principalmente focados no uso de redes 5G, pela maior velocidade, menor latência na comunicação, ampla capacidade de multiconexão de dispositivos dentre outras vantagens (GAI et al., 2021). Trabalhos como o de Coronado et al (CORONADO; CEBRIAN-MARQUEZ; RIGGIO, 2019), que desenvolveram em seu estudo uma plataforma de computação de borda multiacesso para o descarregamento de tarefas de condução autônoma e assistida para as bordas da rede, além de discorrerem sobre os paradigmas da computação em nuvem. Dessa forma, os autores abriram novos horizontes para aplicações em tempo

real, como a navegação e captura de dados de um sistema de navegação autônoma.

No estado atual da pesquisa em visão computacional, as redes neurais convolucionais (CNNs) são amplamente consideradas os modelos mais avançados para classificação de imagens. Essas redes são capazes de identificar padrões complexos nas imagens e, por meio do treinamento em grandes conjuntos de dados, alcançaram desempenhos impressionantes em tarefas de classificação em geral (ALBAWI; MOHAMMED; AL-ZAWI, 2017). Já para a detecção de objetos, as abordagens mais populares incluem Faster R-CNN, RetinaNet, YOLO e SSD. Esses modelos usam as características extraídas pelas CNNs para localizar objetos em tempo real e têm sido utilizados em diversas aplicações, como vigilância, direção autônoma e reconhecimento de faces (QIAN; XU; ZHOU, 2018). No reconhecimento de caracteres, as CNNs também têm mostrado eficácia, mas as redes recorrentes (RNNs) são frequentemente usadas para lidar com sequências de caracteres e palavras. Modelos como CRNN e LSTM-CTC foram desenvolvidos para converter texto digitalizado em texto editável por meio de técnicas de OCR (reconhecimento óptico de caracteres), sendo aplicados em diversas áreas, como digitalização de livros e documentos, reconhecimento de placas de carro e transcrição de legendas (DUTTA et al., 2018).

Com a crescente demanda de aplicações de LPR e seus desafios, este trabalho propõe uma abordagem automática de classificação, detecção e reconhecimento de caracteres buscando ampliar as discussões sobre o uso da rede *Detectron2* para classificação de placas em modelo brasileiro antigo e o novo modelo Mercosul, do *Haar Cascade* como ferramenta de visão computacional para a detecção de placas, *Tesseract-OCR* para o reconhecimento de caracteres e uma nova base de dados contendo apenas placas brasileiras do novo modelo Mercosul (PALEKAR et al., 2017; DIAS; JAGETIYA; CHAURASIA, 2019; DOME; SATHE, 2021).

1.1 Motivação para a Dissertação

Não é de hoje que câmeras de monitoramento e de segurança vem se espalhando rapidamente por todos os setores da sociedade. A princípio essas câmeras serviam apenas para ajudar ao homem na tomada de decisões, seja em tempo real ou por imagens armazenadas. No entanto, com o avanço das tecnologias e o amadurecimento das técnicas de processamento de imagens e visão computacional, uma nova e vasta gama de possibilidades despontaram.

Coadunando com esse amadurecimento, técnicas de LPR no campo de visão computacional permitiu avanços nas discussões sobre detecção de placas e o reconhecimento de dígitos em imagens fornecidas por câmeras de vídeo, sejam elas embarcada em veículos ou em pontos específicos das rodovias, permitindo o desenvolvimento de aplicações mais complexas em tempo real e tornando-se um importante aliado para sistemas inteligente de

segurança e transporte.

O Brasil vem passando por uma mudança de modelos de placas de veículos. A partir do ano de 2019, iniciou-se a substituição das placas do modelo brasileiro antigo pelas placas do novo modelo Mercosul. Essa mudança ocorre de forma gradativa a partir do emplacamento de novos veículos, permitindo que existam dois tipos de placas oficialmente em circulação. Ambos modelos possuem sete caracteres, mas com diferenças; o modelo antigo possui cor predominante cinza e caracteres pretos, sendo formado por três letras, hífen e quatro números; o modelo novo possui cor predominante branca, tarjeta azul e caracteres pretos, sendo formado por três letras, um número, uma letra e dois números, conforme apresentado na Figura 1.

Os modelos e visão computacional estão mais direcionados para o modelo antigo, tornando escasso os estudos sobre o novo modelo. Diante disso, este estudo propõe um estudo de ALPR para o novo modelo de placas Mercosul.

1.2 Descrição do problema

O *Automatic License Plate Recognition* (ALPR), que se tornou um importante tópico de pesquisa desta época, é um sistema de vigilância que através da captura de imagens de veículos, identifica a placa e reconhece seus números e caracteres (RIAZ et al., 2020)

O modelo de placa brasileiro atualmente está em transição do formato de placas antigos, exclusivamente utilizado no Brasil, para um novo modelo que abrange todo o território do Mercosul (RIBEIRO et al., 2019), conforme a Figura 1.



Figura 1 – Diferentes modelos de placas atualmente em circulação no Brasil. Fonte: Adaptadas da internet.

Em cima disso, este trabalho traz como inovação uma solução automática para classificação, detecção, e reconhecimento de caracteres de placas veiculares brasileiras do novo modelo Mercosul, reunindo conceitos atuais inspirados em modelos do estado da arte combinados a métodos tradicionais de aprendizagem de máquina.

1.3 Objetivo Geral e Específicos

A finalidade deste trabalho é apresentar um estudo sobre classificação, detecção e reconhecimento de caracteres no novo modelo de placas do Mercosul adotada no Brasil a partir de 2019 (RIBEIRO et al., 2019). Como parte macro do problema, este trabalho propõe uma abordagem automática partindo da detecção e classificação da placa em modelo brasileiro antigo e novo modelo Mercosul, e o reconhecimento dos caracteres dos modelos classificados como Mercosul.

Objetivos específicos:

1. Investigar na literatura, métodos de detecção e reconhecimento de caracteres de placas para comparação de desempenho entre os resultados;
2. Propor uma abordagem de classificação das placas em modelo brasileiro antigo e o novo modelo Mercosul usando a *Detectron2*, permitindo a escolha automática do objeto desejado;
3. Propor um ajuste de perspectiva das imagens das placas corrigindo inclinações das imagens utilizando a *Hough transform*, melhorando o reconhecimento dos caracteres pelo *Tesseract-OCR*;
4. Apresentar uma abordagem de detecção de placas usando o algoritmo de aprendizado *Haar-Cascade* para possíveis comparações do estado da arte;
5. Apresentar uma abordagem de reconhecimento de caracteres utilizando o software de reconhecimento óptico *Tesseract-OCR* para realizar a leitura dos caracteres;
6. Apresentar um algoritmo de heurística que corrige eventuais falhas no reconhecimento de caracteres;
7. Gerar uma base de dados com imagens de placas reais no novo formato do Mercosul, disponibilizando uma base de dados para novos estudos.

1.4 Produção científica

Durante este projeto de mestrado, os seguintes trabalhos científicos foram aceitos e publicados, a saber:

- (ISDA 2021) - Brazilian Mercosur License Plate Detection and Recognition Using Haar Cascade and Tesseract OCR on Synthetic Imagery - 1º Autor - Qualis B1 (CC);

- (JIAS 2022) - New Approach to the Detection and Recognition of Brazilian Mercosur Plates Using Haar Cascade and Tesseract OCR in Real Images - 2º Autor - Qualis B5 (CC);
- (ISDA 2022) - Fully Automatic LPR Method Using Haar Cascade for Real Mercosur License Plates - 1º Autor - Qualis B1 (CC);
- (ISDA 2022) - New Approach in LPR Systems Using Deep Learning to Classify Mercosur License Plates with Perspective Adjustment - 3º Autor - Qualis B1 (CC);

1.5 Estrutura da Dissertação

O Capítulo 2 apresenta uma revisão bibliográfica de trabalhos relacionados à métodos tradicionais de detecção e reconhecimento de placas de veículos. No capítulo 3 são explanados os modelos de aprendizado de máquina utilizados no método proposto.

No capítulo 4 é apresentado um novo método de classificação, detecção e reconhecimento de caracteres de placas veiculares brasileiras no novo formato Mercosul. No capítulo 5 são apresentados os resultados dos experimentos. Por fim, a Conclusão e Trabalhos Futuros no Capítulo 6.

2 Trabalhos relacionados

Neste capítulo é apresentado métodos de detecção e reconhecimento de placas veiculares. O reconhecimento de placa torna-se uma ferramenta fundamental em para a vida em sociedade com transporte inteligente, seja como ferramenta de fiscalização, seja no auxílio à coleta de informações de veículo, de maneira à melhorar o rastreamento ou mapeamento de condições de tráfego. Ciente da fundamental importância dessa área de estudo para a melhora da qualidade no trânsito, este estudo busca discorrer sobre os principais e mais atuais trabalhos da área, com foco principalmente na detecção de placas e caracteres.

Buscando desenvolver uma ferramenta eficiente e com baixo custo computacional, (Menon, Aiswarya and Omman, Bini, 2018) propuseram um método para detecção e reconhecimento de placas de veículos em imagens de quadro único. Na etapa de detecção, é realizada a segmentação da placa com auxílio de um conjunto de técnicas de filtragem, operações morfológicas, algoritmos para detecção de contorno e extração da região da imagem de interesse. Após a segmentação, os caracteres são classificados com o auxílio da técnica de Machine Learning denominada Support Vector Machine (SVM).

Também instigados por aplicações de baixo custo computacional, (YOUSEFI et al., 2019) apresentaram uma algoritmo automático para detecção de placas de transito. A técnica faz uso de um classificador multiescala treinado a partir de atributos extraídos pela técnica de Padrão binário local (LBP), sendo capaz de detectar placas em qualquer tamanho dentro de um quadro. Com finalidade de melhorar o desempenho e a precisão para a detecção, os autores propuseram variações de técnicas em seu algoritmo, como a detecção em dois estágios, subtração de fundo para eliminação de áreas não móveis e um método para estimar o tamanho das placas em cada parte dos quadros com base em regressão linear. Em seu melhor método, foram alcançadas acurácias de 99%, com uma boa taxa de detecção, comprovando a eficácia do método. Entretanto, mesmo que o algoritmo proposto seja capaz de generalizar a detecção das placas independente do seu tamanho, a perspectiva de captura da placa ainda é um problema.

Um dos primeiros passos para a detecção e reconhecimento de placas veiculares é a detecção do veículo dentro de um cenário mais amplo. Keerthi et al.(KIRAN; PARIDA; DASH, 2021) realizou um estudo detalhado sobre sistemas de monitoramento e classificação de tráfego usando métodos de visão computacional, como geração de hipóteses (HG) e verificação de hipóteses (HV).

Já Pirgazi et al (PIRGAZI; SORKHI; KALLEHBASTI, 2021) desenvolveram uma ferramenta de reconhecimento de placa de veículos. Essa ferramenta realiza a classificação

do veículo através de métodos de emissão de fundo. A partir do veículo detectado, a placa é detectada com auxílio de reconhecimento de caracteres e pattern matching. Os caracteres são segmentados e extraídos da placa a partir de técnicas de recursos estatísticos, métodos de filtragem e operadores de morfologia. Por fim, os caracteres são classificados com auxílio do classificador *Random forest*. Os autores atingiram o estado da arte, com 98% de acurácia na detecção de Caracteres. Entretanto, vale ressaltar que mesmo com ótimos resultados em termos de detecção e reconhecimento, os autores não demonstraram a capacidade do método em lidar com placas com problemas de captura proveniente de perspectiva.

Fernandes et al (FERNANDES et al., 2020) elaboraram um sistema eficiente de detecção de placas. Para a detecção das placas na imagem, foi utilizada a combinação da MobileNet-SSD e Tiny YOLOv3. Já o reconhecimento dos caracteres da placa foi realizado com a OCR-net. A metodologia empregada alcançou 96,87% de precisão, com 8 FPS em um cenário público real e 90,56% de precisão, com 11 FPS em um conjunto de dados de imagens de monitoramento de tráfego. Vale que a técnica tem um elevado custo computacional, o que reflete na baixa taxa de FPS, além de que a técnica ferramenta poderia ser melhorada com o uso de uma versão Yolo mais atualizada.

Amzad et al (HOSSAIN et al., 2021) desenvolveram uma técnica de reconhecimento de placas de veículos baseados em Análise de Componentes conectados (CCA) e CNN treinada à partir de um *Dataset PlateNumbers*. A ferramenta se baseia em CCA para a segmentação de caracteres, alcançando 92,78% de precisão para detecção das placas e 97,94% na segmentação de caracteres. Já para o reconhecimento dos caracteres com o auxílio da CNN treinada, o resultado atingiu 96,91% de precisão, demonstrando resultados satisfatórios. Entretanto, vale ressaltar que o *dataset* utilizado possui baixa quantidade de amostras, além de não ser o ideal para a aplicação em questão.

Dangi et al (DANGI et al., 2022) desenvolveram uma técnica de reconhecimento de números de placas indianos através do uso de uma CNN treinada a partir de um *dataset* sintético. A CNN utilizada foi a LPRNet. Em seus resultados, mediante pós processamento e fine-tuning, o método proposto pelos autores foi capaz de atingir 95% de acurácia, demonstrando resultados satisfatórios. Entretanto, o método precisou passar por várias etapas de pós processamento, o que consequentemente afeta no custo computacional do método.

Em (SABÓIA; FILHO, 2022) Cyro et al. propôs uma abordagem de detecção e reconhecimento de caracteres de placas veiculares usando *Haar Cascade* para detecção da placa e *Tesseract OCR* para reconhecimento de caracteres. A metodologia utilizada foi treinar o algoritmo *Haar Cascade* em uma base de dados de imagens com placas geradas sinteticamente (RIBEIRO et al., 2019), obtendo 83.82% de taxa de detecção e passar as placas detectadas para o software de reconhecimento óptico *Tesseract-OCR*, obtendo

95.72% de taxa de reconhecimento de caracteres.

Elleuch et al. (ELLEUCH MOHAMED; JRABA, 2021) abordou em seu trabalho o reconhecimento de palavras (OCR) manuscritas em árabe, adotando como modelo a rede neural convolucional profunda (DCNN), bem como o Inception-v3, ResNet e o VGG16. A abordagem é composta de três etapas principais: pré-processamento, aprendizagem e reconhecimento. Os modelos ResNet e VGG16 aqui utilizados obtiveram resultados com precisão de 98.99% e 98.10% respectivamente.

Então, motivados pelos estudos abordados nesta secção, bem como o apelo por tecnologias rápidas, eficientes e robustas para a detecção de placas de veículos e o reconhecimento de seus caracteres, este estudo busca o desenvolvimento de uma ferramenta automática de detecção de placas brasileiras do novo formato do Mercosul com auxílio da técnica *Haar Cascade* para detecção das placas, da *Detectron2* para classificação das placas em modelo antigo e modelo novo e, em seguida, do reconhecimento dos caracteres com auxílio do pacote de reconhecimento óptico *Tesseract-OCR*.

3 Fundamentação Teórica

Neste estudo é proposto um método para classificação, detecção e reconhecimento de caracteres de placas veiculares brasileiras. Devido às especificidades do momento de transição entre modelos de placas no Brasil, este trabalho propõe uma abordagem completa passando por diversas etapas como a detecção da placa, a classificação entre modelo antigo e o novo modelo Mercosul, ajuste de perspectiva para corrigir inclinações das imagens devido ao posicionamento das câmeras de capturas de imagens, o reconhecimento de caracteres e um algoritmo de heurística que busca corrigir eventuais trocas de letras por dígitos e vice-versa. Nas próximas seções deste capítulo é apresentado brevemente sobre os métodos de aprendizado de máquina, bem como a métrica de avaliação utilizada para avaliar o método de classificação, detecção e reconhecimento de caracteres em placas veiculares.

3.1 Machine Learning

Diante do exposto nas Sessões 1 e 2, é justificável afirmar o enriquecimento do estudo relacionado a aprendizagem de máquina das últimas décadas. Ele evoluiu do estudo da teoria de aprendizado computacional e reconhecimento de padrões, através de modelos e algoritmos de aprendizagem automática baseada em reconhecimento de padrões e tomada de decisões (ANGRA; AHUJA, 2017).

O aprendizado de máquina existe pelo menos desde a década de 1970, mas na atualidade eles se tornaram cada vez mais presentes. Dois fatores podem ser facilmente elencados para essa evolução: o primeiro é o aumento do poder de processamento computacional, que permite executar tarefas cada vez mais complexas; o segundo é a explosão de dados que são capturados e armazenados, expandindo assim a possibilidade de aplicações disponíveis (LOURIDAS; EBERT, 2016).

Segundo (SHARMA; HAQUE; BLAABJERG, 2021), o aprendizado de máquinas é um campo da inteligências artificial (IA) que permite que sistemas possam aprender e melhorar automaticamente, sem serem explicitamente programados, através de experiências anteriores e acesso à dados. Atualmente, as arquiteturas de *Deep learning* estão mostrando melhor desempenho em comparação com os modelos tradicionais.

3.2 Deep Learning

A *Deep Learn* é uma área da *MachineLearn* que trata mais especificamente de Redes Neurais Artificiais (RNAs), área que busca simular computacionalmente o funcionamento da rede neural do cérebro humano.

As arquiteturas de aprendizagem profunda têm sido empregadas com sucesso em uma ampla gama de aplicações, como classificação de imagens e vídeos, e cuidados de saúde. O sucesso desses modelos é atribuído ao melhoramento da representação de recursos por meio de arquiteturas de processamento multicamada através do desenvolvimento de redes neurais convolucionais (CNNs) (QI et al., 2021). O modelo de aprendizado profundo têm sido usado principalmente para problemas de classificação, regressão e agrupamento (GANAIE; HU et al., 2021), produzindo excelentes resultados.

As Convolutional Neural Networks (CNNs) são um tipo de rede neural profunda que se destacam no processamento de dados com estrutura espacial, como imagens e vídeos. Inspiradas no córtex visual do cérebro humano, as CNNs usam camadas convolucionais para extrair características das imagens e camadas totalmente conectadas para classificar as imagens com base nessas características.

Existem vários tipos de CNNs, cada um com uma arquitetura e finalidade específicas. Algumas das arquiteturas de CNN mais conhecidas são a LeNet, a AlexNet, a VGG, a Inception e a ResNet. Cada uma dessas arquiteturas apresenta diferentes configurações de camadas convolucionais, de pooling e de camadas totalmente conectadas, permitindo que sejam aplicadas em diversas aplicações, como reconhecimento de imagens, segmentação de objetos, detecção de anomalias, entre outras.

3.3 Detectron2

A rede *Detectron2* é uma CNN desenvolvida pelo *Facebook AI Research (FAIR)* para suporte a novas pesquisas de visão computacional. Esta Rede tem o seu funcionamento baseado nas redes *faster R-CNN* e *mask R-CNN*, permitindo que seja realizada não somente a classificação de imagens, mas também a classificação de objetos na imagem, como regiões de interesses ou demais artefatos (PHAM; PHAM; DANG, 2020). Como a Rede é capaz de classificar facilmente as imagens uma vez que a classe apontada pelo objeto da imagem pode ser usada para rotular a mesma dependendo do contexto da aplicação, produzindo resultados robustos de classificação.

Detectron2 é uma reescrita implementada em *Pytorch* da rede *Detectron*, originalmente implementada em *Caffe2*. Seu novo design mais modular é capaz de fornecer treinamentos mais rápidos, além de permitir aos usuários implementações de módulos personalizados. *Detectron2* manteve os modelos disponíveis na *Detectron* original, como

Faster R-CNN, *Mask R-CNN*, *Retinanet*, *Densepose*, entre outros. Além disso, *Detectron2* adicionou suporte para *Semantic Segmentation* e *Panoptic Segmentation* (KIRILLOV et al., 2020; WU et al., 2019).

3.4 Haar-Cascade

Haar cascade é um classificador em cascata disponibilizado pela biblioteca *OpenCV* baseado em árvore proposto por Viola e Jones (Viola, P. and Jones, M., 2001) para detecção de face, (CUIMEI et al., 2017) através da detecção de das formas da superfície da região de interesse com auxílio das teorias de *Wavelet* e *Haar*, que também pode ser utilizado para detectar outros tipos de objetos. O treinamento deste modelo é feito a partir de um conjunto de imagens positivas e negativas. As imagens positivas são aquelas que contém o objeto que se deseja encontrar, e as imagens negativas são as que não contém esse objeto.

3.5 Ajuste de Perspectiva

O ajuste de perspectiva em questão, foi desenvolvido com auxílio de técnicas de visão computacional de baixo custo de processamento em comparação com algoritmos mais avançados para ajuste de perspectiva. O modelo ajusta a perspectiva da imagem da placa através do uso de pré processamento com uso de gradiente na imagem, de maneira a avivar os contornos dos objetos, após este pré processamento, as linhas continuas e horizontais da imagem são detectadas com auxílio da transformada de hough.

A partir do momento que temos as linhas das imagens, realizamos uma filtragem para reduzir linhas que possuam angulações extremas, como as verticais, por exemplo. Após isso, a linha horizontal detectada corresponde à linha superior da placa de trânsito. Sua angulação é calculada tendo como base o eixo X, o centro da imagem é detectado e a imagem é rotacionada de acordo com o ângulo de correção calculado, realizando assim o ajuste de perspectiva na imagem da placa.

3.6 Tesseract-OCR

Tesseract é uma biblioteca de reconhecimento óptico de caracteres baseada em algoritmos de inteligência artificial como *Machine Learning* capaz de classificar texto em imagens e transcreve-los de maneira digital através da classificação individual dos caracteres lidos na imagem em questão. A ferramenta tem suporte para reconhecer mais de 100 idiomas, e é utilizada neste trabalho para o reconhecimento de caracteres de placas de licenciamento de trânsito, além do suporte ao uso de algoritmos de deep learning, tornando

os resultados de classificação de caracteres mais robusto, obtendo um arquivo de texto através de uma imagem.

Tesseract-OCR é uma ferramenta de reconhecimento ótico de caracteres de código aberto, disponibilizado sob a licença Apache 2.0. Neste trabalho é usado o *Pytesseract*, que é uma ferramenta de reconhecimento óptico de caracteres (OCR) para python.

3.7 Algoritmo de Heurística

Um algoritmo de heurística é um método de resolução de problemas que se baseia na experiência, intuição e no conhecimento prévio do problema em questão para encontrar soluções aproximadas e satisfatórias. Em outras palavras, é uma abordagem que busca encontrar uma solução viável, embora possa não ser a melhor solução ótima.

Algoritmos de heurística são frequentemente utilizados em problemas complexos, nos quais a busca pela solução exata é computacionalmente inviável. Em vez disso, os algoritmos de heurística procuram otimizar um critério de desempenho, como a eficiência, a qualidade ou a robustez da solução.

O algoritmo de heurística tem por finalidade fazer ajustes finos no texto resultante do reconhecimento de caracteres feito pelo *Tesseract-OCR*. Considerando que as placas brasileiras do novo formato Mercosul possuem a seguinte sequência de caracteres alfanuméricos: LLLDLDD, sendo L a representação de letra e D a representação do dígito numérico, o reconhecimento pode acarretar em erros, como por exemplo, o reconhecimento da letra O pelo dígito 0(zero), conforme a lógica apresentada na Figura 2.

Exemplos de algoritmos de heurística incluem o algoritmo de busca em profundidade, o algoritmo de busca em largura, o algoritmo genético, a busca tabu, a busca local, entre outros. Esses algoritmos podem ser aplicados em diversos campos, como engenharia, ciência da computação, economia, logística, entre outros, para resolver problemas complexos de maneira eficiente.

Algorithm 1 Pseudocódigo Heurística

```

arrayCaracteres ← placa
for indice=0 to tamanho(arrayCaracteres) do digito
  if indice = 0 or 1 or 2 or 4 then                                ▷ Posição das Letras
    if digito = 0 then
      digito = 'O'
    else if digito = 1 then
      digito = 'I'
    else if digito = 2 then
      digito = 'Z'
    else if digito = 4 then
      digito = 'A'
    else if digito = 5 then
      digito = 'S'
    else if digito = 6 then
      digito = 'G'
    else if digito = 7 then
      digito = 'T'
    else if digito = 8 then
      digito = 'B'
    end if
  else if indice = 3 or 5 or 6 then                                ▷ Posição dos Números
    if digito = 'O' then
      digito = 0
    else if digito = 'Q' then
      digito = 0
    else if digito = 'D' then
      digito = 0
    else if digito = 'I' then
      digito = 1
    else if digito = 'Z' then
      digito = 2
    else if digito = 'A' then
      digito = 4
    else if digito = 'S' then
      digito = 5
    else if digito = 'G' then
      digito = 6
    else if digito = 'T' then
      digito = 7
    else if digito = 'B' then
      digito = 8
    end if
  end if
end for

```

Figura 2 – Pseudocódigo do algoritmo de heurística

3.8 Métrica de Avaliação

3.8.1 Precisão - (*Accuracy*)

Accuracy (Precisão), é o número de ocorrências positivas em P dividido pelo número total de amostras N (FAWCETT, 2006). Ou seja, é a relação entre as respostas do algoritmo e o conjunto das possibilidades de erros. Essa medida avalia os acertos do algoritmo em relação ao total de amostras apresentadas, indicando desta forma, a proximidade dos resultados obtidos daqueles desejado. Podendo ser compreendida pela equação:

$$Accuracy = \frac{P}{P + N}. \quad (3.1)$$

4 Metodologia

Nesta seção é apresentada o conjunto de dados das imagens de veículos e suas placas e a metodologia proposta utilizadas neste trabalho.

4.1 Conjunto de Dados

O conjunto de dados utilizados neste estudo é composto por várias bases de imagens, desde imagens de placas geradas sinteticamente, a uma base inédita de imagens reais gerada no próprio estudo. Além das bases citadas, também é utilizada uma base de dados com imagens negativas, que são aquelas que não possuem o objeto a ser detectado e também necessárias para o treinamento do modelo. A composição das bases foi feita de maneira incremental, gerando as discussões e compondo os resultados do estudo.

4.1.1 Primeiro dataset

As imagens do dataset positivo geradas sinteticamente possuem um dataset de placas brasileiras composto por 3.832 imagens divididas em três subconjuntos de dados, todos com imagens de placas sintéticas com ruído artificial simulando sombra causada por árvores, sujeiras, etc., no formato Mercosul (RIBEIRO et al., 2019). O primeiro subconjunto de dados possui 2.925 imagens de câmeras de monitoramento de tráfego com resolução de 800 x 600 pixels. O segundo subconjunto de dados tem 592 imagens capturadas por uma câmera de 6 megapixels com resolução de 3.264px x 1.836px de um estacionamento na cidade de Natal, Brasil. O terceiro e último subconjunto é composto por 315 imagens aplicadas e recortadas do segundo subconjunto de dados. Neste trabalho é utilizado o primeiro subdataset do dataset sintético Monitoring (RIBEIRO et al., 2019) contendo 2.925 imagens.

4.1.2 Segundo dataset

Como contribuição também deste trabalho, foi gerado e disponibilizado uma nova base de dados chamada LPR-UFC.V1 (SOUZA et al., 2022) com 1.100 amostras de veículos com placas reais do novo formato padrão Mercosul. Estas imagens reais do dataset LPR-UFC.V1 foram utilizadas nos experimentos de teste de detecção e reconhecimento do modelo proposto por este estudo.

O banco de dados LPR-UFC.V1 possui imagens de diferentes ângulos e perspectivas. O processo de coleta foi realizado na cidade de Fortaleza, no Estado do Ceará (Brasil) por meio de captura de imagens em diferentes câmeras. (Modelos: Intebras e Mikvision)

configuradas com resolução de 1.920 x 1.080 pixels, bit rate de 8.192Kbps, codificação H.265 e taxa de atualização de 25fps. As dimensões das imagens obtidas variam de acordo com as dimensões dos crops para cada veículo. As imagens foram salvas no formato PNG (Portable Network Graphics) de 24 bits.

4.1.3 Terceiro dataset

Posteriormente o dataset LPR-UFC.V1 foi incrementando em 1.586 imagens a partir do dataset disponibilizado por (SOUZA et al., 2022), passando a ter 2.686 imagens de veículos com o novo modelo de placas do Mercosul, também gerando outra contribuição deste trabalho. As imagens do novo dataset LPR-UFC.V2 foram coletadas na cidade de Fortaleza, no estado do Ceará, sobre diferentes ângulos de perspectiva e câmeras. (Modelos: Intelbras e Hikvision) configurados com resolução de 1.920px x 1.080px, taxa de bits de 8.192Kbps, codificação H.265 e taxa de atualização de 25fps.

4.1.4 Quarto dataset

Dando continuidade às pesquisas, uma nova base de dados foi introduzida ao estudo. A nova base de dados utilizada é a RodoSol-ALPR (LAROCA E. V. CARDOSO; MENOTTI, 2022), composto por vinte mil imagens divididas em 4 subdatasets: 1 - cars-br: contendo cinco mil imagens de placas do modelo antigo que encontra-se em transição, 2 - cars-me: contendo cinco mil de placas do novo modelo Mercosul, 3 - motorcycle-br: contendo cinco mil imagens de placas de motocicleta do modelo brasileiro antigo e 4 - motorcycle-mr: contendo cinco mil imagens de placas de motocicletas do novo modelo Mercosul. Para os experimentos, apenas a base cars-me foi utilizada.

4.1.5 Quinto dataset

Para o conjunto de imagens negativas foi utilizada uma base de dados contendo mais de 102.000 imagens do Google Street View. O conjunto de dados abrange o centro da cidade e as áreas vizinhas de Pittsburgh, PA; Orlando, FL e parcialmente Manhattan, NY (ZAMIR; SHAH, 2014), todas com as imagens das placas dos veículos estão suprimidas. Para este estudo, um subconjunto de 35.658 foi selecionado para compor nossa base de dados de imagens negativas.

4.2 Método Proposto

Este estudo apresenta um novo método de detecção e reconhecimento de placas veiculares brasileiras do novo modelo do Mercosul. Considerando que o Brasil está passando por uma transição entre seu modelo de placa antiga e o novo modelo implantado a partir

de 2019 (RIBEIRO et al., 2019), o presente estudo elaborou uma proposta completa para detecção, classificação e reconhecimento do novo modelo de placas.




Figura 3 – Figura que ilustra a metodologia proposta por este estudo. Etapa 01 - Classificação da Placa: Classifica se a placa é um modelo brasileiro antigo ou um modelo novo do Mercosul. Etapa 02 - Ajuste de Perspectiva: Ajuste de inclinação usando a transformada de hough. Etapa 03 - Detecção de Placas: Detecção pelo modelo treinado com Haar Cascade. Etapa 04 - Reconhecimento de placas: Reconhecimento de caracteres usando Tesseract OCR. Etapa 05 - Heurística: Algoritmo heurístico para ajustar erros nas posições entre letras e dígitos. Fonte: O próprio autor.

4.2.1 Etapa 01 - Classificação

A primeira etapa do processo consiste na detecção e classificação entre as placas do modelo antigo e do novo modelo Mercosul, conforme apresentado na Figura 3 Etapa 01. A rede convolucional *Detectron2* foi treinada para detecção e classificação de duas classes: 1 - modelo brasileiro antigo de placas e 2 - novo modelo Mercosul exemplificados na Figura 1. Após o treinamento da rede com essas duas classes e a detecção das placas, é verificado se a imagem detectada existe na base de dados de imagens antigas. Se existir, é gerado

a informação de que aquela placa é antiga, tornando possível a aferição da acurácia da classificação.

Placas do modelo antigo são descartadas do experimento, haja vista já possuir bastantes estudos na literatura e não ser alvo deste estudo. As placas do novo modelo seguem para as próximas etapas do processo.

4.2.2 Etapa 02 - Ajuste de perspectiva

Dependendo do posicionamento das câmeras de monitoramento e do posicionamento dos veículos na via, as imagens capturadas podem estar em ângulos desfavoráveis para a detecção e reconhecimento de caracteres, comprometendo a qualidade destas importantes etapas do processo.

As placas classificadas como do novo modelo seguem para o ajuste de perspectiva conforme Figura 3 Etapa 02 4.2.2, onde é aplicado um algoritmo de ajuste de perspectiva utilizando da transformada de Hough para correção da inclinação da imagem resultante do posicionamento das câmeras.

4.2.3 Etapa 03 - Detecção

Após a etapa de ajuste de perspectiva, passamos para a etapa do processo de detecção da placa conforme Figura 3 Etapa 03 4.2.3. Nesta etapa é aplicado o *Haar Cascade* para detecção das placas. *Haar Cascade* é um método eficaz de detecção de objetos usando classificadores em cascata proposto por Viola e Jones em (Viola, P. and Jones, M., 2001).

O ajuste de perspectiva Figura 3 Etapa 02 4.2.2 se mostrou um aliado importante para a detecção das placas. Através do ajuste o *bounding box* resultante da detecção se enquadra mais precisamente na região da placa.

4.2.4 Etapa 04 - Reconhecimento

Concluído a etapa de detecção, o próximo passo é o reconhecimento dos caracteres das imagens das placas detectadas conforme Figura 3 Etapa 04 4.2.4. Nessa etapa é utilizado o pacote de reconhecimento óptico de código aberto *Tesseract-OCR*.

4.2.5 Etapa 05 - Heurística

Por fim, a última etapa do processo é a aplicação de um algoritmo de heurística no texto resultante do *Tesseract-OCR* para corrigir quaisquer reconhecimentos errôneos mencionadas na Etapa 05 4.2.4 da Figura 3.

Nas subseções a seguir, são apresentadas mais detalhadamente as abordagens de aplicadas neste estudo, sendo uma subseção para cada um dos experimentos realizados. Ao final de todos os experimentos, temos os os resultados da metodologia completa aplicada neste estudo.

5 Resultados e Discussão

Esta seção descreve como as experiências foram configuradas, bem como a evolução dos experimentos até a abordagem final. O trabalho aqui realizado foi composto por 4 experimentos descritos nas subseções a seguir.

As experiências foram realizadas, reproduzidas e testadas em laptops pessoais com as seguintes configurações: processador Intel Core i7 a 2,9 GHz, 8 GB de RAM, GPU NVIDIA GeForce GTX 1050 TI com Ubuntu 16.04.

5.1 Experimento 1

O novo modelo de placas adotado nos países do Mercosul foi recentemente disponibilizado no Brasil (RIBEIRO et al., 2019). Como resultado, ainda há um baixo número de veículos circulando com o novo padrão, o que significa que não há bancos de imagens públicas.

Devido a dificuldade de se encontrar, até então, base de dados públicas contendo imagens de veículos com placas no novo formato do Mercosul, este trabalho propõe uma abordagem de detecção e reconhecimento de placas e caracteres a partir de uma base de dados imagens geradas sintenticamente.

5.1.1 Detecção das placas

Nesta subseção, é explicado passo a passo o método usado no primeiro experimento para detecção de placas e reconhecimento de caracteres. Foi aplicado o algoritmo de detecção de objetos *Haar Cascade* para a detecção e segmentação da região de interesse em imagens do conjunto de dados mencionado no parágrafo 4.1.1. Em seguida, as imagens são pré-processadas e enviadas para o software OCR para detecção de texto. Posteriormente, o texto detectado passa por um algoritmo heurístico que ajusta os erros entre letras e dígitos, resultando no texto final.

Para treinar o Cascade, foram utilizadas imagens do subconjunto de dados de monitoramento 4.1.1. O treinamento foi feito utilizando a ferramenta *Cascade Trainer GUI tool (Version 3.3.1)* em 14 etapas. Na Tabela 1 está definida a quantidade de imagens positivas e negativas utilizadas em cada treinamento, sendo o utilizado neste experimento o modelo treinado em negrito. Na Figura 4 é mostrado exemplos de resultados de detecção de placas de veículos.

Redimensionar as imagens tem impacto no desempenho do treinamento de um

Tabela 1 – Quantidades e tamanho das imagens utilizadas nos treinamentos

Positivas	Negativas	Tamanhos Redimensionados							
28136	25193	40x13	80x29	120x39	240x78	360x107	480x156	600x195	800x260
31653	30000	40x13	80x29	120x39	240x78	360x107	480x156	600x195	800x260
38683	20000	40x13	80x29	120x39	240x78	360x107	480x156	600x195	800x260
38683	35658	40x13	80x29	120x39	240x78	360x107	480x156	600x195	800x260
21100	15000	40x13 80x29 120x39 180x59 240x78 360x107							
26615	35658	40x13	80x29	120x39	180x59	240x78	360x107	420x137	

classificador Haar Cascade. Isso porque se o redimensionamento for feito corretamente, ele pode ajudar a melhorar o desempenho do classificador, por exemplo, acelerando o treinamento ou tornando o modelo mais robusto a variações de tamanho dos objetos a serem detectados.



Figura 4 – Exemplos de detecção de placas nos veículos

5.1.2 Reconhecimento de caracteres das placas

Softwares de *optical character recognition* (OCR) são utilizados para converter caracteres em uma imagem em texto. Para obter melhores resultados, a imagem pode ser pré-processada, retirando ruídos que possam atrapalhar a conversão.

Para esta etapa, usamos o filtro gaussiano para o borramento da imagem e retirada de ruídos, o `adaptiveThreshold` para a binarização da imagem e erosão e dilatação para conectar falhas dos padrões escuros, que são os dígitos da placa e retornando ao padrão original executando a dilatação. Os resultados do pré-processamento podem ser vistos da Figura 5.

Ao utilizarmos o *Haar Cascade* treinado, é possível identificar a localização da placa do veículo na imagem de entrada. Verificar Figura 4. Na Figura 6 mostramos apenas a imagem da placa recortada da imagem original.



Figura 5 – Exemplo do pré-processamento das imagens detectadas.



Figura 6 – Exemplo de placas detectadas

Para otimizar o mecanismo de OCR, as imagens das placas detectadas são redimensionadas para 240x78 formando uma nova imagem. De forma empírica, criamos uma nova imagem a partir do pixel 23 até o 73 da altura e a partir do pixel 20 até o pixel 220 da largura, deixando apenas o centro da imagem Figura 7, onde estão apenas os dígitos da placa a ser passada para o Tesseract-OCR.



Figura 7 – Exemplo de placas detectadas e removendo as bordas e mantendo apenas a região de interesse onde estão os dígitos.

Ao final dos passos anteriores, na Figura 8 apresentamos exemplos de reconhecimento dos caracteres a partir das imagens das placas detectadas e pré-processadas.




Figura 8 – OCR Result.

5.1.3 Resultados e discussões

Para o treinamento dos classificadores, foram utilizadas 2.925 imagens do monitoramento de tráfego subconjunto de dados 4.1.1, replicando e modificando suas dimensões

para tornar o classificador capaz de encontrar imagens de diferentes tamanhos usando o software *Cascade Trainer GUI tool* (Versão 3.1.1). Das 2.925 imagens de placas, foram detectadas 2.452. No entanto, houveram 236 detecções parciais que foram removidas do experimento. Várias tentativas foram feitas em busca de uma melhor taxa de acerto, conforme Tabela 1.

A quantidade de imagens positivas e negativas utilizadas nos experimentos interferiu tanto na qualidade do resultado quanto no tempo de treinamento, que variou de um algumas horas a alguns dias.

Os trabalhos de (CORNETO et al., 2017), (SINGH; BHUSHAN, 2019) e (IZIDIO; FERREIRA; BARROS, 2018) serão usados para comparar os resultados, com o primeiro usando detecção via Haar Cascade, o segundo usando reconhecimento via Tesseract-OCR, e o terceiro baseado no detector de objetos YOLO de última geração. Os resultados finais do sistema proposto são apresentados na Tabela 2.

Tabela 2 – Apresentação de Diferentes modelos de detecção de placas com os respectivos resultados.

Método	Experimento	Acurácia (%)
Lofrano(CORNETO et al., 2017)	Base A	92.55%
Lofrano(CORNETO et al., 2017)	Base B	74.33%
Izidio(IZIDIO; FERREIRA; BARROS, 2018)	Custom	99.37%
Método Proposto	Monitoring	83.82%

Em (CORNETO et al., 2017) foram realizadas duas sessões de treinamento com duas bases de imagens, denominadas Base A e Base B. A detecção do resultado do nosso experimento foi de 83,82%, representando uma diminuição de 8,73% em relação à Base A e um aumento de 9,49% em comparação com à Base B. Em (IZIDIO; FERREIRA; BARROS, 2018), um conjunto de dados personalizado de 240 imagens foi usado no experimento com uma taxa de precisão de 99,37%, representando uma redução de 15,55%.

Para reconhecimento de caracteres, escolhemos aleatoriamente cem placas detectadas pelo *Haar Cascade*. As imagens tiveram o nome do arquivo alterado para o número da placa para comparação com o texto gerado pelo Tesseract-OCR. Como resultado, obtivemos uma precisão de 95,72%. Em comparação com (SINGH; BHUSHAN, 2019; IZIDIO; FERREIRA; BARROS, 2018), tivemos um aumento de 0,72% e uma redução de 1,28% na taxa de reconhecimento, respectivamente, conforme apresentando na Tabela 3

Tabela 3 – Apresentação dos resultados do reconhecimento de caracteres.

Método	Experimento	Acurácia (%)
(CORNETO et al., 2017)	ALPR	92.55%
(IZIDIO; FERREIRA; BARROS, 2018)	Custom	99.37%
Método Proposto	Proposto	95.72%

5.2 Experimento 2




Figura 9 – Fluxograma da metodologia proposta. A imagem ilustra o método proposto por este estudo. Nove etapas apresentam o modelo; são eles: Etapa 1 - Placas de Imagens do Mercosul Real, Etapa 2 - Classificador em Cascata de Imagens Sintéticas, Etapa 3 - Segmentação, Etapa 4 - Ajuste de Perspectiva, Etapa 5 - Pré-processamento, Etapa 6 - Tesseract OCR, Etapa 7 - Saída de Texto, Etapa 8 - Heurística e Etapa 9 - Saída de texto.

Neste experimento foi aplicado o modelo treinado no Experimento 1 5.1 com imagens geradas sinteticamente em uma nova base de dados LPR-UFC.V1 4.1.2 com

imagens reais inéditas desenvolvidas neste estudo.

Nesse sentido, este estudo apresenta uma nova abordagem para detecção e reconhecimento de caracteres baseada no treinamento de placas de modelo Mercosul sintéticas, testadas em modelos de placas reais do Mercosul. O dataset de placas reais LPR-UFC.V1 4.1.2 utilizadas neste estudo para os testes com o modelo treinado em placa sintéticas do Experimento 1 5.1 foram contribuições deste estudo buscando ampliar discussões acerca do uso do Haar-Cascade para a detecção de caracteres, com resultados promissores.

Como principais contribuições deste estudo, são abordados os diferentes contextos relevantes:

- Modelo treinado com imagens de placas sintéticas e testadas em imagens de placas reais, ambas do novo formato Mercosul.
- Reconhecimento de caracteres de placas do novo formato Mercosul.
- Uso do Haar-Cascade para detecções de placas em diferentes perspectivas.
- Nova abordagem de ajuste de perspectiva das placas.
- Detecção e reconhecimento de placas do Mercosul em diferentes ângulos de perspectiva usando Tesseract OCR.

Nas próximas subseções são apresentados os métodos de detecção e reconhecimento do uso de LRP nas placas do Mercosul, e explica as diferentes etapas desde o processo de detecção de placas de veículos até a extração e reconhecimento de caracteres. O método consiste em 9 etapas que são: Etapa 1 - Imagens de Placas de Carros do Mercosul Real, Etapa 2 - Classificador em Cascata de Imagens Sintéticas, Etapa 3 - Segmentação, Etapa 4 - Ajuste de Perspectiva, Etapa 5 - Pré-processamento, Etapa 6 - Tesseract-OCR, Estágio 7 - Resultado do Texto, Estágio 8 - Heurística, Estágio 9 - Resultado do Texto, conforme Figura 9.

5.2.1 Etapa de treinamento

A Figura 10 ilustra as diferentes etapas do treinamento; Etapas A, B e C. O conjunto de dados Monitoring (RIBEIRO et al., 2019) foi utilizado para treinar o modelo computacional, que contém 2.925 amostras de imagens sintéticas de placas veiculares do modelo Mercosul 4.1.1.

5.2.2 Etapa de testes

5.2.2.1 Etapa 1 - Placas reais do novo modelo Mercosul

Foi utilizado um banco de dados com imagens de veículos com placas reais do novo modelo Mercosul capturadas por câmeras fixas em ruas e avenidas da cidade de Fortaleza,




Figura 10 – Ilustração da Etapa de Treinamento: A. Conjunto de dados sintéticos, B. Treinamento e C. Modelos treinados com base em imagens sintéticas.

Brasil 4.1.2. A base é formada por imagens gravadas com diferentes perspectivas frontais e traseiras nos períodos da manhã e da tarde.

5.2.2.2 Etapa 2 - Modelo *Haar Cascade* treinado em imagens sintéticas

O modelo treinado com *Haar Cascade* com placas sintéticas foi aplicado ao banco de dados LPR-UFC.V1 apresentado em 4.1.2. Este banco de dados contém 1.100 amostras de imagens de diferentes perspectivas de veículos com placas reais do novo modelo Mercosul.

Foi aplicado o mesmo algoritmo treinado em (SABÓIA; FILHO, 2022) para a detecção de placas reais.

5.2.2.3 Etapa 3 - Detecção

Na etapa de detecção, as 1.000 imagens são passadas por um algoritmo que contém o modelo em cascata treinado em imagens sintéticas. Como resultado, outra imagem é gerada para cada imagem contendo apenas a região da imagem que contém a placa com tamanho de 240x78 conforme Figura 11.



Figura 11 – Ilustração do estágio de segmentação: imagens contando apenas a placa do veículo gerada a partir da imagem original.

5.2.2.4 Etapa 4 - Ajuste de perspectiva

Após detectar as placas e gerar uma nova imagem contendo apenas o recorte central da placa, é executado um algoritmo de ajuste de perspectiva, que corrige o ângulo de inclinação das imagens, conforme mostrado na Figura 12.



Figura 12 – Ilustração do estágio de ajuste de perspectiva: novas imagens geradas pela correção de inclinação das placas.

5.2.2.5 Etapa 5 - Pré-processamento

Na etapa de pré-processamento, algumas técnicas de processamento de imagem fornecidas pelo OPENCV são aplicadas para preparar a imagem a ser passada para o *Tesseract-OCR*.

Para suavizar e remover pequenos ruídos da imagem, é usado o filtro de desfoque gaussiano com um kernel 3x3. Em seguida, a imagem é binarizada usando o limiar adaptativo (*adaptive threshold*). O resultado da binarização é passado pelas operações

morfológicas de erosão seguida de dilatação para que pequenos espaços em branco nos dígitos sejam preenchidos para gerar melhores contornos. Os resultados do pré-processamento podem ser vistos na Figura 5.2.2.5.



Figura 13 – Ilustração da etapa de pré-processamento: As imagens passam por operações de suavização, binarização e operações morfológicas.

5.2.2.6 Etapa 6 - Tesseract OCR

Após o pré-processamento das imagens, iniciam-se as etapas de reconhecimento de caracteres. As imagens segmentadas e pré-processadas das placas reais do Mercosul são passadas para o pacote *Tesseract-OCR*, responsável pelo reconhecimento óptico de caracteres.

O *Tesseract-OCR* é uma ferramenta de reconhecimento óptico de caracteres de código aberto disponível sob a licença Apache 2.0. Neste trabalho, é utilizado o *PyTesseract*, que é uma ferramenta de reconhecimento óptico de caracteres (OCR) para python.

5.2.2.7 Etapa 7 - Resultado do reconhecimento de caracteres

Nesta etapa, temos o resultado do reconhecimento de caracteres das imagens Fig. 14. As placas de formato Mercosul são compostas por 7 caracteres seguindo o padrão: letra, letra, letra, dígito, letra, dígito e dígito. O reconhecimento do *Tesseract-OCR* às vezes pode falhar, por exemplo, identificar o número 0 (zero) onde deve identificar a letra O ou quando esperado a letra B e identificar o dígito 8.

5.2.2.8 Etapa 8 - Heurística

Um algoritmo heurístico é aplicado ao texto resultante para corrigir quaisquer detecções errôneas mencionadas na Etapa 7, após o reconhecimento por *Tesseract-OCR*.

Na Tabela 4 é apresentado o fluxo de substituições do algoritmo, corrigindo detecções equivocadas ao substituir letra por número e vice-versa.




Figura 14 – Imagem do resultado do reconhecimento de caracteres gerado pelo Tesseract-OCR.

Tabela 4 – Tabela de substituições do algoritmo de heurística.

Letra	Dígito	
O	↔	0
Q	→	0
D	→	0
I	↔	1
Z	↔	2
A	↔	4
S	↔	5
G	↔	6
T	↔	7
B	↔	8

5.2.2.9 Stage 9 - Resultado do reconhecimento

Nesta etapa, temos os resultados finais do reconhecimento de caracteres do método proposto, mostrado na Figura 15.




Figura 15 – Imagem com o resultado do reconhecimento de caracteres após passar pelo algoritmo de heurística.

5.2.3 Resultados e discussões

Esta subseção apresenta os resultados e uma discussão sobre o trabalho realizado pelo Experimento 5.2. Para entender melhor o discussão, dividimos em três subseções; Detecção e reconhecimento de caracteres (Testes em placas sintéticas), Detecção e Reconhecimento de Caracteres (Teste em Placas Reais e Placas Sintéticas) e, finalmente, Validação de Resultados em Base Real.

5.2.3.1 Detecção e reconhecimento de caracteres (Testes em placas sintéticas)

A tabela 5 apresenta diferentes modelos para detecção de LPR. Em ambos os trabalhos, buscamos apresentar estudos com diferentes soluções para o problema de detecção.

O modelo proposto por este estudo obteve uma acurácia de 90% para a detecção de placas modelo do Mercosul, em comparação com modelos que obtiveram valores semelhantes encontrados no estado da arte. Vale ressaltar que o modelo apresentado por (SABÓIA; FILHO, 2022) se apresenta como uma solução inovadora onde traz como base para seu estudo, treinamentos com o uso de placas sintéticas do novo modelo Mercosul,

Tabela 5 – Apresentação de diferentes resultados de detecção de placas.

Método	Experimento	ACC (%)
(CORNETO et al., 2017)	Base A	92.55%
(CORNETO et al., 2017)	Base B	74.33%
(IZIDIO; FERREIRA; BARROS, 2018)	Custom	99.37%
(SABÓIA; FILHO, 2022)	Monitoring	83.82%
Ajuste de Perspectiva	Monitoring	90.00%

trazendo novas soluções para diversos problemas. Em comparação com o método (SABÓIA; FILHO, 2022), é possível notar o ganho significativo baseado no método proposto por este estudo, trazendo robustez ao problema de perspectiva de diferentes ângulos de uma imagem. Conforme mostrado na Tabela 5.

Comparado com os resultados do (SABÓIA; FILHO, 2022), que utiliza imagens sintéticas de placas para seu treinamento e teste, o modelo proposto por este estudo apresentou uma solução baseada em ajuste de perspectiva para melhor detecção de regiões de placas por meio de processamento digital de imagens combinado com o método *Haar-Cascade* para reajuste e alinhamento de pontos de placas localizados na imagem. Superando, assim, (SABÓIA; FILHO, 2022) com uma diferença de precisão de 6,18% para a mesma base de teste contendo 100 amostras de imagens sintéticas, porém usando ajuste de perspectiva. Em alguns casos, como mostra a Figura 16 é possível notar diferentes ângulos da imagem, tornando o ajuste de perspectiva mais eficaz dentro do processo como parte do método proposto.

O experimento realizado com o método proposto nas imagens de teste por (SABÓIA; FILHO, 2022) apresentou ganhos relevantes para o alinhamento das placas detectadas, processo em que há um ganho mais significativo na etapa de reconhecimento de caracteres, etapa fundamental para identificação de caracteres. É nesta fase que o modelo traz resultados substanciais em relação ao processo sem o problema de alinhamento de perspectiva para reconhecer cada caractere contido na placa, como mostra a Figura 16. A figura mostra imagens diferentes do conjunto de dados de monitoramento de placas sintéticas razoavelmente alinhadas, pois são principalmente imagens frontais. Vale ressaltar que o problema de perspectiva é muito comum em conjuntos de dados de imagens reais para capturar diferentes ângulos de câmera e pontos estratégicos para monitoramento de captura. A Figura 17, apresenta diferentes imagens reais com diferentes ângulos de perspectiva e cenas sem controle do ambiente.

5.2.3.2 Detecção e reconhecimento de caracteres (Testes em placas reais e Placas Sintéticas)

Nesta subseção, são apresentados os resultados gerados pelo modelo proposto por este estudo e pelo modelo proposto por (SABÓIA; FILHO, 2022). A tabela 6 mostra o resultado gerado pelo autor, que apresenta 83,82% de acerto para a detecção de placas



Figura 16 – Exemplo de perspectiva das imagens sintéticas.



Figura 17 – Exemplo de perspectiva das imagens reais

sintéticas, onde o modelo utilizou imagens sintéticas também para o teste realizado com 100 imagens, obtendo ganhos significativos para modelos baseados em LPR.

Dentro deste mesmo objetivo, foi usado o mesmo método gerado baseado em

Tabela 6 – Comparação dos modelos de detecção - Imagens sintéticas e reais

Método	Experimento	ACC
Cyro (SABÓIA; FILHO, 2022)	Dataset sintético	83.82%
	Dataset real	90.00%

Método	Experimento	ACC
Ajuste de perspectiva	Dataset Sintético	90.00%
	Dataset real	90.00%

treinamento de imagens sintéticas para detecção de placas reais, o modelo treinado com imagens sintéticas foi capaz de obter resultados satisfatórios referente a imagens sintéticas de placas do Mercosul (Consideradas modelos novos em relação a novos datasets). Desta forma, como mostra o resultado da Tabela 6, o treinamento realizado no modelo baseado em imagens sintéticas de placas mercosul, conseguiu detectar mais placas reais, ou seja, placas verdadeiras de veículos. O resultado foi de 90% em relação a placas reais, contra 83% sobre as placas sintéticas. Para ambos os testes foram separadas 100 imagens reais e 100 imagens sintéticas. Isso se deu pelo fato de o método *Haar Cascade* ter aprendido diferentes texturas realçadas das imagens sintéticas baseados em contornos e linhas bem definidas dentro de seu processo, tornando a rede mais robusta com o treinamento baseado em 2.925 imagens sintéticas.

Ainda na Tabela 6, o método proposto por este estudo, apresentou uma nova abordagem para o problema de perspectiva da imagem dentro do processo de detecção e reconhecimento de caracteres. Para a detecção da placa, o modelo permaneceu com 90% de acurácia, tanto para as imagens sintéticas do experimento realizado por (SABÓIA; FILHO, 2022), quanto nas imagens reais do dataset de teste adquiridas por LPR-UFC.V1, mostrando assim a robustez do modelo.

A Tabela 7 apresenta os resultados de Reconhecimento dos Caracteres realizado pela etapa de identificação com método Tesseract OCR. Os resultados apresentaram valores equiparados em termos de similaridades do problemas de perspectivas. Ou seja, as imagens mostraram-se dentro do mesmo padrão com alinhamentos simétricos tornando o processo da etapa de alinhamento de perspectiva com pouca influência, já que as imagens encontravam-se em sua grande maioria, bem alinhadas, tanto nas imagens sintéticas, quanto nas imagens reais.

Ao observamos a Tabela 7, tanto o trabalho de (SABÓIA; FILHO, 2022), quanto o método proposto, apresentam-se com valores similares com diferença mínimas, equivalente a uma placa a mais reconhecida baseada nos caracteres reais. Porém, mostrando equivalência de valores relevância do alinhamento das placas para um melhor reconhecimento pelo modelo, já que grande parte das imagens são capturadas frontalmente sem grandes

Tabela 7 – Comparação dos modelos de reconhecimento de caracteres usando Tesseract OCR - Imagens sintéticas e reais.

Método	Experimento	ACC
Cyro (SABÓIA; FILHO, 2022)	Dataset Sintético	95,72%
	Dataset Real	83,01%

Método	Experimento	ACC
Proposed Perspective adjustment	Dataset Sintético	95,72%
	Dataset Real	83,13%

problemas de ângulos perspectivas. Assim como em ambos os testes nas placas sintéticas, obtendo os mesmos de valores 95,72%, pois em ambos os casos, mostram captura de placas em ângulos frontais por se tratar de imagem sintética na região sobreposta a placa do veículo.

Desta forma, a obtenção de maiores valores na métrica de acurácia, pode ser medido também por diferentes imagens de diferentes perspectivas, tornando o resultado mais próximo do cenário real, como é o caso do dataset LPR-UFC.V1, que trás diferentes ângulos e desafios de perspectivas.

5.2.3.3 Valiação dos resultados no dataset de imagens reais

A fim de validar o método proposto, foi realizado um teste com o Dataset LPR-UFC.V1 4.1.2 contendo 1 mil amostras de diferentes veículos e diferentes perspectivas de imagens reais de veículos com placas Mercosul. Baseado no método proposto que aborda o treinamento em imagens sintéticas de placas Mercosul, combinado ao método de ajuste de perspectiva. Foi realizado pós treinamento do modelo, um teste para detecção e reconhecimento dos caracteres nos mais diferentes problemas de perspectivas, com ângulos distintos, tornando o processo de detecção e identificação dos caracteres mais desafiador.

Os resultados apresentados na Tabela 8, foram realizadas em 1.000 amostras do dataset LPR-UFC.V1 4.1.2 que contém 1.100 imagens de diferentes placas Mercosul de veículos, com diferentes ângulos de perspectivas. Ao analisar o dataset, onde o teste realizado foi dividido em 10 arquivos de placas Mercosul, é possível perceber que os primeiros arquivos são compostos em sua grande maioria, por imagens fontais sem muito ajustes a serem feitos, se tratando de ajustes de perspectivas. Outra informação relevante, é que o fato de o arquivo 6 ao 10 de imagens de placas Mercosul de veículos, possuem em sua grande maioria com reais problemas de perspectivas com relevância para o problema específico, exceto o arquivo 6, que se assemelha aos arquivos 1 ao 5.

Desta forma, é possível identificar que os arquivos de teste do 6 ao 10 obtiveram valores superiores ao modelo sem ajuste de para detecção das placas de modelo Mercosul,

Tabela 8 – Apresenta a divisão do dataset UFC-LRP.V1: contendo 1 mil amostras de diferentes placas reais de Mercosul - Resultado da detecção.


Nº de imagens (Dataset LPR-UFC)		Sem ajuste	ACC	Com ajuste	ACC
Arquivo 1	100	90	90%	83	83%
Arquivo 2	200	167	83,5%	163	81,5%
Arquivo 3	300	259	86,3%	254	84,6%
Arquivo 4	400	356	89%	346	86,5%
Arquivo 5	500	453	90,6%	439	87,8%
Arquivo 6	600	552	92%	535	89,1%
Arquivo 7	700	626	89,4%	622	88,8%
Arquivo 8	800	649	81,1%	697	87,1%
Arquivo 9	900	680	75,5%	771	85,6%
Arquivo 10	1000	713	71,3%	856	85,6%

chegando a 10% de diferença nas placas dos arquivos 9 e 10, e 6% por cento contra o modelos sem ajuste de perspectiva referente ao arquivo 8.

Tabela 9 – Apresenta a divisão do UFC-LRP.V1: contendo 100 amostras de diferentes placas reais do Mercosul - Resultado do Reconhecimento.

Nº de Imanges (Dataset LPR-UFC)		ACC Sem ajuste	ACC Com ajuste
Arquivo 10	100	76,1%	81,8%

Figura 18 – Figura baseada na Tabela 8, mostrando os diferentes valores obtidos depois do ajuste de perspectiva.



A detecção de caracteres é um processo fundamental para o reconhecimento pertencentes as imagens capturadas no processo de detecção. Nesta etapa de teste foram utilizadas para o experimento 100 amostras com diferentes problemas de perspectiva. Foi aplicado a etapa de reconhecimento com uso do algoritmo Tesseract OCR para identificação dos caracteres. É possível notar que após o processo de alinhamento da placa pela etapa de ajuste de perspectivas, o modelo proposto conseguiu identificar mais caracteres de diferentes placas, tornando o modelo mais eficiente também para leitura e reconhecimento dos caracteres contidos após a etapa de qualificação, para placas reais de modelos Mercosul de veículos.

A Tabela 9 apresenta resultados do arquivo 10 baseado em diferentes amostras separadas do dataset LPR-UFC.V1. O lote contém 100 amostras de imagens reais e obteve ganhos significativos para reconhecimento de caracteres, com diferença de 5,7% após o processamento e alinhamento, tornando o modelo mais robusto para detecção de caracteres com base na mudança de perspectiva, conforme mostrado na Figura 18.

5.3 Experimento 3

Nesta seção será apresentada a metodologia usada para o processo de LPR aplicada a esse estudo. No trabalho apresentando por (SABÓIA; FILHO, 2022), um modelo Haar Cascade treinado com imagens sintéticas é aplicado em um conjunto de dados com imagens também sintéticas. Em (SOUZA et al., 2022), o mesmo modelo treinado em imagens sintéticas é aplicado a um conjunto de imagens reais. O método proposto neste trabalho é treinar o modelo Haar Cascade com imagens reais e aplicá-lo ao dataset de imagens reais.

Este trabalho busca ampliar as discussões sobre o uso do Haar Cascade como ferramenta de visão computacional para a detecção de placas, Tesseract OCR para o reconhecimento de caracteres, disponibilizando uma nova base de dados LPR-UFC contendo 2686 imagens de placas do Brasil do novo modelo Mercosul.

Como principais contribuições deste estudo, são abordados os diferentes contextos relevantes:

- Detecção de modelos de placas do Mercosul em imagens reais.
- Reconhecimento de caracteres do modelo de placa do Mercosul em imagens reais.
- Um estudo comparativo entre um modelo treinado com imagens de placas sintéticas e um modelo treinado com imagens de placas reais.
- Detecção e reconhecimento de placas do Mercosul em ângulos de perspectiva ajustados usando Tesseract OCR.
- Aumento do conjunto de dados LRP-UFC com mais 1.586 imagens reais de veículos com o novo modelo de placa Mercosul.

Nas próximas subseções são apresentados os métodos de detecção e reconhecimento do uso de LRP nas placas do Mercosul, e explica as diferentes etapas desde o processo de detecção de placas de veículos até a extração e reconhecimento de caracteres. O método consiste em 9 etapas que são: Etapa 1 - Imagens de Entrada do Conjunto de Dados com Imagens Reais, Etapa 2 - Modelo Haar-Cascade Treinado, Etapa 3 - Segmentação das Placas, Etapa 4 - Ajuste de Perspectiva, Etapa 5 - Pré-processamento das Imagens, Etapa 6 - Reconhecimento de Caracteres, Etapa 7 - Resultado do reconhecimento da Imagem em Texto, Etapa 8 - Algoritmo de Heurística, Etapa 9 - Resultado Final do Reconhecimento de Caracteres.

5.3.0.1 Etapa 1 - Imagens de Entrada do Conjunto de Dados com Imagens Reais

Nesta etapa uma nova base de dados foi construída contendo exclusivamente veículos com placas do novo formato Mercosul Figura 19 tanto com perspectiva frontal quanto com perspectiva traseira. A base de dados conta com 2.686 imagens, sendo 2.586 utilizadas no treinamento e 100 separadas para testes.



Figura 19 – Amostras de imagens de conjuntos de dados reais de diferentes veículos.

5.3.0.2 Etapa 2 - Modelo Haar-Cascade Treinado

O treinamento do modelo foi feita com as 2.586 imagens separadas para treinamento. Para isso, o software Cascade Trainer GUI tool (Version 3.3.1) foi utilizado. As imagens das placas aplicadas aos testes foram recortadas da imagem original contendo todo o veículo, em seguida as imagens apeans das placas foram redimensionadas para 7 tamanhos diferentes conforme Tabela 10, formando o base de imagens positivas, que são aquelas que contém o objeto a ser detectado. Para as imagens negativas, foi utilizada a mesma base usada em (SABÓIA; FILHO, 2022).

Tabela 10 – Trainamento do Haar-Cascade.

Posotivas	Negativas	Redimensionamentos						
17.962	35.568	60x16	80x22	100x27	120x32	140x38	160x44	180x49

5.3.0.3 Etapa 3 - Detecção das Placas

Nesta etapa as 100 imagens de veículos com placas do Mercosul separadas para testes são passadas pelo modelo treinado, resultado em novas imagens contendo apenas o recorte da placa Figura 20.



Figura 20 – Amostra da detecção em diferentes placas.

5.3.0.4 Etapa 4 - Ajuste de Perspectiva

Após a etapa de detecção, a imagem resultante é passada para o algoritmo de ajuste de perspectiva, onde corrige a inclinação e deixa a placa alinhada corretamente, conforme apresentado na Figura 21.



Figura 21 – Amostra de ajuste de perspectiva em diferentes placas. Compare com a Figura 20

5.3.0.5 Etapa 5 - Pré-processamento das Imagens

Na etapa de pré-processamento, as imagens das placas passam por uma série de funcionalidades disponibilizadas pela biblioteca OPENCV, onde é feita a conversão da imagem es escala de cinza, aplicação de filtros para suavização de ruídos, binarização a operações morfológicas para o fechamento de lacunas entre os dígitos Figura 22.



Figura 22 – Pré-processamento: imagem suavizada, binarizada e operações morfológicas aplicadas em diferentes placas.

5.3.0.6 Etapa 6 - Reconhecimento de Caracteres

O resultado do pré-processamento da imagem é enviado para a ferramenta de reconhecimento óptico de caracteres Tesseract-OCR, em sua versão python chamada de Pytesseract.

5.3.0.7 Etapa 7 - Resultado do reconhecimento da Imagem em Texto

Nesta etapa o Tesseract retorna o texto reconhecido da imagem Figura 23. É importante entender que a sequência das placas no novo formato Mercosul é composta por 3 letras, seguidas de 1 dígito, seguido de 1 letra, seguido de mais 2 dígitos, totalizando assim 7 caracteres por placa. Note que o tesseract pode se confundir entre letras, dígitos, letras para dígitos e vice-versa.




Figura 23 – Resulta do reconhecimento de caracteres em diferentes placas.

5.3.0.8 Etapa 8 - Algoritmo de Heurística

O formato das placas no novo modelo Mercosul segue o padrão com 7 dígitos na seguinte sequência: letra, letra, letra, número, letra, número, número. Por vezes o

reconhecimento de caracteres pode reconhecer uma letra quando se espera um número, como por exemplo a troca da letra O pelo Número 0. Para otimizar os resultados, um algoritmo de heurística é utilizado para efetuar as trocas de caracteres quando se espera letra e aparece dígito e vice-versa. A lógica do algoritmo encontra-se na Tabela 4.

5.3.0.9 Etapa 9 - Resultado Final do Reconhecimento de Caracteres

Como resultado do algoritmo de heurística, um novo texto resultante é informado, corrigindo falhas e otimizando os resultados de reconhecimento 24.




Figura 24 – Imagem com o resultado do reconhecimento de caracteres após passar pelo algoritmo de heurística.

5.3.1 Resultados e Discussões

Nesta seção será descrito os resultados e a discussão sobre dos experimentos realizados no estudo. No trabalho proposto por (SABÓIA; FILHO, 2022), um modelo usando o método Haar Cascade foi treinado utilizando-se de imagens geradas sinteticamente. No trabalho proposto por (SOUZA et al., 2022), esse mesmo modelo treinado com imagens sintéticas foi aplicado nos testes da base de dados de imagens reais. O método proposto deste trabalho é treinar um novo modelo com imagens reais e aplicá-lo novamente às imagens da base de dados do experimento 2 5.2. Abordaremos os resultados em duas subseções: Detecção e Reconhecimento de Caracteres.

5.3.1.1 Detecção

Para uma melhor compreensão, é importante destacar que o modelo de detecção treinado nesse experimento foi aplicado apenas à base de testes real do experimento 2 5.2.

Nos testes realizados sem o ajuste de perspectiva para a base real, o modelo treinado neste trabalho apresentou um resultado de 91.00% de acurácia. Houve ganho de 1.00% no modelo treinado na base real aplicado à base de testes real.

Já para os testes realizados com ajuste de perspectiva, o modelo treinado neste trabalho apresentou um resultado de 97.00% de acurácia. Também houve ganho, sendo um aumento de 7.00% no modelo treinado na base real aplicado à base de testes real. O ganho se mostrou mais elevado devido à base de dados real possuir maior quantidade de

placas inclinadas. A base de dados sintéticas, justamente por ser criada por computador, possui alinhamento mais homogêneo e menor quantidade de obstáculos para a detecção. Ambos resultados podem ser vistos na Tabela 11.

Tabela 11 – Modelos de detecção e seus respectivos resultados.

Sem Ajuste de Perespectiva	Treinamento	Testes	ACC (%)
Cyro M. G. Sabóia (SABÓIA; FILHO, 2022)	Dataset Sintético	Dataset Sintético	83.82%
Luís Fabrício de F. Souza (SOUZA et al., 2022)	Dataset Sintético	Dataset Real	90.00%
Método Proposto	Dataset Real	Dataset Real	91.00%

Com Ajuste de Perspectiva	Treino	Testes	ACC (%)
Cyro M. G. Sabóia (SABÓIA; FILHO, 2022)	Dataset Sintético	Dataset Sintético	90.00%
Luís Fabrício de F. Souza (SOUZA et al., 2022)	Dataset Sintético	Dataset Real	90.00%
Método Proposto	Dataset Real	Dataset Real	97.00%

5.3.1.2 Reconhecimento de Caracteres

Na Tabela 12 apresentamos os resultados do reconhecimento de caracteres. Para um melhor entendimento, é importante destacar que o reconhecimento foi aplicado apenas à mesma base de testes utilizada no 5.2. Tanto os resultados com o ajuste de perspectiva quanto o sem ajuste de perspectiva mostraram ganho em relação aos resultados apresentados por (SOUZA et al., 2022).

Para o reconhecimento de caracteres sem o ajuste de perspectiva, obtivemos um resultado de 86,05% contra 83.01%, apresentando um aumento de 3.04%. Para o reconhecimento de caracteres com o ajuste de perspectiva, o resultado foi 88.48% contra 83.13%, apresentando aumento de 5.35% ambos comparado aos resultados de (SOUZA et al., 2022).

Tabela 12 – Character Recognition models Comparison using Tesseract OCR - Real and synthetic images.

No Perspective Adjustment Method	Experiments	ACC
Cyro M. G. Sabóia (SABÓIA; FILHO, 2022)	Syntectic Dataset	95.72%
Luís Fabrício de F. Souza (SOUZA et al., 2022)	Real Dataset	83.01%
Proposed Method	Real Dataset	86.05%

With Perspective Adjustment Method	Experiments	ACC
Cyro M. G. Sabóia (SABÓIA; FILHO, 2022)	Syntectic Dataset	95.72%
Luís Fabrício de F. Souza (SOUZA et al., 2022)	Real Dataset	83.13%
Proposed Method	Real Dataset	88.48%

O modelo proposto, comparado aos métodos da literatura (SABÓIA; FILHO, 2022) e (SOUZA et al., 2022), trouxe resultados superiores e satisfatórios. Tendo como base os métodos encontrados para a mesma problemática, o método de ajuste de perspectiva tornou processo de detecção de placas mais robusto, ajudando no processo de identificação

dos caracteres em imagens reais. O desempenho foi medido pela acurácia baseada na quantidade de identificação de placas, bem como acerto nas identificações dos caracteres.

5.4 Experimento 4

O crescente aumento de tráfego nas cidades e rodovias impactada diretamente na crescente quantidade de soluções de monitoramento através de câmeras e sistemas inteligente. Não obstante, a introdução de novas tecnologias de carros autônomos também faz crescer a importância da visão computacional para a gestão de tráfego baseado na detecção e reconhecimento de placas veiculares (LEE; HALIM; WAHAB, 2022). O Brasil está passando atualmente por uma gradual mudança de formato de suas placas do modelo brasileiro antigo para o novo modelo Mercosul. Diante desse desafio, este trabalho propõe um estudo baseado na classificação de placas entre modelo antigo e o novo utilizando Detectron2, detecção por meio do método Haar Cascade, bem como o reconhecimento de caracteres com uso de ajuste de perspectiva.

Como principais contribuições desse trabalho, os diferentes tópicos abaixo são abordados:

- Classificação Detectron2 em modelos de placas antigas e novos modelos de placas Mercosul.
- Detecção de modelos de placas do Mercosul em imagens reais e sintéticas.
- Reconhecimento de caracteres em placas modelo Mercosul em diferentes ângulos de perspectiva usando Tesseract OCR.

Nas próximas subseções é apresentada a metodologia proposta deste trabalho, explicando as etapas de classificação dos diferentes tipos de placas em circulação no Brasil, detecção da placa e reconhecimento dos caracteres. Dividiremos o método nas seguintes etapas: Etapa 1 - Classificação das placas em modelo antigo e modelo novo, Etapa 2 - Ajuste de perspectiva, Etapa 3 - Detecção das placas, Etapa 4 - Reconhecimento de caracteres e Etapa 5 - Algoritmo de heurística.

Conforme apresentando na Figura 3, o fluxo de execução realizado nesta pesquisa inicia-se com a classificação das imagens em 2 tipos de classes: Modelo brasileiro antigo e o novo modelo Mercosul. Após a classificação das placas nos modelos citados, as placas de modelo antigo são descartadas para os demais processos, dando continuidade apenas às placas de modelo novo. O próximo passo é ajustar as inclinações que dificultam tanto o estágio de detecção quanto o estágio de reconhecimento de caracteres. Para isso, aplicamos a transformada Hough. Com o ajuste realizado, a etapa de detecção é acionada conforme Figura 25. O próximo passo após a detecção e segmentação da placa é o reconhecimento de caracteres pelo Tesseract OCR. O reconhecimento pode conter erros de posicionamento de letras e dígitos que é corrigido pelo próximo estágio de heurística conforme Tabela 4.



Figura 25 – Figura ilustrando o resultado do ajuste de perspectiva.

É importante salientar que nesse estudo as placas classificadas como sendo do novo modelo Mercosul seguem para as próximas etapas do processo, sendo as imagens classificadas como sendo do modelo brasileiro antigo descartadas para o restante do experimento. Já que o estudo proposto trás como solução para placas modelos mercosul, escasso na literatura até o atual momento, devido a falta de imagens reais para treinamento e testes.

5.4.1 Etapa 01 - Classificação das placas (Modelo brasileiro antigo e Novo modelo Mercosul)

Para este trabalho a rede convolucional Detectron2 foi adaptada para treinar um modelo de classificação com duas classes: 1 - modelo brasileiro antigo de placas e 2 - novo modelo Mercosul, exemplificados na Figura 1.

O treinamento do modelo de classificação e placas foi realizado utilizando duas bases de dados, sendo a base de placas do modelo brasileiro antigo RodoSol-ALPR 4.1.4 e a base de dados do novo modelo Mercosul LPR-UFC.V2 4.1.3. Para balancearmos as bases de dados para o treinamento, apenas 2.566 imagens selecionadas aleatoriamente do dataset RodoSol-ALPR 4.1.4, subdataset cars-br foram utilizadas. O treinamento foi realizado usando 80% das imagens para treinamento e 20% para testes, com 100.000 iterações.

5.4.2 Etapa 02 - Ajuste de perspectiva

Neste trabalho propomos o ajuste de perspectiva das imagens de placas que estão com uma inclinação desfavorável tanto para a detecção quanto para a interpretação pelo Tesseract-OCR utilizando a transformada de Hough. Na Figura 25, em 1, temos a imagem original capturada pelas câmeras, em 2 recortamos a área de interesse para evidenciar a angulação e em 3 a imagem da placa com a inclinação corrigida. O Resultado do processamento das imagens das placas por esse algoritmo é a correção da inclinação da

placa, ajudando tanto na detecção quanto no reconhecimento dos caracteres conforme resultados mostrados nas Tabelas 15 e 16 e representado graficamente na Figura 26.

5.4.3 Etapa 03 - Detecção das placas

O treinamento do modelo de detecção de placas foi feito utilizando 2.566 imagens positivas do dataset UFC-LPR.V2 4.1.3 e 35.568 imagens negativas 4.1.5. Para o conjunto de imagens positivas, 6 redimensionamentos diferentes com fator de Width x Height de 0,325 foram realizados, totalizando quinze mil trezentos e noventa e seis imagens conforme Tabela 13.

Tabela 13 – Treinamento Haar-Cascade.

Positivas	Negativas	Redimensionamentos					
15396	35568	60x19	80x26	100x32	120x39	140x45	160x52

Na Figura 25 mostramos como a detecção, e consecutivamente o reconhecimento, são beneficiados pelo ajuste de perspectiva. Ao realizar a correção de inclinação da placa, a caixa delimitadora da detecção enquadra corretamente a placa, possibilitando, ao recortar a imagem, que todos os caracteres estejam inteiros para a próxima etapa e reconhecimento dos caracteres.

5.4.4 Etapa 04 - Reconhecimento de caracteres

O reconhecimento óptico de caracteres (OCR) é um processo de se reconhecer caracteres a partir de uma imagem, sendo possível obter um arquivo de texto editável (DOME; SATHE, 2021). Para este trabalho, o reconhecimento de caracteres das placas é feito pela biblioteca Tesseract.

Tesseract OCR necessita que a imagem de entrada seja convertida em uma Imagem Binária para então ser processada em “Análise de componentes conectados” na qual a divisão de texto/palavras é realizada com contornos de caracteres. Os caracteres delineados são posteriormente enviados para o reconhecimento dos caracteres e processadas em um classificador adaptativo(AUDICHYA; SAINI, 2017).

A imagem da placa recortada a partir da caixa delimitadora encontrada na etapa de detecção da placa, antes de ser passada para o Tesseract-OCR para o reconhecimento de caracteres, passa por uma série de pré-processamentos disponibilizados pela biblioteca OPENCV, como binarização para conversão da imagem para preto e branco(binária), suavização para remoção de ruídos e operações morfológicas de abertura para a correção de possíveis falhas nos dígitos. Quanto melhor a qualidade da imagem, como tamanho, contraste, iluminação, etc, melhor será o resultado.

5.4.5 Etapa 05 - Algoritmo de heurística

As novas placa no novo formato Mercosul possuem 7 caracteres com a seguinte sequência: letra, letra, letra, dígito, letra, dígito e dígito. O resultado do reconhecimento de caracteres pelo Tesseract-OCR pode conter pequenos equívocos e reconhecer dígito onde deveria ser uma letra e vice-versa. Para corrigir essas eventuais trocas, um algoritmo de heurística é aplicado ao resultado de reconhecimento conforme Tabela 4.

5.4.6 Resultados e discussões

Nesta seção discutimos sobre os resultados alcançados em nosso experimento. Para uma melhor compreensão, dividimos a discussão em 3 subseções: Classificação, Detecção e Reconhecimento de caracteres.

5.4.6.1 Classificação

A rede Detectron2 é uma rede convolucional capaz de detecção regiões de interesse, delineando o objeto com uso de caixas delimitadoras, a rede convolucional pode ser adaptada para identificação do objeto. Uma vez rotulado o objeto, a rede classifica objetos entre duas classes diferentes, as placas brasileiras do modelo antigo e as placas brasileiras do novo formato Mercosul.

Nosso conjunto de dados foi definindo duas classes: Antiga e Mercosul. Para cada imagem, a classificação fornece um valor que indica a precisão da placa ser daquele modelo que foi rotulado como antigo ou novo, então a acurácia de detecção do da etapa de classificação obteve a média dos valores de precisão de cada imagem fornecida. Como resultado, o modelo obteve 95.48% de acurácia conforme apresentamos na Tabela. 14.

Tabela 14 – Classificação de placas brasileiras com Detectron2.

Classificação	ACC (%)
Proposto	95.48%

Uma vez treinada os modelos com as referidas classes, modelo placa nova e modelo placa antiga, foram realizadas os testes com 20% das imagens dos datasets com diferentes tipos de placas. Assim, o modelo treinado obteve uma acurácia relevante se tratando de imagens reais. A rede convolucional foi capaz de identificar com precisão as diferentes características das placas, tornando o modelo eficaz para identificação do tipo de placas Mercosul e placas antigas.

5.4.6.2 Detecção


No modelo de detecção proposto por este estudo, um novo modelo com 17 estágios foi treinado usando imagens reais do novo modelo de placas do Mercosul usando o dataset LPR-UFC.V2 4.1.3 redimensionadas para 6 tamanhos diferentes conforme Tabela 13.

O modelo treinado neste estudo obtiveram testes aplicados tanto à base de dados sintética quanto à base de dados real, com ajuste de perspectiva e sem ajuste de perspectiva, apresentadas por (SABÓIA; FILHO, 2022) e (SABÓIA et al., 2022), conforme Tabela 15. Os experimentos realizados mostraram ganhos relevantes na detecção das placas quando aplicado o ajuste de perspectiva nas imagens devido o ajuste de perspectiva corrigir a distorção na imagem e tornar as placas de veículos mais alinhadas e uniformes, o que facilita a detecção pelo haar-cascade. Essa abordagem se mostrou bastante promissora em otimizar os resultados.

Tabela 15 – Modelos de detecção de placas e seus respectivos resultados.

Sem ajuste de perspectiva	Treino	Teste	ACC (%)
Método Proposto	Dataset Real	Dataset Sintético	83.96%
	Dataset Real	Dataset Real	93.00%
Cyro M. G. Sabóia (2022) (SABÓIA; FILHO, 2022)	Dataset Sintético	Dataset Sintético	83.82%
Luís Fabrício de F. Souza (2022) (SOUZA et al., 2022)	Dataset Sintético	Dataset Real	90.00%
Cyro M. G. Sabóia (2022) (SABÓIA et al., 2022)	Dataset Real	Dataset Real	91.00%
Com ajuste de perspectiva	Treino	Teste	ACC (%)
Método Proposto	Dataset Real	Dataset Sintético	92.61%
	Dataset Real	Dataset Real	98.00%
Cyro M. G. Sabóia (2022) (SABÓIA; FILHO, 2022)	Dataset Sintético	Dataset Sintético	90.00%
Luís Fabrício de F. Souza (2022) (SOUZA et al., 2022)	Dataset Sintético	Real Dataset	90.00%
Cyro M. G. Sabóia (2022) (SABÓIA et al., 2022)	Dataset Real	Dataset Real	97.00%

Figura 26 – Representação gráfica dos modelos de detecção de placas e seus respectivos resultados.



O modelo treinado com a base de dados de imagens reais e aplicadas às imagens sintéticas sem ajuste de perspectiva obteve 83.96% de acurácia, uma diferença de ganho de apenas 00.14% em relação ao treinamento do modelo com base de dados de imagens sintéticas apresentado por (SABÓIA; FILHO, 2022), essa similaridade dos resultados se deve à boa qualidade das imagens do dataset LPR-UFC.V2 (SABÓIA et al., 2022), que contém imagens com as bordas das placas bem definidas como as imagens geradas sinteticamente naturalmente possuem. Quando aplicada às imagens com ajuste de perspectiva, o

ganho de detecção do trabalho poposto neste artigo aumenta, passando de 90.00% para 92.61%, um acréscimo de 02.61%.

Ao ser aplicado o modelo treinado com a base de dados de imagens reais e aplicadas à base de testes de imagens também reais, o resultado apresenta uma melhor evolução, passando de 91.00% para 93.00% sem o ajuste de perspectiva e de 97.00% para 98.00% com o ajuste de perspectiva, apresentando um aumento de 02.00% e 01.00% respectivamente.

O fato de este estudo ter feito diversas comparações entre os cruzamentos dos modelos treinados entre a base de dados de imagens sintéticas e a base de dados de imagens reais mostrou que ao utilizar imagens reais para o treinamento do modelo torna os resultados da detecção mais promissores. Isso se deve ao modelo aprender detalhes importantes que as imagens reais possuem, como sombra, sujeiras, angulação da câmera em relação ao objeto capturado, dentre outras oclusões.

5.4.6.3 Reconhecimento de caracteres

Os resultados apresentados na Table 16 mostram que o reconhecimento de caracteres do método proposto obteve um pior desempenho se comparado com o trabalho de (SABÓIA; FILHO, 2022). Essa piora se deve ao fato das imagens sintéticas possuírem imagens com realce diferentes e com contornos definidos, se tratando de desenhos com bordas destacadas 5.4.4, como contraste, delimitação mais precisa dos contornos da placa e iluminação homogênea.

Entretanto, os resultados do reconhecimento de caracteres sem ajuste de perspectiva e com ajuste de perspectiva obtiveram ganhos de 4.70% e 4.33% respectivamente em relação aos resultados apresentados por (SOUZA et al., 2022) e ganho de 01.66% e uma perda de 01.02% respectivamente em relação aos resultados apresentados por (SABÓIA et al., 2022). Essa variação de ganho e perda nos resultados de reconhecimento está diretamente relacionada à qualidade das imagens das placas detectadas 5.4.3, pois não obrigatoriamente o método do Tesseract-OCR irá fazer o reconhecimento corretamente.

Considerando que o novo modelo de placas Mercosul possui 7 dígitos e a ordem dos caracteres são letra, letra, letra, dígito, letra, dígito e dígito, a etapa 05 da Figura 3 realiza a correção de eventuais trocas de dígitos conforme Tabela 4.

A Tabela 16 apresenta diferentes trabalhos encontrados no estado da arte, que propõem o reconhecimento dos caracteres por meio do uso das mesmas bases de dados utilizadas nos testes deste estudo proposto. O modelo proposto apresentou ganhos relevantes com uso do ajuste de perspectiva.

Tabela 16 – Comparação dos modelos de reconhecimento de caracteres usando Tesseract OCR - Imagens reais e sintéticas.

Sem ajuste de perspectiva	Experimentos	ACC
Método Proposto	Dataset Real	87.71%
Cyro M. G. Sabóia (2022) (SABÓIA; FILHO, 2022)	Dataset Sintético	95,72%
Luís Fabrício de F. Souza (2022) (SOUZA et al., 2022)	Dataset Real	83,01%
Cyro M. G. Sabóia (2022) (SABÓIA et al., 2022)	Dataset Real	86,05%
With Perspective Adjustment Method	Experiments	ACC
Proposed Method	Dataset Real	87.46%
Cyro M. G. Sabóia (2022) (SABÓIA; FILHO, 2022)	Dataset Sintético	95,72%
Luís Fabrício de F. Souza (2022) (SOUZA et al., 2022)	Dataset Real	83,13%
Cyro M. G. Sabóia (2022) (SABÓIA et al., 2022)	Dataset Real	88.48%

5.5 Discussão

O presente estudo promoveu uma abordagem completa de ALPR em placas brasileiras do novo Formato Mercosul. Os experimentos iniciaram-se quando ainda não se tinha bases de dados públicas e placas do modelo Mercosul, tornando as pesquisas com este foco escassas.

No primeiro momento, uma base de dados com imagens sintéticas 4.1.1 foi utilizada para treinar um modelo específico para o novo formato de placas que estava se iniciando. No segundo momento, uma nova base de dados UFC-LPR.V1 4.1.2 com imagens reais foi disponibilizada por este estudo, sendo uma das primeiras a se tornarem públicas. O modelo treinado com imagens sintéticas foi aplicado nos testes com imagens reais para avaliação dos impactos de um modelo treinado com imagens não reais.

Dando continuidade aos experimentos, a base de dados UFC-LPR.V1 foi incrementada com mais imagens 4.1.3, diversificando ainda mais amostragem de dados tanto com perspectivas dianteiras quanto com perspectivas traseiras. Um novo modelo foi treinado utilizando-se dessa nova base de dados, passando tanto o treino quanto os testes a serem feitos com imagens reais.

Tabela 17 – Evolução dos treinamentos com imagens sintéticas e reais.

Experimento	Treino	Teste
1	Dataset Sintético	Dataset Sintético
2	Dataset Sintético	Dataset Real
3	Dataset Real	Dataset Real
4	Dataset Real	Dataset Real

Como inovação, o estudo também propôs uma abordagem de classificação automática das imagens em duas classes: placas brasileiras do formato antigo e placas do novo

formato Mercosul. O resultado apontou 95,48% de acurácia na classificação, tornando o método ALPR proposto relevante e totalmente automático.

Por fim, este trabalho propôs um ALPR completo, desde a classificação das imagens em duas classes(modelo brasileiro antigo e novo modelo Mercosul), passando pela detecção e finalizando com o reconhecimento dos caracteres. A Tabela 17 traz a abordagem utilizada em cada um dos experimentos.

Os métodos de detecção e reconhecimento aplicados neste estudo possuem particularidades que tornam os resultados interessantes de serem analisados. A discussão dos resultados podem ser divididas em duas seções: Detecção e Reconhecimento de Caracteres. A evolução dos resultados podem ser vista na Tabela 18.

Tabela 18 – Resultados dos experimentos

Detecção			
Sem ajuste de perspectiva	Treino	Teste	ACC (%)
Experimento 1	Dataset Sintético	Dataset Sintético	83.82%
Experimento 2	Dataset Sintético	Dataset Real	90.00%
Experimento 3	Dataset Real	Dataset Real	91.00%
Experimento 4	Dataset Real	Dataset Real	93.00%
Com ajuste de perspectiva	Treino	Teste	ACC (%)
Experimento 1	Dataset Sintético	Dataset Sintético	90.00%
Experimento 2	Dataset Sintético	Dataset Real	90.00%
Experimento 3	Dataset Real	Dataset Real	97.00%
Experimento 4	Dataset Real	Dataset Real	98.00%

Reconhecimento		
Sem ajuste de perspectiva	Datasets	ACC (%)
Experimento 1	Dataset Sintético	95.72%
Experimento 2	Dataset Real	83.01%
Experimento 3	Dataset Real	86.05%
Experimento 4	Dataset Real	87.71%
Com ajuste de perspectiva	Datasets	ACC (%)
Experimento 1	Dataset Sintético	95.72%
Experimento 2	Dataset Real	83.13%
Experimento 3	Dataset Real	88.48%
Experimento 4	Dataset Real	87.46%

5.5.1 Detecção

A Figura 27 traz a representação gráfica dos resultados de detecção apresentados na Tabela 18. Como podemos observar, os resultados do Experimento 4 5.4 obtiveram relevantes ganhos em relação aos demais experimentos. Isso se deve ao treinamento o modelo ter sido feito na base de dados UFC-LPR.V2 4.1.3, que possui maior diversidade de imagens com perspectivas de captura traseira e dianteira, e posicionamento de câmeras.




Figura 27 – Uma representação de plotagem dos resultados de detecção sem ajuste e com ajuste de perspectiva da Tabela 18.

5.5.2 Reconhecimento de Caracteres

A Figura 28 traz a representação gráfica dos resultados de reconhecimento de caracteres apresentados na Tabela 18.

Os resultados apresentados no experimento 1 mostram que o reconhecimento de caracteres em imagens sintéticas se mostrou bastante elevado. Isso se deve às características das imagens serem melhores delineadas, com contornos bem definidos e não possuírem oclusões relevantes que afetem o desempenho. Quando o reconhecimento passa a ser feito em imagens reais, a perda, mesmo que parcial, dessas características impactam diretamente os resultados. Os experimento 2, 3 e 4 possuem resultados bastantes semelhantes, tanto com o ajuste de perspectiva quanto sem o ajuste de perspectiva. Embora o ajuste de perspectiva traga um melhor desempenho na detecção das placas, isso não obrigatoriamente deve se refletir no reconhecimento, pois aumentando a quantidade de placas detectadas, aumenta-se, também, a possibilidade de ocorrer mais erros no reconhecimento.




Figura 28 – Uma representação de plotagem dos resultados de reconhecimento de caracteres sem ajuste e com ajuste de perspectiva da Tabela 18.

6 Conclusão

O estudo proposto traz uma nova abordagem totalmente automática de ALPR em placas do novo formato Mercosul. Atualmente há dois modelos de placas em vigência no Brasil, tornando um desafio a separação das imagens com placas do formato antigo e do novo formato. Além disso, a captura das imagens possuem angulações diferentes devido aos diferentes posicionamentos das câmeras nas vias, criando outro desafio de se conseguir corrigir essa angulação. O novo modelo trouxe como uma abordagem eficiente, um método de ajuste de perspectiva pós captura da placa em imagens digitais. O Estudo abordou diferentes comparações baseadas em modelos com treinamentos por meio de imagens sintéticas e imagens reais.

A abordagem que utilizamos neste estudo foi, a partir do momento que ainda não tínhamos uma base de dados pública de imagens de placas reais do novo formato Mercosul, o uso de uma base de dados de imagens sintéticas 4.1.1 para o início dos experimentos com o treinamento do modelo de detecção e reconhecimento. Com a continuidade dos estudos, nosso trabalho disponibilizou, se não a primeira, umas das primeiras bases de dados de placas do Mercosul com imagens reais.

Nosso método foi capaz de, sem a necessidade de intervenção humana na separação de dados, classificar o conjunto de imagens relevantes para o estudo, ajustar as inclinações das placas nas imagens, detectar e reconhecer os caracteres automaticamente. Além disso, trouxe resultados que permite uma análise acerca dos modelos treinados com imagens sintéticas e reais.

Em nossos experimentos no decorrer deste estudo, diversas combinações foram utilizadas em busca dos melhores resultados. O modelo foi capaz de classificar as placas veiculares detectadas em; placas antigas e placas novas(modelo Mercosul), obtendo uma acurácia de 95.48%. O modelo de detecção treinado e testado com imagens reais obteve acurácia de 93,00% sem o ajuste de perspectiva e 98,00% com o ajuste de perspectiva, mostrando um relevante ganho quando do uso dessa técnica. Para o reconhecimento de caracteres, o ganho na detecção impacta diretamente os resultados, tendo leves variações tanto sem quanto com ajuste de perspectiva. O estudo manteve a equivalência entre os resultados de leitura e identificação dos caracteres apresentados nas placas capturadas, atingindo 87.46% de acurácia. Concluindo assim a eficácia do modelo proposto capaz de detectar com precisão, classificar com eficiência e identificar os caracteres com eficácia de forma totalmente automática.

O ajuste de perspectiva se mostrou um grande aliado na detecção das placas, mas que nem sempre trará melhoras para o reconhecimento. Observamos que o aumento de

placas detectadas, não obrigatoriamente refletirá no aumento do reconhecimento. Isso se deve ao fato de se ter mais caracteres para reconhecer, permitindo que mais erros ocorram e, consecutivamente, diminua a acurácia dos resultados.

Alguns pontos podem ser observados como pontos de melhorias para trabalhos futuros. Propomos soluções de novos problemas, como imagens de placas de motos, diferentes oclusões, imagens noturnas, tipos de câmeras para diferentes problemas e utilização de diferentes métodos de classificação e detecção.

Referências

ALBAWI, S.; MOHAMMED, T. A.; AL-ZAWI, S. Understanding of a convolutional neural network. *2017 International Conference on Engineering and Technology (ICET)*, p. 1–6, 2017. Citado na página 25.

ANGRA, S.; AHUJA, S. Machine learning and its applications: A review. *2017 International Conference on Big Data Analytics and Computational Intelligence (ICBDAC)*, p. 57–60, 2017. Citado na página 35.

AUDICHYA, M.; SAINI, J. A study to recognize printed gujarati characters using tesseract ocr. *Engineering, Technology and Applied Science Research*, v. 5, p. 1505–1510, 09 2017. Citado na página 70.

BENSOUILAH, M.; ZENNIR, M. N.; TAFFAR, M. An alpr system-based deep networks for the detection and recognition. *ICPRAM*, p. 204–211, 2021. Citado na página 24.

CIUNTU, V.; FERDOWSI, H. Real-time traffic sign detection and classification using machine learning and optical character recognition. *2020 IEEE International Conference on Electro Information Technology (EIT)*, p. 480–486, 2020. Citado na página 23.

CORNETO, G. L. et al. A new method for automatic vehicle license plate detection. *IEEE Latin America Transactions*, v. 15, n. 1, p. 75–80, 2017. Citado 2 vezes nas páginas 50 e 58.

CORONADO, E.; CEBRIAN-MARQUEZ, G.; RIGGIO, R. Enabling computation offloading for autonomous and assisted driving in 5g networks. *2019 IEEE Global Communications Conference (GLOBECOM)*, p. 1–6, 2019. Citado na página 24.

CUIMEI, L. et al. Human face detection algorithm via haar cascade classifier combined with three additional classifiers. *2017 13th IEEE International Conference on Electronic Measurement Instruments (ICEMI)*, p. 483–487, 2017. Citado na página 37.

DANGI, R. S. et al. Efficient and robust indian number plate recognition through modified and tuned lprnet. *ICDSMLA 2020*, Springer, p. 115–129, 2022. Citado na página 32.

DIAS, C.; JAGETIYA, A.; CHAURASIA, S. Anonymous vehicle detection for secure campuses: A framework for license plate recognition using deep learning. *2019 2nd International Conference on Intelligent Communication and Computational Techniques (ICCT)*, p. 79–82, set. 2019. Citado na página 25.

DOMÉ, S.; SATHE, A. P. Optical charater recognition using tesseract and classification. *2021 International Conference on Emerging Smart Computing and Informatics (ESCI)*, p. 153–158, 2021. Citado 2 vezes nas páginas 25 e 70.

DUTTA, K. et al. Improving cnn-rnn hybrid networks for handwriting recognition. *2018 16th International Conference on Frontiers in Handwriting Recognition (ICFHR)*, p. 80–85, 2018. Citado na página 25.

- ELLEUCH MOHAMED; JRABA, S. K. M. The effectiveness of transfer learning for arabic handwriting recognition using deep cnn. *Journal of Information Assurance and Security*, v. 8, p. 085–093, 2021. Citado na página 33.
- FAWCETT, T. An introduction to roc analysis. *Pattern recognition letters*, Elsevier, v. 27, n. 8, p. 861–874, 2006. Citado na página 40.
- FERNANDES, L. S. et al. A robust automatic license plate recognition system for embedded devices. In: CERRI, R.; PRATI, R. C. (Ed.). *Intelligent Systems*. Cham: Springer International Publishing, 2020. p. 226–239. ISBN 978-3-030-61377-8. Citado 2 vezes nas páginas 23 e 32.
- GAI, R. et al. A summary of 5g applications and prospects of 5g in the internet of things. *2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)*, p. 858–863, 2021. Citado na página 24.
- GANAI, M. A.; HU, M. et al. Ensemble deep learning: A review. *arXiv preprint arXiv:2104.02395*, 2021. Citado na página 36.
- GLADENCE, L. et al. Traffic sign recognition - autonomous driverless vehicles. *2022 6th International Conference on Trends in Electronics and Informatics (ICOEI)*, p. 86–92, 2022. Citado na página 23.
- HILPERT, M. et al. A new approach for inferring traffic-related air pollution: use of radar-calibrated crowd-sourced traffic data. *Environment international*, Elsevier, v. 127, p. 142–159, 2019. Citado na página 23.
- HOSSAIN, M. A. et al. Number plate recognition system for vehicles using machine learning approach. *International Conference on Innovative Computing and Communications*, p. 799–814, 2021. Citado na página 32.
- IBADOV, S. et al. Algorithm for detecting violations of traffic rules based on computer vision approaches. *MATEC Web of Conferences*, v. 132, p. 05005, 01 2017. Citado na página 23.
- IZIDIO, D. M. F.; FERREIRA, A. P. A.; BARROS, E. N. S. An embedded automatic license plate recognition system using deep learning. *2018 VIII Brazilian Symposium on Computing Systems Engineering (SBESC)*, p. 38–45, 2018. Citado 2 vezes nas páginas 50 e 58.
- JAIN, K.; GUPTA, M.; ABRAHAM, A. A review on privacy and security assessment of cloud computing. *Journal of Information Assurance and Security*, v. 16, p. 161–168, 01 2021. Citado na página 24.
- KESSENTINI, Y. et al. A two-stage deep neural network for multi-norm license plate detection and recognition. *Expert Systems with Applications*, v. 136, p. 159–170, 2019. ISSN 0957-4174. Citado na página 23.
- KIRAN, V. K.; PARIDA, P.; DASH, S. Vehicle detection and classification: A review. In: ABRAHAM, A. et al. (Ed.). *Innovations in Bio-Inspired Computing and Applications*. Cham: Springer International Publishing, 2021. p. 45–56. ISBN 978-3-030-49339-4. Citado na página 31.

- KIRILLOV, A. et al. *PointRend: Image Segmentation As Rendering*, June 2020. Citado na página 37.
- LAROCA E. V. CARDOSO, D. R. L. V. E. R.; MENOTTI, D. On the cross-dataset generalization in license plate recognition. *International Conference on Computer Vision Theory and Applications (VISAPP)*, p. 166–178, 2022. Citado na página 42.
- LEE, Y. Y.; HALIM, Z. A.; WAHAB, M. N. A. License plate detection using convolutional neural network–back to the basic with design of experiments. *IEEE Access*, v. 10, p. 22577–22585, 2022. Citado 2 vezes nas páginas 24 e 68.
- LOURIDAS, P.; EBERT, C. Machine learning. *IEEE Software*, v. 33, n. 5, p. 110–115, 2016. Citado na página 35.
- LUNA, A. C. et al. License plate recognition for stolen vehicles using optical character recognition. *ICT Analysis and Applications*, Springer, p. 575–583, 2022. Citado na página 24.
- Menon, Aiswarya and Omman, Bini. Detection and recognition of multiple license plate from still images. *2018 International Conference on Circuits and Systems in Digital Enterprise Technology (ICCSDET)*, p. 1–5, dez. 2018. Citado na página 31.
- MOLINA-MORENO, M.; GONZALEZ-DIAZ, I.; MARIA, F. Diaz-de. Efficient scale-adaptive license plate detection system. *IEEE Transactions on Intelligent Transportation Systems*, IEEE, v. 20, n. 6, p. 2109–2121, 2018. Citado na página 23.
- NETO, E. C. et al. Brazilian vehicle identification using a new embedded plate recognition system. *Measurement*, v. 70, p. 36–46, 2015. ISSN 0263-2241. Citado na página 23.
- PALEKAR, R. R. et al. Real time license plate detection using opencv and tesseract. *2017 International Conference on Communication and Signal Processing (ICCSP)*, p. 2111–2115, abr. 2017. Citado na página 25.
- PHAM, V.; PHAM, C.; DANG, T. Road damage detection and classification with detectron2 and faster r-cnn. *2020 IEEE International Conference on Big Data (Big Data)*, p. 5592–5601, 2020. Citado na página 36.
- PIRGAZI, J.; SORKHI, A. G.; KALLEHBASTI, M. M. P. An efficient robust method for accurate and real-time vehicle plate recognition. *Journal of Real-Time Image Processing*, Springer, v. 18, n. 5, p. 1759–1772, 2021. Citado na página 31.
- QI, S. et al. Review of multi-view 3d object recognition methods based on deep learning. *Displays*, Elsevier, v. 69, p. 102053, 2021. Citado na página 36.
- QIAN, H.; XU, J.; ZHOU, J. Object detection using deep convolutional neural networks. *2018 Chinese Automation Congress (CAC)*, p. 1151–1156, 2018. Citado na página 25.
- RIAZ, W. et al. Yolo based recognition method for automatic license plate recognition. *2020 IEEE International Conference on Advances in Electrical Engineering and Computer Applications(AEECA)*, p. 87–90, 2020. Citado na página 26.
- RIBEIRO, V. et al. Brazilian mercosur license plate detection: a deep learning approach relying on synthetic imagery. *2019 IX Brazilian Symposium on Computing Systems Engineering (SBESC)*, p. 1–8, 2019. Citado 7 vezes nas páginas 26, 27, 32, 41, 43, 47 e 52.

SABÓIA, C. M. G.; FILHO, P. P. R. Brazilian mercosur license plate detection and recognition using haar cascade and tesseract ocr on synthetic imagery. In: ABRAHAM, A. et al. (Ed.). *Intelligent Systems Design and Applications*. Cham: Springer International Publishing, 2022. p. 849–858. ISBN 978-3-030-96308-8. Citado 13 vezes nas páginas 32, 53, 57, 58, 60, 61, 63, 64, 66, 67, 72, 73 e 74.

SABÓIA, C. M. G. et al. Fully automatic lpr method using haar cascade and perspective adjustment for real mercosur license plates. *Intelligent Systems Design and Applications*, Springer, 2022. Citado 3 vezes nas páginas 72, 73 e 74.

SALIMULLINA, A. D.; BUDANOV, D. O. Computer vision system for speed limit traffic sign recognition. *2022 Conference of Russian Young Researchers in Electrical and Electronic Engineering (ElConRus)*, p. 415–418, 2022. Citado na página 23.

SBORZ, G. A. M. et al. A custom processor for an fpga-based platform for automatic license plate recognition. *2019 32nd Symposium on Integrated Circuits and Systems Design (SBCCI)*, p. 1–6, 2019. Citado na página 24.

SHARMA, H.; HAQUE, A.; BLAABJERG, F. Machine learning in wireless sensor networks for smart cities: a survey. *Electronics*, MDPI, v. 10, n. 9, p. 1012, 2021. Citado na página 35.

SINGH, J.; BHUSHAN, B. Real time indian license plate detection using deep neural networks and optical character recognition using lstm tesseract. p. 347–352, 2019. Citado na página 50.

SOUZA, L. F. de F. et al. New approach to the detection and recognition of brazilian mercosur plates using haar cascade and tesseract ocr in real images. *Journal of Information Assurance and Security*, v. 17, p. 144–153, 2022. Citado 8 vezes nas páginas 41, 42, 63, 66, 67, 72, 73 e 74.

VI, G. V.; FAUDZI, A. A. b. M. A study on different techniques in alpr system: The systems performance analysis. In: NASIR, A. F. A. et al. (Ed.). *Recent Trends in Mechatronics Towards Industry 4.0*. Singapore: Springer Singapore, 2022. p. 617–627. ISBN 978-981-33-4597-3. Citado na página 24.

Viola, P. and Jones, M. Rapid object detection using a boosted cascade of simple features. *Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. CVPR 2001*, v. 1, p. I–I, abr. 2001. Citado 2 vezes nas páginas 37 e 44.

WU, Y. et al. *Detectron2: A PyTorch-based modular object detection library*. 2019. Disponível em: <[https://ai.facebook.com/blog/-detectron2-a-pytorch-based-modular-object-detection-library-/](https://ai.facebook.com/blog/-detectron2-a-pytorch-based-modular-object-detection-library/)>. Citado na página 37.

XU, J. et al. Contrasting the direct use of data from traffic radars and video-cameras with traffic simulation in the estimation of road emissions and pm hotspot analysis. *Transportation Research Part D: Transport and Environment*, Elsevier, v. 62, p. 90–101, 2018. Citado na página 23.

YOUSEFI, E. et al. Real-time scale-invariant license plate detection using cascade classifiers. *2019 IEEE Conference on Multimedia Information Processing and Retrieval (MIPR)*, p. 399–402, 2019. Citado na página 31.

ZAMIR, A. R.; SHAH, M. Image geo-localization based on multiplenearest neighbor feature matching usinggeneralized graphs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 36, n. 8, p. 1546–1558, 2014. Disponível em: <http://www.cs.ucf.edu/~aroshan/index_files/Dataset_PitOrlManh/>. Citado na página 42.

ZHANG, C. et al. License plate recognition system based on opencv. Springer, p. 251–256, 2021. Citado na página 24.