



CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS  
CURSO DE ENGENHARIA DE COMPUTAÇÃO

# **CLASSIFICAÇÃO DE FAIXAS HORIZONTAIS DE TRÂNSITO UTILIZANDO TÉCNICAS DE VISÃO COMPUTACIONAL**

**ÉDER CRISTÓVÃO COTA DOS SANTOS**

Orientador: Odilon Corrêa da Silva

TIMÓTEO  
JULHO DE 2022

**ÉDER CRISTÓVÃO COTA DOS SANTOS**

**CLASSIFICAÇÃO DE FAIXAS HORIZONTAIS DE  
TRÂNSITO UTILIZANDO TÉCNICAS DE VISÃO  
COMPUTACIONAL**

Trabalho de Conclusão de Curso (Graduação) apresentado ao Curso de Engenharia de Computação do Centro Federal de Educação Tecnológica de Minas Gerais, como requisito parcial para a obtenção do título de Bacharel em Engenharia de Computação.

Orientador: Odilon Corrêa da Silva

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS  
CURSO DE ENGENHARIA DE COMPUTAÇÃO  
TIMÓTEO  
JULHO DE 2022

Éder Cristóvão Cota dos Santos

**CLASSIFICAÇÃO DE FAIXAS HORIZONTAIS DE TRÂNSITO UTILIZANDO TÉCNICAS  
DE VISÃO COMPUTACIONAL**

Trabalho de Conclusão de Curso  
apresentado ao Curso de Engenharia de Computação  
do Centro Federal de Educação Tecnológica de  
Minas Gerais, campus Timóteo, como requisito  
parcial para obtenção do título de Engenheiro de  
Computação.

Trabalho aprovado. Timóteo, 14 de julho de 2022:

---

Prof. Me. Odilon Corrêa da Silva  
Orientador

---

Prof. Dr. Elder de Oliveira Rodrigues  
Professor Convidado

---

Prof. Dr. Lucas Pantuza Amorim  
Professor Convidado

Timóteo  
2022



Emitido em 05/09/2022

**CÓPIA DE FOLHA DE ASSINATURAS Nº 1/2022 - DCCTM (11.63.05)**

**(Nº do Protocolo: NÃO PROTOCOLADO)**

*(Assinado digitalmente em 05/09/2022 17:18 )*

ELDER DE OLIVEIRA RODRIGUES  
PROFESSOR ENS BASICO TECN TECNOLOGICO  
DCCTM (11.63.05)  
Matrícula: 1694225

*(Assinado digitalmente em 08/09/2022 22:11 )*

LUCAS PANTUZA AMORIM  
PROFESSOR ENS BASICO TECN TECNOLOGICO  
DCCTM (11.63.05)  
Matrícula: 2897411

*(Assinado digitalmente em 05/09/2022 01:45 )*

ODILON CORREA DA SILVA  
PROFESSOR ENS BASICO TECN TECNOLOGICO  
DCCTM (11.63.05)  
Matrícula: 2794495

Para verificar a autenticidade deste documento entre em <https://sig.cefetmg.br/documentos/> informando seu número:  
**1**, ano: **2022**, tipo: **CÓPIA DE FOLHA DE ASSINATURAS**, data de emissão: **05/09/2022** e o código de  
verificação: **acd4360279**

Dedico este trabalho a minha mãe Vânia que se dedicou muito para a formação da minha educação e ao meu pai Éber que me ensinou a persistir nos estudos.

# Agradecimentos

Primeiramente, sou grato a Deus por ter me mostrado o caminho certo para a minha formação e para a minha vida. A minha família que compreendeu todos os momentos que tive de dedicação aos estudos em detrimento do lazer em família.

Também agradeço aos meus amigos João Vitor, Gabriel Felipe, Kayque Netto e André Luiz que me ajudaram muito durante a minha formação e tornou a rotina de estudos mais animada.

Agradeço também aos professores do ensino técnico e do ensino superior do CEFET, nos quais tive uma grande inspiração que lecionam com o brilho no olhar e o prazer de ensinar.

Ao meu orientador pelo entendimento de todas as dificuldades enfrentadas no desenvolvimento deste trabalho, pela paciência, pela agilidade e pelo conhecimento transmitido.

Por fim, agradeço a banca composta pelo Lucas Pantuza e Elder que foram circunspectos com os detalhes e que ajudaram a apurar este trabalho.

*“Olhai para as aves do céu, que nem se-  
meiam, nem segam, nem ajuntam em celeiros;  
e vosso Pai celestial as alimenta.” (Mateus  
6:26)*

# Resumo

A colisão frontal de veículos é a principal causa de acidentes fatais no trânsito. Muitas empresas investiram em tecnologias para evitar este tipo de acidente. Entre estas tecnologias estão os Sistemas Avançados de Assistência ao Condutor e os Sistemas de Direção Automatizada. Assim, neste trabalho, é proposto e avaliado um método para identificação e classificação das faixas horizontais de trânsito utilizando técnicas de visão computacional e também é avaliado o comportamento no processamento de imagens de rodovias brasileiras. Para a validação da solução, foram utilizados 5 bases de dados, sendo 2 delas de trabalhos correlatos e 3 de rodovias brasileiras retiradas de vídeos disponibilizados na *internet* de forma pública. A taxa de acerto atingida pelo método varia de 77,66% a 89,33%, e em média foi atingido o valor de 82,80% para os diferentes tipos de faixas de trânsito. A linguagem escolhida para o desenvolvimento foi Python e a biblioteca de visão computacional OpenCV.

**Palavras-chave:** OpenCV, Visão Computacional, Python, Transformada de Hough, Filtro de Sobel.

# Abstract

Head-on vehicle collisions are the leading cause of fatal traffic accidents. Many companies have invested in technologies to prevent this type of accident. Among these technologies, these include Advanced Driver Assistance Systems and Steering Systems Automated. Thus, in this work, it is proposed and evaluated a method to identify and classification of horizontal traffic lanes using computer vision techniques and the behavior in image processing of Brazilian highways is also evaluated. For the validation of the solution, 5 databases were used, 2 of them of works related and 3 from Brazilian highways taken from videos made available on the internet by public form. The hit rate achieved by the method varies from 77.66% to 89.33%, and on average the value of 82.80% was reached for the different types of traffic lanes. The language chosen for development was Python and the OpenCV computer vision library.

**Keywords:** OpenCV, Computer Vision, Python, Hough Transform, Sobel Filter.

# Lista de Figuras

Figura 1 – Faixas de fluxo e ultrapassagem normalizadas pelo Contran. . . . .	7
Figura 2 – Faixas de único sentido e e exemplos de aplicações. . . . .	7
Figura 3 – Processo para o processamento de imagens. . . . .	8
Figura 4 – Imagem original no espaço de cores RGB. . . . .	9
Figura 5 – Resultado da aplicação do filtro gaussiano com diferentes valores de $\sigma$ . . . . .	10
Figura 6 – Seleção da região de interesse. . . . .	10
Figura 7 – Segmentação no espaço de cores RGB. . . . .	11
Figura 8 – Aplicação do filtro Sobel. . . . .	12
Figura 9 – Resultado da aplicação do filtro de detecção das bordas de Canny. . . . .	13
Figura 10 – Comparação entre o método de Sobel e de Canny. . . . .	14
Figura 11 – Mapeamento de pontos de borda no Espaço de Hough. . . . .	15
Figura 12 – Representação alternativa de uma linha e sua correspondência no Espaço de Hough. . . . .	16
Figura 13 – Aplicação do filtro Sobel. . . . .	16
Figura 14 – Reconhecimento e classificação das faixas de trânsito. . . . .	17
Figura 15 – Exemplo da classificação e identificação das faixas feito por Paula e Jung (2015). . . . .	18
Figura 16 – Resultados de detecção da faixa selecionada feito por Cheng et al. (2010) . . . . .	19
Figura 17 – Detecção e classificação as faixas de trânsito feito por Zang et al. (2018). . . . .	20
Figura 18 – Fluxo de procedimentos utilizados para a identificação e classificação das linhas de sinalização de trânsito. . . . .	22
Figura 19 – Posição da câmera para o registro das imagens. . . . .	23
Figura 20 – Demonstração do limite de observação. . . . .	24
Figura 21 – Área limite da região de interesse. . . . .	25
Figura 22 – Imagem convertida para escala monocromática recortada da área de interesse. . . . .	25
Figura 23 – Efeito blur aplicado sobre a imagem com escala de cores monocromática. . . . .	26
Figura 24 – Filtro de Sobel aplicado sobre a imagem com escala de cores monocromática. . . . .	27
Figura 25 – Comparação dos resultados dos algoritmos de detecção de bordas e o resultado do método de Hough. . . . .	28
Figura 26 – Linhas duplicadas identificadas pelo método de Hough. . . . .	29
Figura 27 – Mescla de segmentos não sobrepostos. . . . .	30
Figura 28 – Mescla de segmentos parcialmente sobrepostos. . . . .	31
Figura 29 – Mescla de segmentos totalmente sobrepostos. . . . .	31
Figura 30 – Linhas horizontais identificadas pelo método de Hough. . . . .	32

Figura 31 – Identificação das faixas horizontais. . . . .	32
Figura 32 – Diagrama para identificação das faixas horizontais. . . . .	33
Figura 33 – Definição dos pontos $r'_1$ e $r''_1$ . . . . .	34
Figura 34 – Centro da ROI para identificação das faixas à esquerda e a direita. . . . .	34
Figura 35 – Diagrama de fluxo para classificação das faixas. . . . .	35
Figura 36 – Esquema do funcionamento do classificador C1. . . . .	36
Figura 37 – Ilustração das possíveis maneiras em que ocorre a falha na detecção de uma linha. . . . .	37
Figura 38 – Faixas horizontais que dividem a ROI. . . . .	37
Figura 39 – Demonstração dos grupos de faixa localizadas a esquerda e a direita do veículo. . . . .	38
Figura 40 – Estrutura dos arquivos que contém os dados reais. . . . .	42
Figura 41 – Captura de um quadro do vídeo "clip_iPad_DMA190414_". . . . .	42
Figura 42 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C1 para o vídeo 1. . . . .	43
Figura 43 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C2 para o vídeo 1. . . . .	44
Figura 44 – Captura de um quadro do vídeo 'clip_iPad_DMA190414_' classificado pela solução. . . . .	45
Figura 45 – Captura de um quadro do vídeo do segundo experimento em baixa luminosidade. . . . .	46
Figura 46 – Captura de um quadro do vídeo em baixa luminosidade . . . . .	46
Figura 47 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C1 para o vídeo 2. . . . .	47
Figura 48 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C2 para o vídeo 2. . . . .	48
Figura 49 – Captura de um quadro do vídeo do terceiro experimento. . . . .	49
Figura 50 – Captura de um quadro do vídeo do terceiro experimento com a classificação de faixas. . . . .	49
Figura 51 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C1 para o vídeo 3. . . . .	50
Figura 52 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C2 para o vídeo 3. . . . .	50
Figura 53 – Captura de um quadro do vídeo do quarto experimento. . . . .	52
Figura 54 – Captura de um quadro do vídeo do quarto experimento com a classificação de faixas. . . . .	52
Figura 55 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C1 para o vídeo 4. . . . .	53

Figura 56 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C2 para o vídeo 4. . . . .	53
Figura 57 – Captura de um quadro do vídeo do quinto experimento. . . . .	55
Figura 58 – Captura de um quadro do vídeo do quinto experimento com a classificação de faixas. . . . .	55
Figura 59 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C1 para o vídeo 5. . . . .	56
Figura 60 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C2 para o vídeo 5. . . . .	56

# Lista de Tabelas

Tabela 1 – Distribuição de acidentes por causa. . . . .	2
Tabela 2 – Resultado de todos os cinco experimentos submetidos a solução apresentada. . . . .	21
Tabela 3 – Resultado da classificação das faixas com ruídos. . . . .	39
Tabela 4 – Estrutura da matriz de confusão para uma tarefa de classificação multi-classe. . . . .	40
Tabela 5 – Abreviação das classificações das faixas. . . . .	41
Tabela 6 – Abreviação das classificações das faixas. . . . .	41
Tabela 7 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 1.	43
Tabela 8 – Matriz de confusão da faixa à direita do classificador C1 para o vídeo 1.	43
Tabela 9 – Matriz de confusão da faixa à esquerda do classificador C2 para o vídeo 1.	44
Tabela 10 – Matriz de confusão da faixa à direita do classificador C2 para o vídeo 1.	45
Tabela 11 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 3.	47
Tabela 12 – Matriz de confusão da faixa à direita do classificador C1 para o vídeo 2.	47
Tabela 13 – Matriz de confusão da faixa à esquerda do classificador C2 para o vídeo 2.	47
Tabela 14 – Matriz de confusão da faixa à direita do classificador C2 para o vídeo 2.	48
Tabela 15 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 3.	50
Tabela 16 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 3.	51
Tabela 17 – Matriz de confusão da faixa à esquerda do classificador C2 para o vídeo 3.	51
Tabela 18 – Matriz de confusão da faixa à direita do classificador C2 para o vídeo 3.	51
Tabela 19 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 4.	53
Tabela 20 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 4.	54
Tabela 21 – Matriz de confusão da faixa à esquerda do classificador C2 para o vídeo 4.	54
Tabela 22 – Matriz de confusão da faixa à direita do classificador C2 para o vídeo 4.	54
Tabela 23 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 5.	56
Tabela 24 – Matriz de confusão da faixa à direita do classificador C1 para o vídeo 5.	57
Tabela 25 – Matriz de confusão da faixa à esquerda do classificador C2 para o vídeo 5.	57
Tabela 26 – Matriz de confusão da faixa à direita do classificador C2 para o vídeo 5.	57
Tabela 27 – Tabela com o resultado de todos os cinco experimentos submetidos a solução apresentada. . . . .	58

# Lista de Abreviaturas e Siglas

ADS	Sistemas de Condução Automatizados
ADAS	Sistemas Avançados de Assistência ao Motorista
AGNU	Assembleia Geral das Nações Unidas
CAS	Sistema de Prevenção de Colisões
Contran	Conselho Nacional de Trânsito
CFM	Conselho Federal de Medicina
FE	Faixa à esquerda
FD	Faixa à direita
LDWS	Sistema de Alerta de Saída de Faixa
OMS	Organização Mundial da Saúde
ONG	Organização não Governamental
ONU	Organização das Nações Unidas
OPAS	Organização Pan Americana da Saúde
PRF	Polícia Rodoviária Federal
PIB	Produto Interno Bruto
SNT	Sistema Nacional de Trânsito
SUS	Sistema Único de Saúde

# Sumário

<b>1 – Introdução</b>	<b>1</b>
1.1 Justificativa	3
1.2 Objetivos	5
1.2.1 Objetivo Geral	5
1.2.2 Objetivos Específicos	5
<b>2 – Fundamentação Teórica</b>	<b>6</b>
2.1 Tipos de marcações e cores	6
2.2 Processamento Digital de Imagens	8
2.3 Pré-processamento	9
2.3.1 Conversão para escala de cinza	9
2.3.2 Desfoque Gaussiano	9
2.3.3 Região de Interesse	10
2.4 Segmentação de Imagens	11
2.4.1 Filtro Sobel	11
2.4.2 Detecção das bordas de Canny	12
2.4.3 Canny vs Sobel	13
2.4.4 Transformada de Hough	14
2.5 Reconhecimento e Interpretação	16
2.6 Biblioteca OpenCV	17
<b>3 – Trabalhos Relacionados</b>	<b>18</b>
<b>4 – Desenvolvimento</b>	<b>21</b>
4.1 Aquisição de Imagens	23
4.2 Pré-Processamento	23
4.2.1 Seleção da área de interesse	24
4.2.2 Conversão para a Escala de Cinza	25
4.2.3 Desfoque Gaussiano	26
4.3 Segmentação	26
4.3.1 Operador de Sobel	26
4.3.2 Utilização da Transformada de Hough	27
4.3.3 Eliminação de segmentos colineares	29
4.3.4 Eliminação de segmentos horizontais	31
4.4 Extração de Características	32
4.4.1 Agrupamento dos segmentos de acordo com a distância entre grupos	33

4.4.2	Agrupamento dos segmentos de acordo com a posição do veículo . . . . .	34
4.5	Classificação dos grupos de linhas . . . . .	35
4.5.1	Classificador C1 . . . . .	36
4.5.2	Classificador C2 . . . . .	37
4.6	Estabilização da classificação . . . . .	39
<b>5</b>	<b>– Resultados Experimentais . . . . .</b>	<b>40</b>
5.1	Matriz de confusão . . . . .	40
5.2	Validação do processamento das imagens . . . . .	41
5.3	Experimento 1 . . . . .	42
5.4	Experimento 2 . . . . .	45
5.5	Experimento 3 . . . . .	49
5.6	Experimento 4 . . . . .	52
5.7	Experimento 5 . . . . .	55
5.7.1	Avaliação dos resultados . . . . .	58
<b>6</b>	<b>– Conclusão . . . . .</b>	<b>59</b>
	<b>Referências . . . . .</b>	<b>61</b>

# 1 Introdução

Os acidentes de trânsito chegam a matar 3,4 mil pessoas por dia nas estradas mundialmente e milhões de pessoas são feridas ou adquirem alguma deficiência todos os anos. Com isto, a Organização Mundial da Saúde (OMS) juntamente com a aliança global de Organizações Não Governamentais (ONGs) estão adotando medidas para prevenir os acidentes de trânsito em todo o mundo ([NAÇÕES UNIDAS BRASIL, 2015](#)).

Em março de 2010, a Assembleia Geral das Nações Unidas (AGNU) lançou uma resolução que define o período de 2011 a 2020 como sendo a "Década de ações para a segurança no trânsito". Este documento foi baseado em um estudo da OMS que contabilizou em 2009, aproximadamente 1,3 milhões de mortes por acidente de trânsito em 178 países. Sendo que destas 50 milhões de pessoas sobreviveram com sequelas ([SENADO FEDERAL, 2013](#)). O acidente de trânsito é a nona causa de mortes em todo o mundo e fere de 20 a 50 milhões de pessoa por ano. Esta resolução define algumas etapas para o aumento na segurança das rodovias de maneira a exigir maior grau de rigorosidade na legislação a fim de dar mais proteção a grupos mais vulneráveis, como ciclistas e pedestres ([NAÇÕES UNIDAS BRASIL, 2011](#)). Entre algumas das medidas citadas no portfólio publicado pela [OPAS/OMS \(2015\)](#) estão:

- Promover e apoiar projetos, programas e iniciativas que estão relacionadas com a redução de mortes por acidentes de trânsito;
- Apoiar a qualificação da informação sobre o índice mortalidade no trânsito;
- Apoiar a qualificação de profissionais no tema sobre a redução do índice mortalidade no trânsito;
- Sistematizar e produzir conhecimentos para dar visibilidade a experiências inovadoras sobre a Segurança no Trânsito.

No Brasil, os acidentes de trânsito causam cinco mortes por hora segundo um relatório do Conselho Federal de Medicina [CFM \(2019\)](#). No período entre 2008 e 2016, o número de vítimas que morreram nas estradas e ruas do país foram em mais de 368 mil pessoas. O CFM fez um balanço entre os anos de 2009 a 2018 que apontou que os acidentes de trânsito deixaram mais de 1,6 milhões de pessoas feridas e aproximadamente R\$ 3 bilhões de custo ao Sistema Único de Saúde (SUS).

As lesões que são ocasionadas nas rodovias geram uma grande perda econômica para o país e para as famílias. Geralmente, essas perdas decorrem de custos de reabilitação, investigação das causas do acidente, perda de produtividade da vítima e entre outras despesas. Os acidentes de trânsito chegam a custar em média para os países 3% do seu Produto Interno Bruto (PIB) (OPAS/OMS, 2019).

No ano de 2020, o número de mortes em rodovias federais em todo o Brasil aumentou em 8% durante o período do carnaval. E segundo o balanço da Operação Carnaval 2020, realizado pela Polícia Rodoviária Federal (PRF), foi registrado um aumento de 6% de feridos em relação a 2019. Entre as causas dos acidentes mais comuns durante este período é o de atropelamento de pessoas e a saída de pista que foram responsáveis por 68% das mortes. Ao todo, a PRF registrou 1.213 acidentes, 1.574 feridos e 91 mortes. Este balanço concluiu que 87% das mortes poderiam ser evitadas, pois a causa preliminar foi apontada relacionada com a conduta dos motoristas e pedestres (AGÊNCIA BRASIL, 2020).

Tabela 1 – Distribuição de acidentes por causa.

	Acidentes	Pessoas envolvidas	Mortes
Defeito mecânico em veículo	3.732	7.170	116
Defeito na via	973	1.939	47
Desobediência à sinalização	8.490	22.559	981
Dormindo	2.483	5.502	311
Falta de atenção	26.963	64.064	1.852
Ingestão de álcool	5.813	13.187	353
Não guardar distância de segurança	4.214	12.065	105
Ultrapassagem indevida	1.173	3.805	328
Velocidade incompatível	6.028	13.106	701
Animais na Pista	1.527	2.793	90
Outras	6.050	12.842	449

Fonte: Atlas da Acidentalidade no Transporte Brasileiro (ATLAS, 2019).

Na Tabela 1, as causas 'Desobediência à sinalização', 'Dormindo', 'Falta de atenção' e 'Ultrapassagem indevida' somam 39mil acidentes, o que equivale 57,94% dos acidentes de trânsito totais no ano de 2019. Estas causas podem provocar colisão frontal pela invasão de faixa ou então levar a saída da pista de trânsito e ocasionar o choque com outros veículos ou com objetos fora da pista. A colisão frontal é o tipo de acidente que será tratado neste trabalho por possuir a maior taxa de vítimas fatais.

A prevenção deste tipo de acidente pode ser feita pela utilização de tecnologias de visão computacional, que possibilitam o gerenciamento e processamento das imagens captadas das vias urbanas através de câmeras de monitoramento, servindo para alertar o motorista quanto a saída de faixa e a possível colisão com outro veículo.

Existem algoritmos para o reconhecimento de faixas horizontais que ajudam a minimizar o problema da colisão frontal. Porém, a taxa de eficácia, ou seja, a taxa de reconhecimento dos algoritmos que foram publicados até o momento não é de 100%, variando de 78,07% no artigo publicado por [Paula e Jung \(2013\)](#) até 99,6% no trabalho de [Zang et al. \(2018\)](#). Este último atinge esta taxa com imagens tiradas durante o dia, em períodos noturnos a taxa de acurácia diminui para 60%. Já no trabalho de [JÚNIOR \(2016\)](#) a taxa de acerto para imagens noturnas é de 86,58%.

Sendo assim, quanto menor a taxa de acurácia do algoritmo, maiores são as chances de se ter uma informação incorreta. E por se tratar de vidas humanas, é desejado que a solução tenha uma alta taxa de precisão próxima aos 100%, para que não haja um equívoco de informações que possam provocar um acidente.

## 1.1 Justificativa

Durante o ano de 2016 começou um grande avanço no número de empresas que iniciaram investimentos em tecnologia de Sistemas de Direção Automatizada (ADS) que são divididas em 5 níveis. O nível mais alto, o nível 5, permite o carro ir de um ponto ao outro sem a necessidade de intervenção de um motorista ([CHAN, 2017](#)). Dentre as empresas que se destacam nesta tecnologia estão, segundo [Chan \(2017\)](#):

- A Tesla atualizou os sistemas de piloto automático e afirmou ter o *hardware* disponível para carros totalmente autônomos;
- A Uber começou a testar em vias públicas com motorista a bordo os seus carros autônomos;
- O Google fechou um acordo de produção de 100 carros autônomos com a Fiat-Chrysler.

Também existem projetos de rodovias inteligentes, onde o governo do país é quem projeta e implanta. Esta solução para diminuir os acidentes é utilizada, por exemplo, no Japão, cujo sistema de estradas inteligentes informam para os motoristas o limite de velocidade e a condição de tráfego através da coleta e transferência de dados por meio de transceptores de rádio e de sinal infravermelho. Porém, o custo deste sistema de rodovias inteligentes é alto, o que o torna inviável ainda mais sobre a perspectiva do Brasil ([Ross, 2015](#)). Ou seja, para países de territórios grandes ou subdesenvolvidos, o sistema que torna mais viável são os sistemas ADS ou os Sistemas Avançados de Assistência ao Condutor (ADAS).

Entretanto, existem duas visões ao ADS que podem impactar a aceitação de mercado. Um campo defende um nível de maturidade crescente das tecnologias ADAS que já estão no mercado e a evolução para níveis mais altos de ADS, no qual, podem ajudar em tarefas de direção que exigem um rápido nível de reação e de precisão. Nesta visão, também é defendido que o motorista deva permanecer no circuito de tomadas de decisões, devido ao fato de que motoristas humanos podem trocar olhares, avaliar gestos corporais e prever atos de direção melhor que uma máquina. Além disso, muitos usuários ainda preferem assumir o controle do veículo mesmo sabendo da disponibilidade da tecnologia (CHAN, 2017).

A outra visão defende que a implantação de sistemas ADS torna o motorista inadequado para dirigir ao ser exposto por um longo período à tecnologia. Essa conduta foi comprovada em sistemas de automação de nível 2, onde o veículo de forma automática pode controlar a direção e a velocidade para ajudar o motorista. Isso acarreta no aumento da confiança no dispositivo que acaba deixando o usuário mais desatento e colocando sua vida e a de outras pessoas em risco. Logo, este campo sugere a implementação direta para o nível 5, onde o veículo é totalmente automatizado (CHAN, 2017).

Diante a isto, uma maneira de reduzir estes problemas é a implementação de tecnologias ADAS, que auxiliará o condutor com avisos de saída de faixa, que é reconhecido em inglês como Lane Departure Warning System (LDWS). Este sistema irá aumentar a segurança para os condutores e passageiros, possibilitando também uma maior aceitação de mercado se comparado com a tecnologia ADS.

## 1.2 Objetivos

### 1.2.1 Objetivo Geral

Este trabalho tem como objetivo geral propor e avaliar um método para classificação da sinalização horizontal na pista de rolamento.

### 1.2.2 Objetivos Específicos

Para atender o objetivo geral proposto é definido os seguintes objetivos específicos:

- Encontrar a posição e o tamanho da área da região de interesse favorável para o aumento da acurácia do método;
- Utilizar de técnicas de visão computacional para identificação e classificação da sinalização horizontal em autovias;
- Analisar o desempenho do algoritmo em relação a taxa de acurácia com imagens de trabalhos correlatos e de rodovias brasileiras.

## 2 Fundamentação Teórica

Neste capítulo será apresentado o arcabouço teórico para compreensão dos recursos utilizados sobre a identificação de faixas horizontais de trânsito, apresentando os conceitos base e suas tecnologias para desenvolver a solução do problema proposto.

### 2.1 Tipos de marcações e cores

A sinalização horizontal é constituída por dois tipos de traçado que regularizam o sentido de tráfego, o traçado contínuo e o traçado seccionado. Estes traçados podem ser simples, ou seja, contendo apenas uma faixa, ou combinados em duplas. As formas padrão estabelecidas no manual do [Contran \(2007\)](#) para sinalização são<sup>1</sup> (Figura 1 e Figura 2):

- **Contínua:** corresponde às linhas sem interrupção e que regulariza a não permissão a ultrapassagem e deslocamento lateral;
- **Tracejada ou Seccionada:** corresponde às linhas interrompidas que utilizam espaçamentos entre os traços e que regulariza a permissão a ultrapassagem e deslocamento lateral;
- **Setas, Símbolos e Legendas:** correspondem às informações representadas em forma de desenho ou inscritas, aplicadas no pavimento, indicando uma situação ou complementando a sinalização vertical existente.

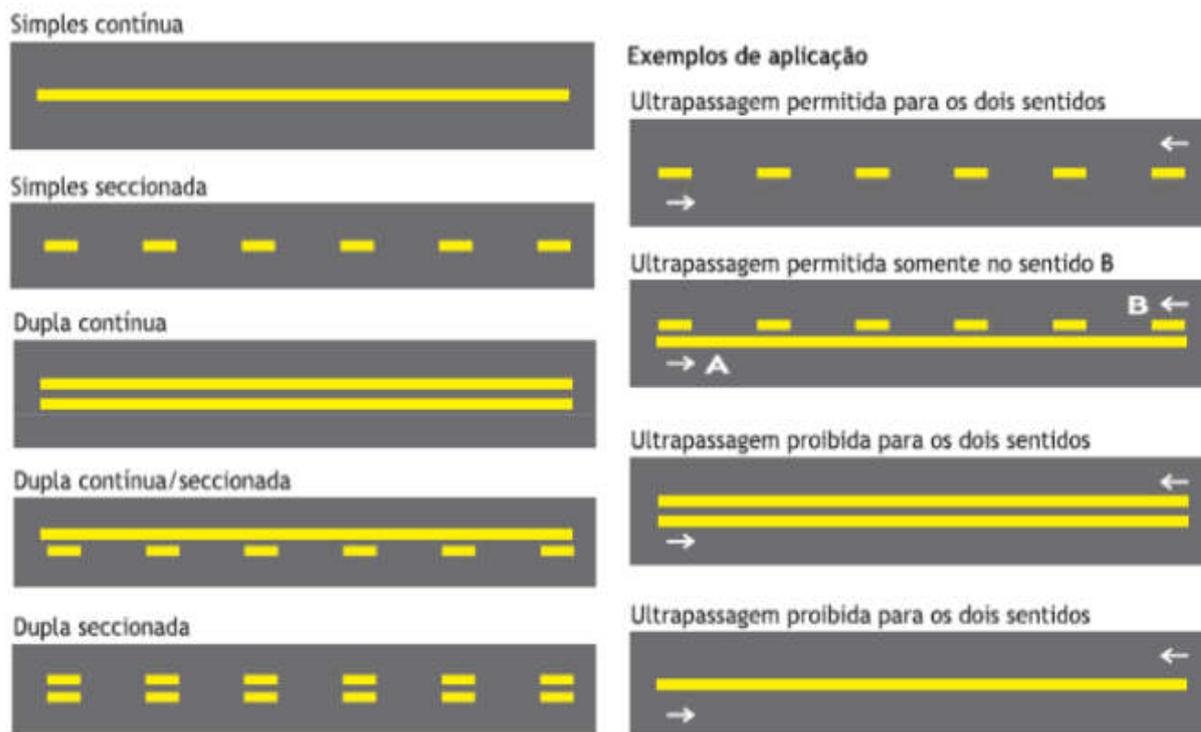
Também para regularizar sentido de fluxo são utilizados duas cores amarelo e branco, no qual, é definido por sua utilização, sendo:

- **Amarelo:** corresponde às linhas que regularizam o sentido oposto de fluxo, ou seja, de mão dupla, representadas na Figura 1;
- **Branco:** corresponde às linhas que regularizam o sentido de fluxo no mesmo sentido, ou seja, de mão única, representadas na Figura 2;

---

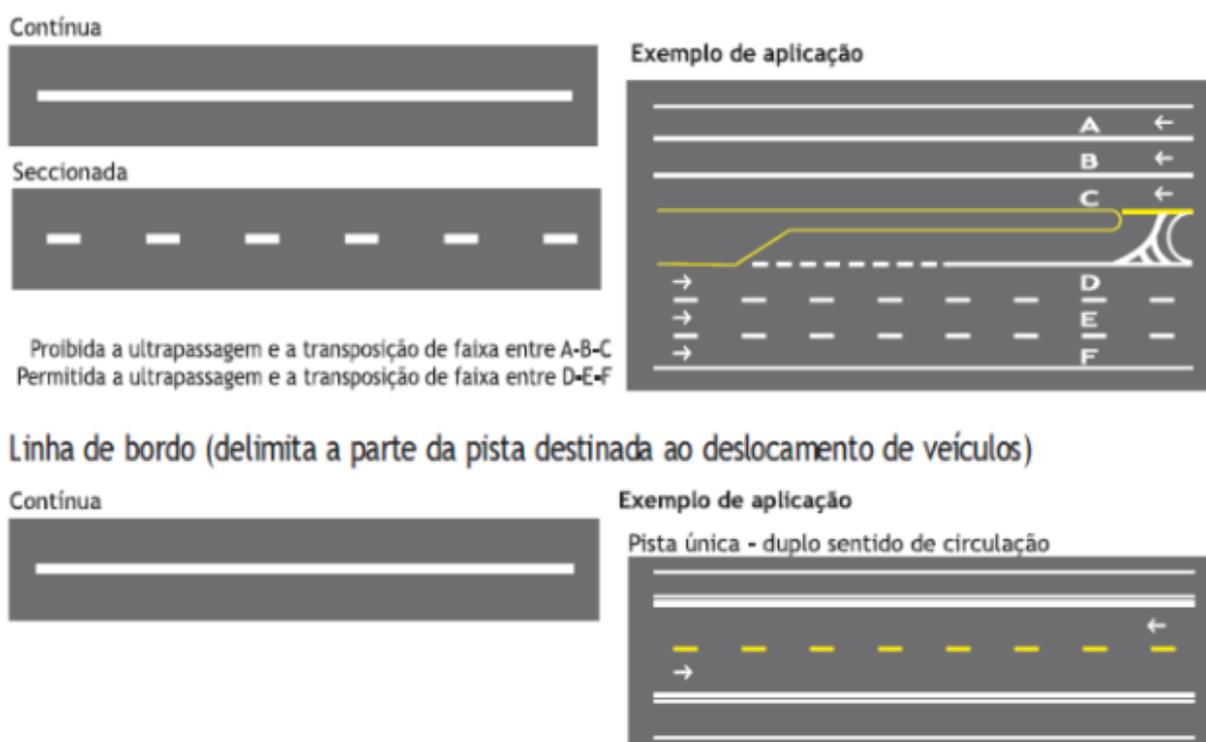
<sup>1</sup> Para este trabalho só será analisado as faixas contínuas e as seccionadas.

Figura 1 – Faixas de fluxo e ultrapassagem normalizadas pelo Contran.



Fonte: Manual Básico de Segurança do Trânsito (CONTRAN, 2004)

Figura 2 – Faixas de único sentido e e exemplos de aplicações.



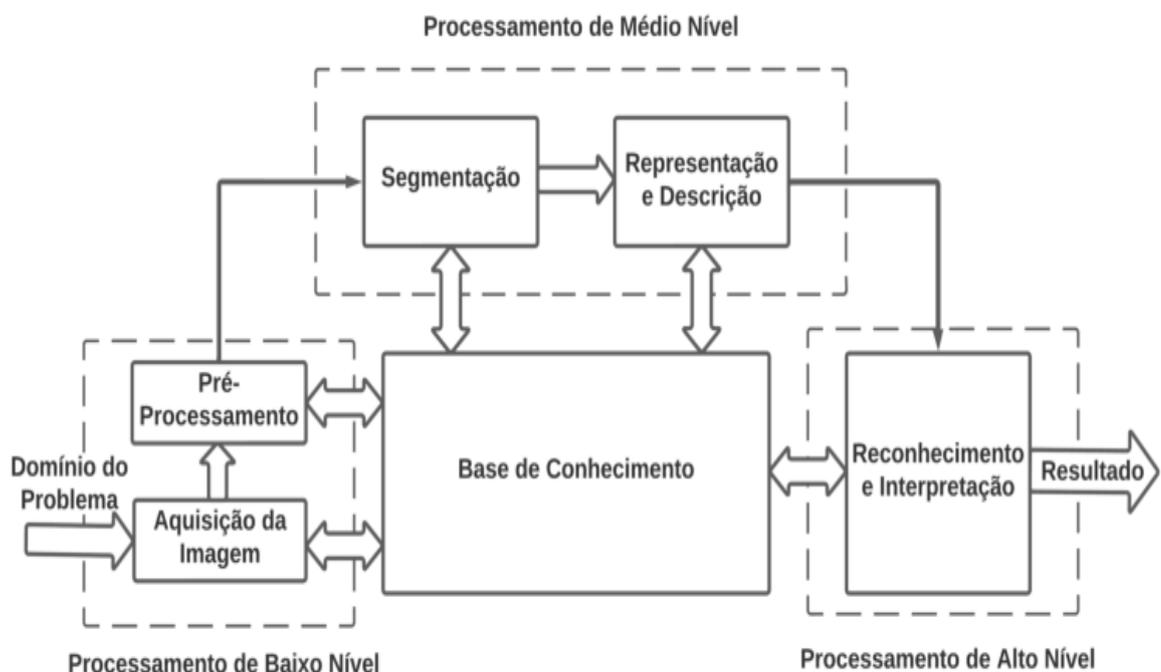
Fonte: Manual Básico de Segurança do Trânsito (CONTRAN, 2004)

## 2.2 Processamento Digital de Imagens

Segundo [Gonzalez e Woods \(2010\)](#), o processamento de imagens é a operação na qual ocorre o processamento das imagens através de um computador, sendo que estas imagens são definidas como uma função bidimensional  $f(x,y)$ , em que  $x$  e  $y$  são coordenadas espaciais no plano e a amplitude de  $f$  é chamada de *intensidade* ou *nível de cinza*. E quando os valores de  $f$  são em quantidades finitas e discretas, é chamado de imagem digital.

[Gonzalez e Woods \(2010\)](#) dividem o processamento digital em três partes: o processamento de baixo nível, médio nível e alto nível, conforme a Figura 3. O processamento de baixo nível envolve operações de pré-processamento para redução de ruídos, realce de contraste e o aguçamento das imagens. Uma característica do processo de baixo nível é que tanto a entrada quanto a saída do processamento são dados em formato de imagens. Já o processamento de médio nível envolve operações de segmentação, as informações de compactação para atender as configurações do processamento computacional e a classificação de objetos individuais. O processo de médio nível tem como entrada imagens e a saída são atributos extraídas das imagens, como por exemplo, bordas e contornos. E o processamento de alto nível tem como característica dar valor ao conjunto de objetos reconhecidos, como a análise de imagens.

Figura 3 – Processo para o processamento de imagens.



Fonte: Adaptado ([Gonzalez; Woods, 2010](#))

## 2.3 Pré-processamento

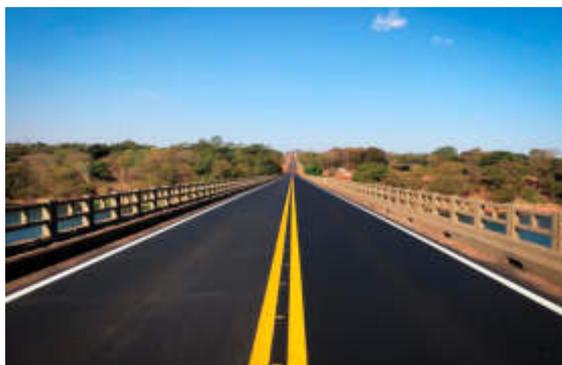
A etapa de pré-processamento da imagem é crucial para a identificação e manipulação das informações contidas na imagem. Nesta etapa é que ocorre a suavização, redução e recortes para diminuição de ruídos. O pré-processamento segue as etapas de seleção da região de interesse, conversão para a escala de cinza, aplicação do filtro blur e detecção das bordas de Canny (EISENKRAEMER, 2017).

### 2.3.1 Conversão para escala de cinza

A região de interesse é recortada da imagem original, mas com cores em RGB (Vermelho, Verde e Azul) que demandam um maior tempo de processamento. Para diminuir este problema já que as cores não influenciam no reconhecimento de objetos e das faixas é feito a conversão para a escala em tons de cinza, ou seja, monocromática representando na Figura 4.

Figura 4 – Imagem original no espaço de cores RGB.

(a) Imagem original com as cores de interesse delimitadas por um retângulo.



(b) Imagem convertida para escala monocromática.



Fonte: Adaptado (SEABRA, 2020).

### 2.3.2 Desfoque Gaussiano

O filtro tem a função de eliminar o máximo de ruído de uma imagem de modo que perca o mínimo de informações possíveis. O Desfoque Gaussiano é caracterizado como filtro linear de suavização e opera pela substituição do valor de cada pixel da imagem pela soma dos níveis de cinza de sua vizinhança. A soma é feita através dos pesos dos atributos de acordo com a função de distribuição Gaussiana. O valor atribuído a um pixel diminui de acordo com o pixel de referência e o pixel central, deste modo é garantido que a imagem resultante não será distorcida (MISRA; WU, 2020). O filtro Gaussiano é definido na Equação 1 e seu resultado representado na Figura 5:

$$G_{\sigma} = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{(x^2 + y^2)}{2\sigma^2}\right) \quad (1)$$

Figura 5 – Resultado da aplicação do filtro gaussiano com diferentes valores de  $\sigma$ .



Fonte: Adaptado (SEABRA, 2020)

Onde  $\sigma$  é definido pela largura do filtro e  $x,y$  são as coordenadas da imagem. A largura do filtro define o grau de suavização e com o valor  $\sigma$  maior implica em uma maior suavização. Esta função é usada como filtro de suavização que é aplicado simetricamente na imagem, tendo assim o mesmo valor de suavização por toda a imagem.

### 2.3.3 Região de Interesse

A aquisição das imagens é feita por uma câmera de vídeo que geralmente capta automóveis, placas verticais, meio-fio entre outros objetos que diminuem o desempenho da classificação das faixas. Para diminuir este problema é selecionado apenas uma parte da imagem, com isto, diminui o tempo de processamento e a taxa falsos positivos de regiões que não possuem informações relevantes para a detecção das faixas. Como demonstrado na Figura 6 abaixo:

Figura 6 – Seleção da região de interesse.



Fonte: Adaptado (SEABRA, 2020)

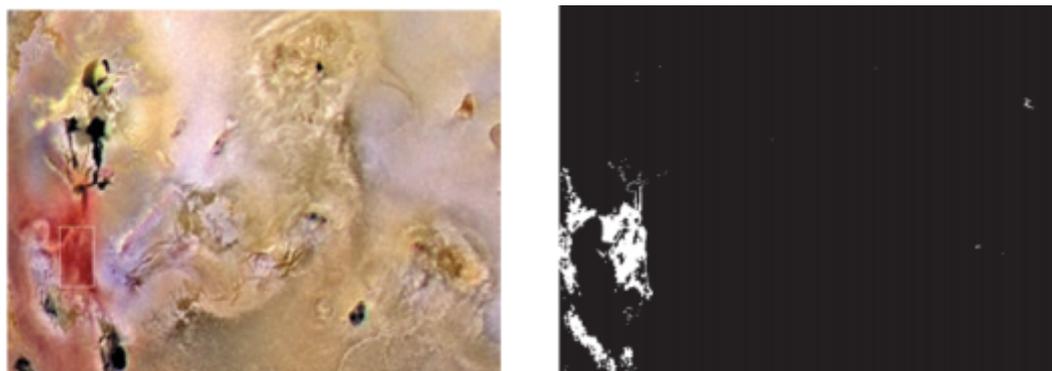
## 2.4 Segmentação de Imagens

A segmentação é um dos mais importantes processos dentro do processamento digital de imagens, devido estar relacionado a compreensão, análise e interpretação das imagens (Silva; Tavares, 2011). Este processo consiste na divisão da imagem em conjunto de pixels que tem como finalidade simplificar ou mudar a representação da imagem de modo que facilite sua análise. É usado para localizar formas geométricas e objetos através de suas linhas ou curvas (Gonzalez; Woods, 2008).

A segmentação, representada na Figura 7, é dividida em duas propriedades básicas de valores de intensidade que são a descontinuidade e a similaridade. A descontinuidade divide a imagem com base nas mudanças de intensidade como por exemplo, as bordas. E a similaridade é baseada na divisão da imagem em regiões, onde estas regiões sejam semelhantes de acordo com as características predefinidas (Gonzalez; Woods, 1992).

Figura 7 – Segmentação no espaço de cores RGB.

- (a) Imagem original com as cores de interesse delimitadas por um retângulo. (b) Resultado da segmentação no espaço de cores RGB.



Fonte: (Gonzalez; Woods, 2010).

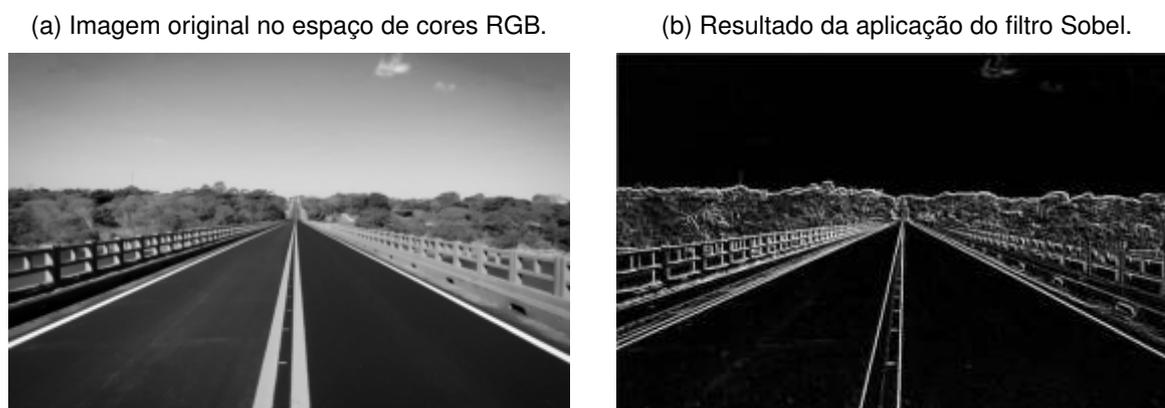
### 2.4.1 Filtro Sobel

O filtro de Sobel consiste em um par de kernels 3 por 3 que são aplicados a uma imagem para produzir gradientes de pixels que são próximos, com o objetivo de detectar as bordas na direção vertical ( $H_Y$ ) e horizontal ( $H_X$ ). O kernel de Sobel é dado como:

$$H_X = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix} \quad e \quad H_Y = \begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix} \quad (2)$$

Assim, o método de Sobel é uma operação de gradiente espacial 2D que consiste em aprimorar as bordas de uma imagem, conforme é possível ver na Figura 8.

Figura 8 – Aplicação do filtro Sobel.



Fonte: Adaptado (SEABRA, 2020).

As linhas são destacadas devido aos gradientes nas bordas que são geralmente maiores do que aqueles em regiões mais homogêneas. Os coeficientes dos kernels podem ser ajustados de acordo com necessidade dos requisitos. E com o aumento destes coeficientes, maiores serão o número de arestas detectadas (Yaokun Wu et al., 2019).

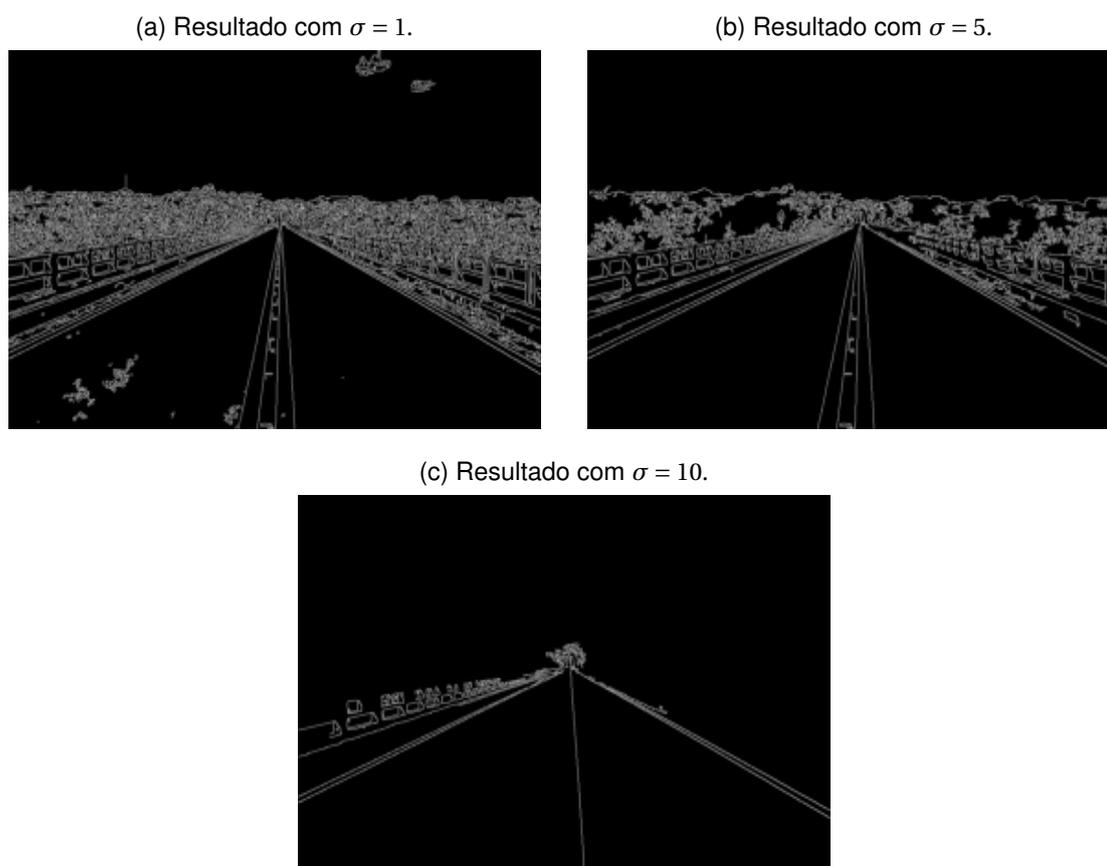
#### 2.4.2 Detecção das bordas de Canny

A detecção de bordas de Canny possuem três critérios de desempenho: detecção, localização e injeção de resposta múltipla. Este último força o processo de detecção a reconhecer uma única borda onde há apenas uma que é verdadeira. O objetivo de Canny neste trabalho é desenvolver um detector ótimo para os tipos de bordas mais comuns em imagens digitais do tipo degrau (Maia; Porfírio, 2002). O filtro ótimo pode ser aproximado pela derivada da função Gaussiana, obtendo-se assim o filtro aproximado pela Equação 3:

$$G'(x) = -\frac{x}{\sigma^2} \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (3)$$

É possível observar na Figura 9 que quanto maior o desvio padrão  $\sigma$ , menor é a quantidade de bordas identificadas como sendo espúrias. Em contrapartida, é necessário observar o aumento do valor  $\sigma$ , pois se for muito alto haverá o desfoque das bordas ou até uma menor quantidade de bordas identificadas.

Figura 9 – Resultado da aplicação do filtro de detecção das bordas de Canny.



Fonte: (Maia; Porfírio, 2002).

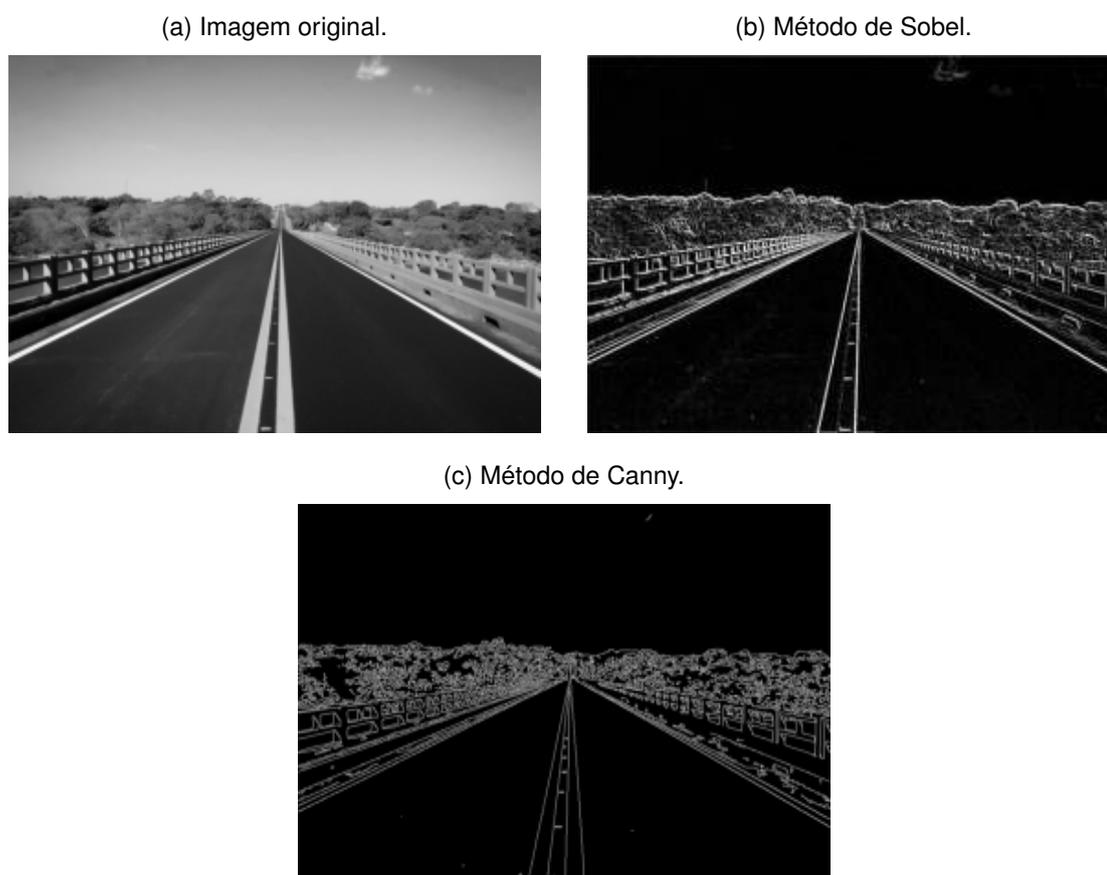
### 2.4.3 Canny vs Sobel

A detecção de bordas de Sobel é um algoritmo que detecta a magnitude absoluta do gradiente e define a direção dos pixels de uma imagem, assim é possível determinar as bordas de um objeto.

Já a detecção de bordas de Canny é um pouco mais complexa, além de detectar os gradientes da imagem, para definir as bordas é necessário também aplicar o limiar da magnitude de gradiente inferior para descartar as bordas com menor grau de certeza. Logo após é aplicado limiar duplo para determinar as bordas em potencial e por fim é descartado todas as outras bordas fracas e não conectadas a bordas fortes.

As principais vantagens da detecção de bordas pelo operador de Sobel é que o processo é mais simples e menos custoso. Porém, a técnica de Canny produz bordas mais suaves. A desvantagem do algoritmo de Canny é que ele é mais complexo e menos eficiente em relação ao tempo de processamento (HAIDAR, 2021). A Figura 10 abaixo demonstra a diferença entre os métodos:

Figura 10 – Comparação entre o método de Sobel e de Canny.



Fonte: Adaptado ([SEABRA, 2020](#)).

#### 2.4.4 Transformada de Hough

A transformada de Hough é uma técnica de segmentação de imagens para detecção de um conjunto de pontos que pertencem a uma determinada forma geométrica de uma imagem, como por exemplo, linhas, círculo e elipses. Para maximizar o desempenho dos cálculos da transformada de Hough, a imagem deve ser transformada para escala monocromática e então submetida a uma técnica para detecção de bordas como a de Canny ou a de Sobel ([PEDRINE; SCHWARTZ, 2008](#)).

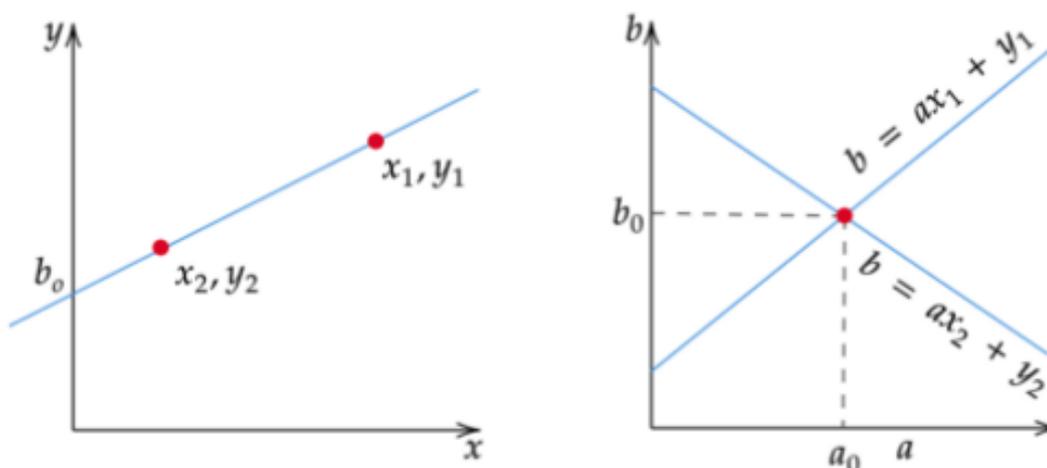
O algoritmo de Hough trabalha em cima de quatro conceitos, a imagem de borda, Espaço de Hough, mapeamento dos pontos de borda no Espaço de Hough, a representação de uma linha e como elas são detectadas.

A imagem de borda é a saída de um algoritmo de detecção de borda, como por exemplo, o algoritmo de Canny e Sobel. Para a Transformada de Hough, é crucial a utilização de um algoritmo de detecção de borda para produzir como entrada uma imagem com bordas.

O Espaço de Hough é um plano 2D em que o eixo horizontal representa uma inclinação e o eixo vertical representa a interceptação de uma linha na imagem de borda. Uma linha é representada na forma de  $y = mx + b$  que é a equação de uma função linear

(HOUGH, 1962). Uma linha que é representada na imagem de borda produz no Espaço de Hough um ponto, uma vez que uma linha possui uma inclinação  $m$  e interceptação em  $b$ . E um ponto na imagem de borda  $(x_1, y_1)$  pode ter um número infinito de linhas passando por este ponto. Então, um ponto de borda produz uma linha no Espaço de Hough na forma de  $b = ax_1 + y_1$  (LEAVERS, 1992). Na Transformada de Hough, o Espaço de Hough é usado para determinar se existe uma linha na imagem de borda.

Figura 11 – Mapeamento de pontos de borda no Espaço de Hough.



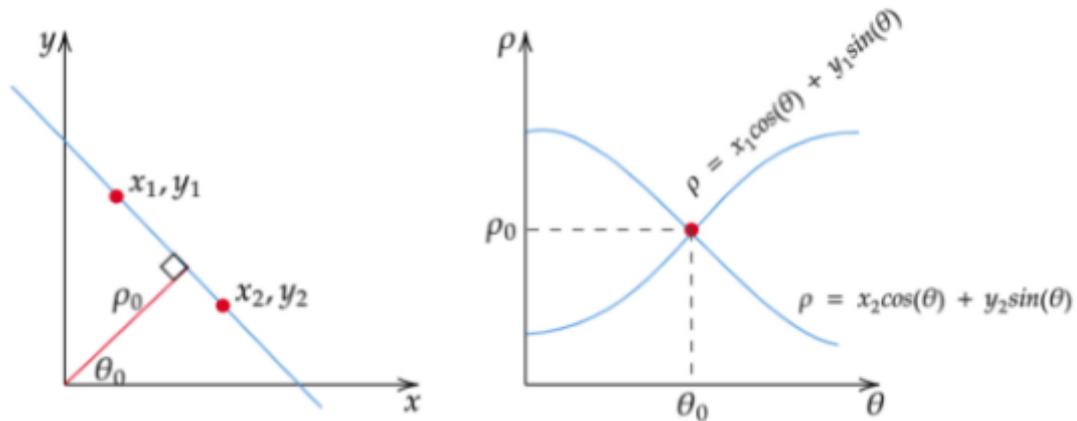
Fonte: (LEE, 2020)

Porém, há uma falha na representação de linhas na forma de  $y = mx + b$  e o Espaço de Hough com a inclinação e a interceptação. Com isto, o algoritmo não é capaz de detectar linhas verticais porque a inclinação é indefinida ou infinita para linhas verticais (LEAVERS, 1992). Para evitar este problema um segmento de reta é representado por uma linha normal que passa pela origem e é perpendicular a essa linha. A linha normal é definida por  $\rho = x \cos(\theta) + y \sin(\theta)$  onde  $\rho$  é o comprimento da linha normal e  $\theta$  é o ângulo entre a linha normal e o eixo  $x$ .

Com esta representação no Espaço de Hough, os valores de  $\theta$  são valores no eixo horizontal e os valores de  $\rho$  são os valores no eixo vertical. O mapeamento dos pontos de borda no Espaço de Hough é semelhante a esta forma, exceto que um ponto de borda  $(x_1, y_1)$  gera uma curva cosseno no Espaço de Hough em vez de uma linha reta (LEAVERS, 1992) como é possível ver na Figura 12. Essa representação normal de uma linha elimina a questão de valores infinitos que surge ao lidar com linhas verticais.

E para a detecção de linhas, como mencionando anteriormente, um ponto de aresta gera uma curva cosseno no Espaço de Hough e se mapear todos os pontos de borda de uma imagem no Espaço de Hough isso gera como saída muitas curvas cosseno.

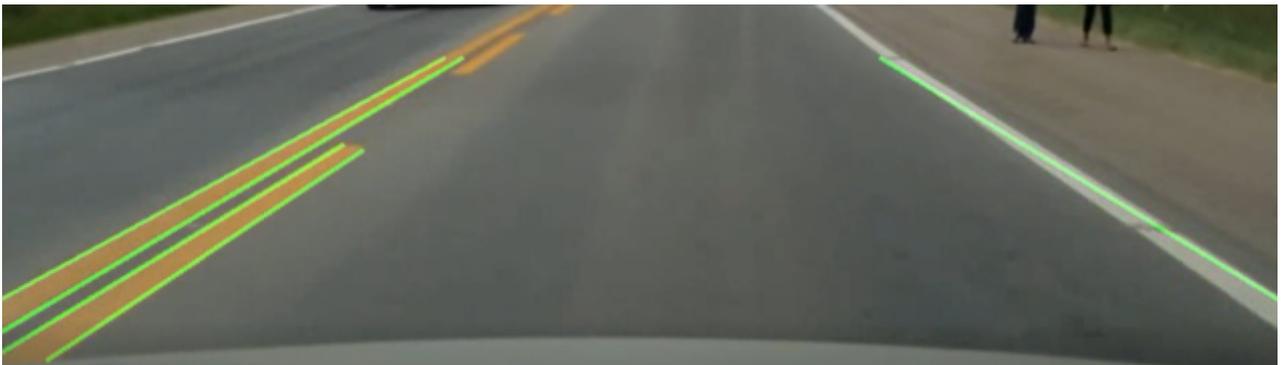
Figura 12 – Representação alternativa de uma linha e sua correspondência no Espaço de Hough.



Fonte: (LEE, 2020)

Se dois pontos de borda estiverem na mesma linha suas curvas cosseno se cruzarão no ponto  $(\rho, \theta)$ . Assim, a Transformada de Hough detecta as linhas encontrando o ponto  $(\rho, \theta)$  que possuem o número de interseções maior que um determinado limiar, o resultado da aplicação do método pode ser visto na Figura 13. Porém, nem sempre essa detecção gera o melhor resultado o que pode produzir linhas duplicadas. E para resolver isso será abordado o método na seção 4.3.4.

Figura 13 – Aplicação do filtro Sobel.



Fonte: Adaptado (Paula, 2020).

## 2.5 Reconhecimento e Interpretação

Reconhecimento ou classificação é o processo que atribui um identificador aos objetos de uma imagem, baseado nas características predefinidas, como é possível ver na Figura 14. O objetivo então é reconhecer padrões e identificar os objetos na cena a partir de

medições. Cada objeto possui um padrão de formas, linhas e cores e os valores medidos são características destes padrões (NASCIMENTO, 2007).

Figura 14 – Reconhecimento e classificação das faixas de trânsito.



Fonte: Adaptado (Paula, 2020).

As técnicas de reconhecimento de padrões podem ser divididas em dois tipos, que é a classificação baseada em aprendizagem supervisionada e a não-supervisionada. Os algoritmos de classificação supervisionada se subdividem em dois tipos, os paramétricos e os não paramétricos. No paramétrico, é feito o treinamento a partir de uma grande quantidade de amostras rotuladas para que os parâmetros estatísticos de cada classe possam ser estimados. Já na classificação não-paramétrica, os parâmetros do conjunto de treinamento não são considerados (ANDRADE; FRANCISCO; ALMEIDA, 2013).

E na classificação não-supervisionada, o classificador divide o conjunto de dados de entrada a partir de um critério de verossimilhança, resultando em um conjunto de clusters em que cada um é associado a uma classe. Já o processo de interpretação consiste em atribuir um significado ao conjunto de objetos que foram reconhecidos (MOREIRA, 2001).

## 2.6 Biblioteca OpenCV

O OpenCV é uma biblioteca de *softwares* de visão computacional e aprendizado de máquina de código aberto. Ele foi construído com o objetivo de fornecer uma infraestrutura de aplicativos de visão computacional que agilizam o processo de desenvolvimento. A maioria dos algoritmos são focados na análise de visão computacional em tempo real. A linguagem nativa é o C++ e atualmente possui interfaces com o C, Python, Java e MATLAB (OPENCV, 2020).

### 3 Trabalhos Relacionados

O Lane Departure Warning System (LDWS), é reconhecido como um sistema de aviso de saída de faixa. Este sistema funciona de acordo com a monitoração da posição de um veículo a partir de uma faixa de rodagem e alerta ao motorista a saída ou se o carro está prestes a sair da faixa. Os LSDW's disponíveis são baseados na visão em perspectiva e usam algoritmos para interpretar as imagens e estimar a posição do veículo quanto ao alinhamento nas faixas da estrada (Xiangjing An; Mo Wu; Hangen He, 2006). Na literatura é possível encontrar os seguintes trabalhos relacionados a detecção e/ou classificação de faixas que são mostrados a seguir.

No artigo desenvolvido por Paula e Jung (2015), apresenta uma abordagem para classificar a sinalização horizontal usando uma câmera de bordo. A classificação das faixas começa a partir da detecção dos limites da pista, usando o modelo de detecção linear-parabólico e de calibração automática da câmera em tempo real. Logo após, é aplicado uma suavização adaptativa para reduzir o ruído na imagem que mantém as bordas próximas separadas e pares de máximos-mínimos locais são utilizados para identificar possíveis sinalizações da pista. E para a classificação da sinalização horizontal é aplicado um classificador Bayesiano em cada quadro do vídeo. O resultado final apresentou uma taxa de acerto de 96%, usando diversos vídeos e com diferentes câmeras e resoluções.

Figura 15 – Exemplo da classificação e identificação das faixas feito por Paula e Jung (2015).

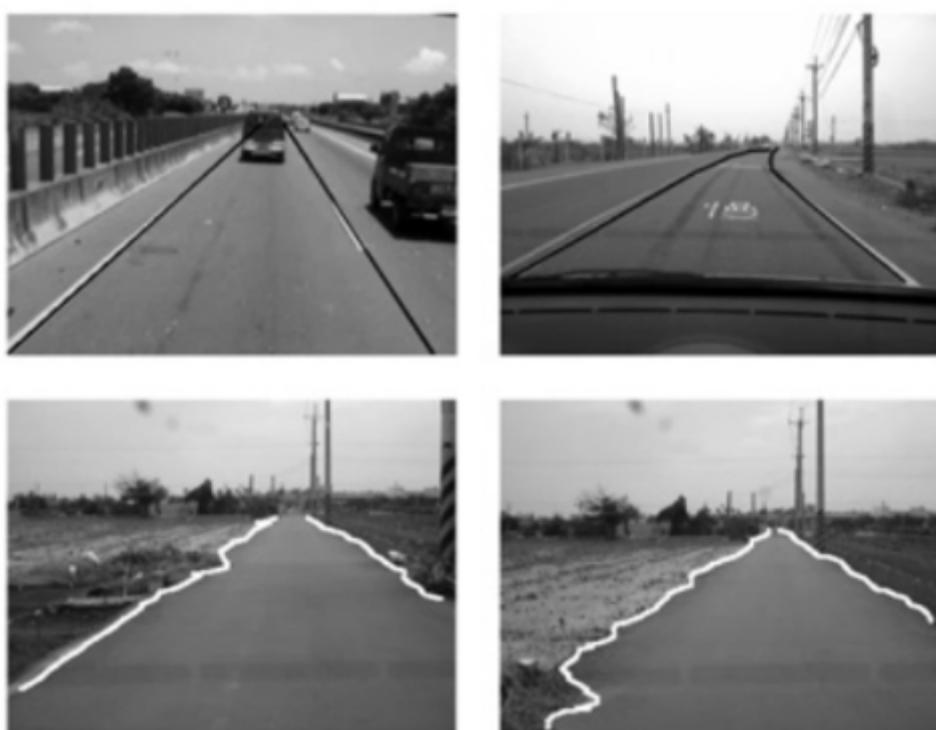


Fonte: (Paula; Jung, 2015).

Já no estudo de Cheng et al. (2010), apresenta um sistema de hierarquia para detecção de faixas capaz de lidar com vias com ou sem sinalização horizontal. O sistema primeiramente classifica o ambiente antes de aplicar os algoritmos para os diferentes tipos de estrada. Para a classificação do ambiente é extraído os pixels com as cores de

marcação de faixa e são utilizados para a detecção das possíveis faixas viárias. Os veículos identificados com as cores presentes nas sinalizações são eliminados a fim de aplicar ângulos de inclinação que procuram localizar os limites da pista. E para as estradas sem sinalização viária horizontal, é aplicado o Mean-Shift<sup>1</sup> para dividir a via em duas pistas de rodagem. Os possíveis limites de estrada são eleitos a partir dos limites da região, e a regra de Bayes é usada para escolher os candidatos com a maior taxa de probabilidade de serem os limites da pista. Além disto, o sistema consegue identificar as sinalizações independentemente das condições viárias com um acerto de 97,39%.

Figura 16 – Resultados de detecção da faixa selecionada feito por Cheng et al. (2010)



Fonte: (Cheng et al., 2010).

No trabalho de Collado et al. (2005), apresenta um algoritmo de detecção e classificação de faixas de rodagem para sistemas ADAS. O algoritmo usa um filtro para extração das bordas às quais um modelo de retas das pistas é ajustado. O tipo de faixa (contínua, descontínua ou mesclada) é reconhecido usando a análise de Fourier. O conhecimento das linhas da estrada ajuda a orientar a busca por outras linhas e detectar automaticamente a orientação viária (mão única, mão dupla ou rodovia) e a detectar manobras permitidas e proibidas, como por exemplo, a invasão de faixa em linha contínua. Todo este sistema é calibrado automaticamente.

<sup>1</sup> De acordo com Cheng (1995) "É um procedimento iterativo simples que muda cada ponto de dados para a média dos pontos de dados em sua vizinhança". Ou seja, localiza em uma área de interesse os máximos pontos através de uma função para cálculo de densidade.

No artigo desenvolvido por [Zang et al. \(2018\)](#), detecta e classifica as faixas de trânsito e emite um aviso ao motorista de uma possível colisão frontal. O algoritmo começa a detecção com a imagem da via aplicando o modelo Stereo Matching <sup>2</sup> que é usado para reduzir a interferência e detecção de objetos irrelevantes sobre a distância de colisão. Logo após, é aplicado o mapeamento de perspectiva inversa na imagem original e na imagem sem os objetos irrelevantes. Em seguida, é utilizado o filtro Sobel, para fundir estas duas imagens para obter um mapa de visualização em escala de cinza de baixo ruído. Depois, é utilizado a Transformação de Hough sobre o mapa de visualização de baixo ruído para obter um mapa de análise no Espaço de Hough. Com isto, duas linhas são identificadas (à esquerda / direita) que estão mais próximas do veículo que são identificadas como as faixas paralelas. Se apenas uma linha lateral for identificada, a outra linha lateral da faixa paralela pode ser complementada de acordo com o modelo de faixas de tráfego. Com as faixas detectadas é possível obter a classificação delas através do mapa de visualização em escala de cinza de baixo ruído. Para isso, as áreas de interesse selecionadas para classificação são importadas para um algoritmo de análise profunda já treinada que é aprimorada com base na rede neural convolucional LeNet-5 para reconhecer as categorias de faixa. Este sistema obteve uma taxa de acerto de 99,6% após 5 horas de treinamento.

Figura 17 – Detecção e classificação as faixas de trânsito feito por [Zang et al. \(2018\)](#).



Fonte: ([Zang et al., 2018](#)).

<sup>2</sup> O Stereo Matching é um algoritmo que compara um par de imagens para estimar a disparidade dos pixels. Para isso, é analisado os arredores dos pixels da imagem a esquerda e é comparado com os arredores dos pixels da imagem a direita ([Stankiewicz; Domański, 2018](#)).

## 4 Desenvolvimento

O algoritmo para identificação e classificação de faixas horizontais de trânsito foi elaborado em Python, juntamente com a biblioteca OpenCV na versão 3.14.17. E foram utilizadas técnicas de processamento digital de imagens e de visão computacional para atender o objetivo proposto.

Nos testes e no desenvolvimento do trabalho foi utilizado um computador do tipo desktop com as seguintes configurações de *hardware*:

- **Fonte:** Pichau Nidus 500W PG-5001-BR-OEM;
- **Placa mãe:** ASUS TUF Gaming B460m-Plus;
- **Memória Ram:** Team Group T-Force Delta DDR4 2666mhz 2x8gb em dual channel;
- **Processador:** Intel Core i5-10400, Cache 12MB, 2.9GHz (4.3GHz Max Turbo);
- **Armazenamento:** SSD Kingston A400, 240GB, Leitura 500MB/s, Gravação 350MB/s.

Já a base de dados é composta por 5 vídeos, dos quais 2 deles são utilizados em trabalhos correlatos. Destes 5 vídeos, 4 são de rodovias brasileiras e 1 é de um rodovia da Coreia do Sul. A Tabela 2 abaixo mostra as características de cada um dos vídeos utilizados nos experimentos, onde as sinalizações são representadas por:

- **c:** Faixa contínua;
- **s:** Faixa seccionada;
- **cc:** Faixa dupla contínua;
- **cs:** Faixa dupla, sendo ela contínua do lado esquerdo e seccionada do lado direito;
- **sc:** Faixa dupla, sendo ela seccionada do lado esquerdo e contínua do lado direito;
- **cc:** Faixa dupla seccionada;

Tabela 2 – Resultado de todos os cinco experimentos submetidos a solução apresentada.

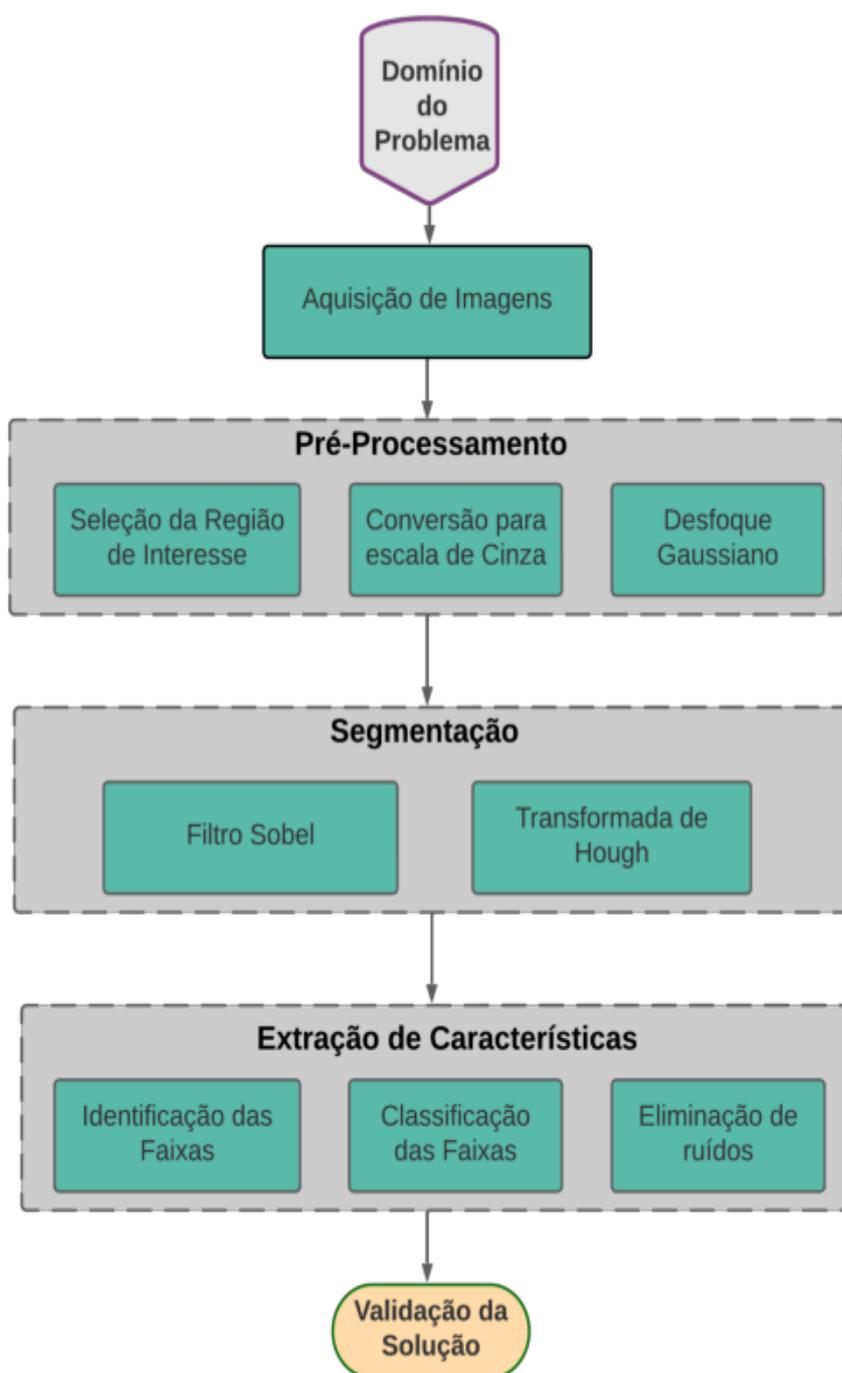
Experimento	Resolução	Sinalizações*	Quantidade de Quadros	Taxa de Quadros(s)	Autor do Trabalho**
1	1280 × 720	c, s, cc, cs, sc	1500	15	<a href="#">Paula e Jung (2015)</a>
2	1280 × 720	c, s	1519	30	<a href="#">JÚNIOR (2016)</a>
3	1920 × 1080	c, s	1074	30	-
4	1920 × 1080	c, s, cc, cs, sc	1210	30	-
5	1280 × 720	s	5278	30	-

\*Sinalizações contidas no vídeo do experimento.

\*\*Refere-se ao autor do trabalho correlato.

No trabalho desenvolvido por Almeida, Corso e Britto (2009), é dividido o processamento digital de imagens no domínio do problema, aquisição de imagens, pré-processamento, segmentação, extração de características, classificação e decisão. A solução proposta segue o mesmo raciocínio como demonstrado pelo diagrama da Figura 18. Todo o código foi desenvolvido em Python juntamente com a biblioteca de código aberto OpenCV.

Figura 18 – Fluxo de procedimentos utilizados para a identificação e classificação das linhas de sinalização de trânsito.



Fonte: Elaborado pelo autor.

Segundo Wazlawick (2010) o tipo de pesquisa desenvolvido neste trabalho é descritiva que institui a necessidade de descrever e comparar os diferentes métodos de classificação de faixas rodoviárias. E quanto ao procedimento técnico é uma pesquisa de levantamento, no qual, foram buscadas técnicas de reconhecimento de padrão de imagens a fim de aumentar a taxa de acurácia do algoritmo.

## 4.1 Aquisição de Imagens

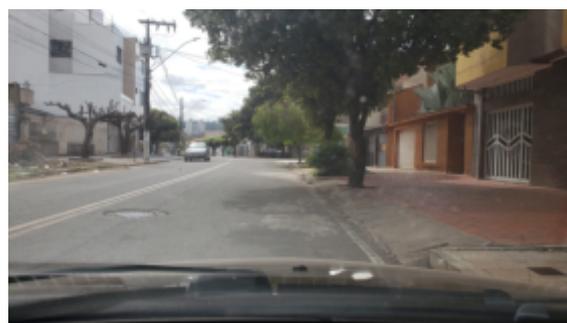
As imagens foram obtidas a partir do interior do veículo, onde a câmera foi posicionada próximo ao centro do para-brisa, como pode se ver na Figura 19a e o resultado na imagem da Figura 19b. Com o veículo em movimento é possível ser analisado a mudança de faixas tanto da faixa à esquerda quanto a faixa à direita do veículo a partir da posição da câmera, onde deverá estar posicionada de forma que a pista ocupe pelo menos até a metade da altura das imagens.

Figura 19 – Posição da câmera para o registro das imagens.

(a) Posição da câmera.



(b) Resultado a partir da Posição da câmera.



Fonte: Elaborado pelo autor.

## 4.2 Pré-Processamento

A etapa de pré-processamento tem como função aprimorar a qualidade da imagem e ajustá-las para as etapas de processamento. É nesta etapa em que ocorre a suavização, redução ou recortes com o objetivo de otimizar o desempenho do algoritmo, reduzir ou destacar certas características.

A imagem a ser tratada na etapa de pré-processamento passa por um redimensionamento, tanto em questão da largura quanto altura. Nos testes foi percebido em que algumas vezes essa redução além de deixar o algoritmo com um tempo de processamento menor, ajudou também na taxa de acerto.

### 4.2.1 Seleção da área de interesse

As imagens que formam a base de dados exibem a rodovia com as faixas horizontais do lado esquerdo e ao lado direito do veículo. Mas, como a posição da câmera está localizada no para-brisas, existe uma distorção nas imagens em que as retas se encontram no final do horizonte observável, como é mostrado pela área marcada de laranja na Figura 20. Isto é um problema devido ao fato de que o algoritmo tem dificuldades para identificar onde começa uma faixa e termina a outra. Além disso, existe um outro problema com este afunilamento, que é o fato dos segmentos de reta deixarem de ser detectados quando se aproxima do limite da visão do observador.

Figura 20 – Demonstração do limite de observação.



Fonte: Elaborado pelo autor.

Para resolver isto, é selecionado a área mais próxima ao carro e que se estende até abaixo da metade da altura da imagem, onde pode ser visto na imagem 21. Com isto, além de se ter uma taxa de acurácia maior, obtém-se também um tempo de processamento menor além de entregar uma resposta mais rápida sobre a identificação da faixa para o motorista. Isto se deve ao fato de que o recorte da imagem tem uma menor quantidade de pixels para serem processados, diminuindo a quantidade de cálculos e, conseqüentemente, entregando um tempo de processamento menor.

Figura 21 – Área limite da região de interesse.



Fonte: Elaborado pelo autor.

#### 4.2.2 Conversão para a Escala de Cinza

Logo após é aplicado a conversão para escala de cinza, como mostrado na Figura 22. Como as imagens coloridas possuem três canais de cores e a escala monocromática possui apenas um canal, essa conversão torna os cálculos mais simples, permitindo assim um tempo de processamento menor.

Além disso, esta conversão permite preservar o contraste da imagem original, mantendo assim, as informações da imagem em RGB. Isso será fundamental quando for usado o filtro de Sobel, pois é necessário que as bordas estejam nítidas para que o algoritmo consiga detectar as faixas.

Figura 22 – Imagem convertida para escala monocromática recortada da área de interesse.



Fonte: Elaborado pelo autor.

### 4.2.3 Desfoque Gaussiano

Como descrito no referencial teórico na Subseção 2.3.2, o grau de suavização está relacionado com o parâmetro  $\sigma$ , ou seja, quanto maior o valor de  $\sigma$ , maior será a suavização. Deste modo, foi utilizado para este trabalho o filtro Gaussiano com o valor de  $\sigma = 1$ . A Figura 23 abaixo demonstra a aplicação do filtro Gaussiano.

Figura 23 – Efeito blur aplicado sobre a imagem com escala de cores monocromática.



Fonte: Elaborado pelo autor.

O filtro Gaussiano é um filtro de passa baixa, desta forma ele realiza a suavização de forma mais atenuada e seguindo o formato original das curvas de maneira que serrilhados e ruídos da imagem sejam reduzidos. Isso faz com que ele seja adequado para utilização de outras técnicas para detecção de bordas como o filtro de Sobel que será detalhado a seguir.

## 4.3 Segmentação

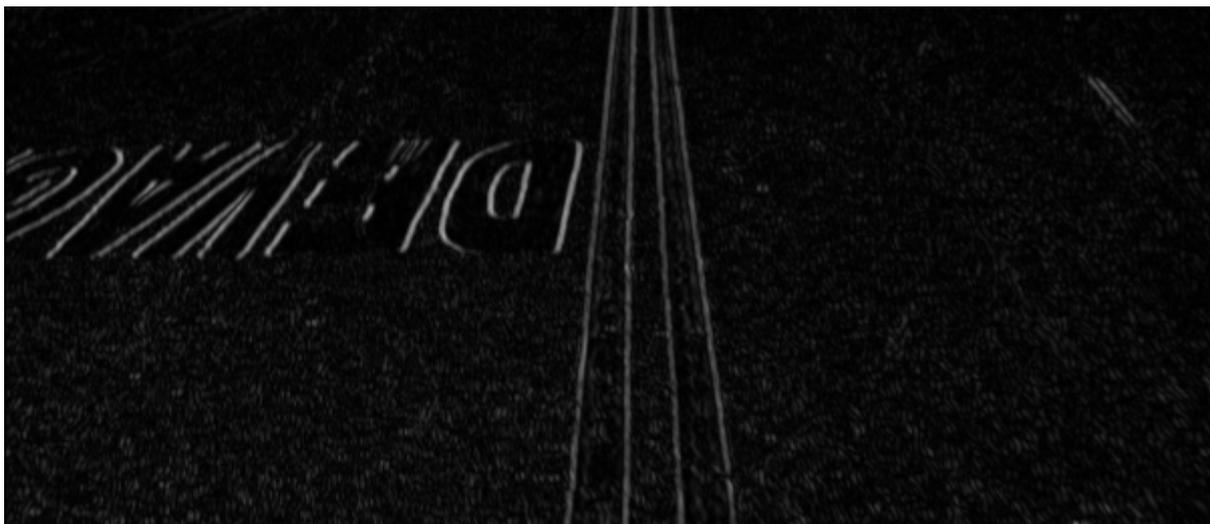
É nesta etapa que será definida a representação das sinalizações horizontal através de suas linhas e curvas. Este é o processo principal para que as sinalizações possam ser classificadas na etapa de interpretação das curvas.

### 4.3.1 Operador de Sobel

A detecção de bordas de Sobel utiliza métodos matemáticos para calcular áreas com diferentes intensidades de gradiente em uma imagem. Ele é realizado através de um *kernel* que é basicamente uma matriz  $3 \times 3$  de índices ponderados de forma assimétrica ou simétrica. Essas áreas quando há uma diferença mais intensa nas proximidades dos pixels geralmente indicam a borda de um objeto.

Ao usar a detecção da borda de Sobel a imagem é primeiro processada nas direções  $X$  e  $Y$  separadamente e depois é combinada para formar a imagem da soma das bordas  $X$  e  $Y$ . No entanto, a imagem pode ser processada em apenas um sentido na vertical ou horizontal, no qual, o sentido vertical é a forma que será abordada neste trabalho. Pois, após alguns testes feitos com o filtro foi percebido que a segmentação na direção vertical é o que teve maior êxito para identificação das faixas.

Figura 24 – Filtro de Sobel aplicado sobre a imagem com escala de cores monocromática.



Fonte: Elaborado pelo autor.

E para o método de Sobel foi utilizado os seguintes parâmetros para a função da biblioteca OpenCV:

```
cv2.Sobel = (src, ddepth, dx, dy)
cv2.Sobel = (src, ddepth, dx, dy)
src = imagem
ddepth = cv2.CV_64F
dx = 1
dy = 0
```

É importante destacar que para todo trabalho o operador de Sobel destaca as bordas de forma horizontal e o threshold mínimo utilizado na imagem acima para o operador de Sobel foi de 40 e o máximo de 100.

### 4.3.2 Utilização da Transformada de Hough

A transformada de Hough disponibilizada na biblioteca OpenCV requer alguns parâmetros. Abaixo será mostrado a função, quais são estes parâmetros e os valores utilizados neste trabalho para identificação das retas.

```
cv2.HoughLinesP(image, rho, theta, threshold, lines, minLineLength, maxLineGap)
```

- *image*: Imagem para ser rastreado as retas;
- $\rho = 1$ : Distância do acumulador em pixels;
- $\theta = \pi/180$ : Ângulo de resolução do acumulador em radianos;
- *threshold* = 80: Valor do limiar do acumulador, ao qual só serão mostradas as retas superior a este limiar;
- *lines* = *np.array*([]): Vetor de saída das linhas;
- *min\_line\_length* = 5: Tamanhos de retas menores que este valor serão desconsideradas;
- *max\_line\_gap* = 20: Distância máxima permitida entre pontos de uma reta, valores superiores a este a reta é desconsiderado;

Conforme descrito na Subseção 2.4.3, apesar do algoritmo de Canny suavizar mais as arestas se comparado com o operador de Sobel, nos testes realizados com a limitação da área de interesse obteve-se uma maior definição das faixas horizontais de trânsito pelo método de Sobel conforme demonstrado na Figura 25. Isto foi possível ser identificado realizando o rastreamento das retas através do método de Hough.

É importante salientar que para os testes abaixo foi utilizado os seguintes parâmetros para a função da biblioteca OpenCV do método de Canny:

```
cv2.Canny(src, tlower, tupper)
src = imagem
tlower = 0
tupper = 200
```

Figura 25 – Comparação dos resultados dos algoritmos de detecção de bordas e o resultado do método de Hough.

(a) Resultado do método de Canny com a limitação da área de interesse.



(b) Resultado do método de Sobel com a limitação da área de interesse.

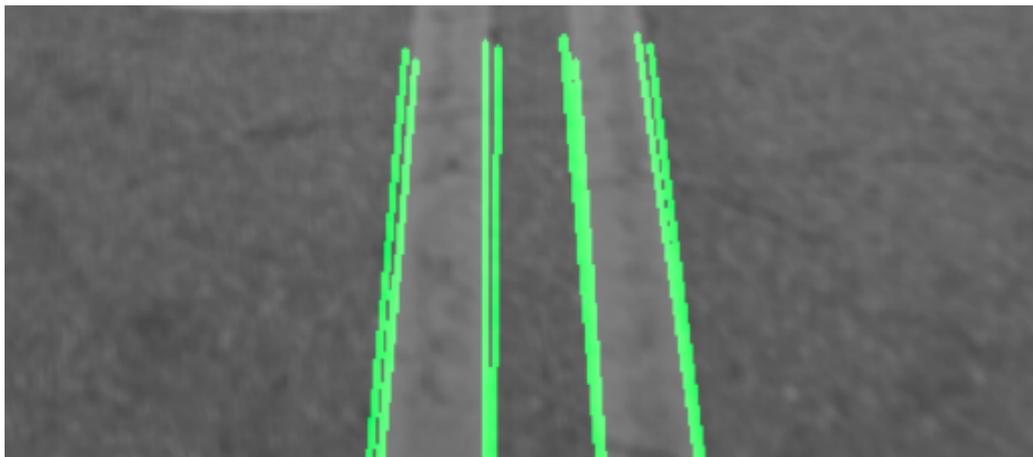


Fonte: Elaborado pelo autor.

### 4.3.3 Eliminação de segmentos colineares

Apesar do algoritmo de Hough ser muito eficiente, há um problema com a segmentação baseada em arestas, devido as arestas não envolverem o objeto por completo ou então as bordas são duplicadas conforme é possível ver na Figura 26. Para formar fronteiras fechadas em torno de regiões, é necessária uma etapa de pós-processamento de ligação ou agrupamento de arestas que correspondem a uma única fronteira.

Figura 26 – Linhas duplicadas identificadas pelo método de Hough.



Fonte: Elaborado pelo autor.

Para resolver isto foi implementado na solução o método desenvolvido por [TAVARES e PADILHA \(1995\)](#) que mescla os segmentos de reta a partir destes cinco passos:

1. É definido as coordenadas do centroide  $(x_G, y_G)$  que são formados por quatro endpoints tomando como segmento os comprimentos  $l_i$  e  $l_j$  como o ponto de 'aglomeração' mostrado na Equação 4. Em que,  $(a, b)$  são as extremidades do segmento  $i$  e  $(c, d)$  são as extremidades do segmento  $j$ . A linha mesclada conterá este centroide.

$$x_G = \frac{l_i(a_x + b_x + l_j(c_x + d_x))}{2(l_i + l_j)} \quad (4)$$

$$y_G = \frac{l_i(a_y + b_y + l_j(c_y + d_y))}{2(l_i + l_j)}$$

2. Depois é definido a orientação da linha mesclada como a soma ponderada das orientações dos determinados segmentos e seus pesos são respectivos ao seus comprimentos. A orientação da linha mesclada  $\theta_r$  é dada pela Equação 5. Onde  $l_k$  representa o tamanho e  $\theta_k$  a direção do segmento  $k$ .

$$\begin{aligned} &\text{se } |\theta_i - \theta_j| \leq \frac{\pi}{2}, \text{ então} \\ &\theta_r = \frac{l_i \theta_i + l_j \theta_j}{l_i + l_j}, \text{ senão} \\ &\theta_r = \frac{l_i \theta_i + l_j (\theta_j - \pi \frac{\theta_j}{|\theta_j|})}{l_i + l_j} \end{aligned} \quad (5)$$

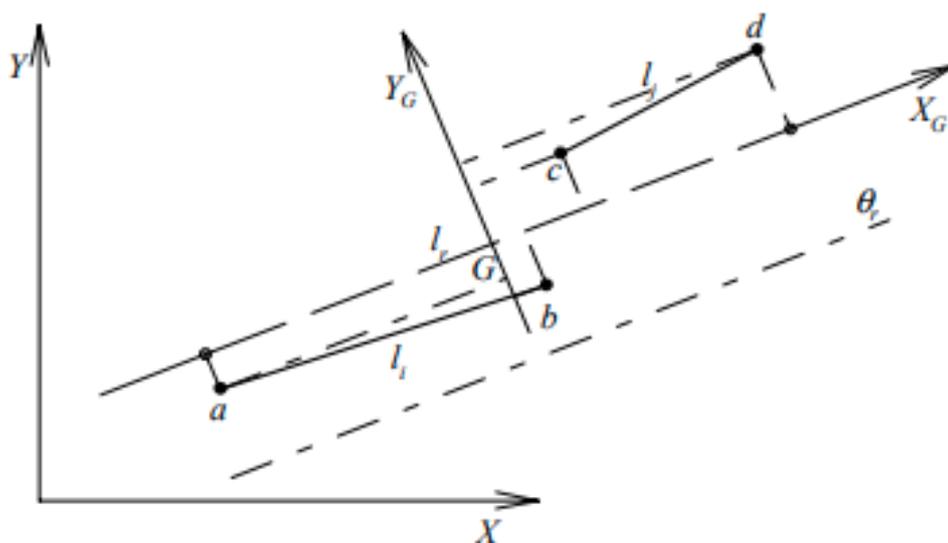
3. Logo após, é definido um quadro  $(X_G, Y_G)$  centrado no centroide  $(x_g, y_g)$  e tendo o eixo  $X_G$  paralelo à direção  $\theta_r$  da linha mesclada.
4. As coordenadas são determinadas nas extremidades  $(a, b, c, d)$  de ambos os segmentos no quadro  $(X_G, Y_G)$ . A transformação das coordenadas é uma translação seguida de uma rotação definida pela Equação 6. Onde  $(\theta_{X_G}, \theta_{Y_G})$  são coordenadas do ponto  $\delta$  no quadro  $(X_G, Y_G)$ .

$$\begin{aligned} \delta_{X_G} &= (\delta_y - y_G) \sin \theta_r + (\delta_x - x_G) \cos \theta_r \\ \delta_{Y_G} &= (\delta_y - y_G) \cos \theta_r + (\delta_x - x_G) \sin \theta_r \end{aligned} \quad (6)$$

5. Para as duas projeções ortogonais sobre o eixo  $X_G$  dos quatro pontos finais  $(a, b, c, d)$  que estão mais distantes é definido as extremidades da linha mesclada.

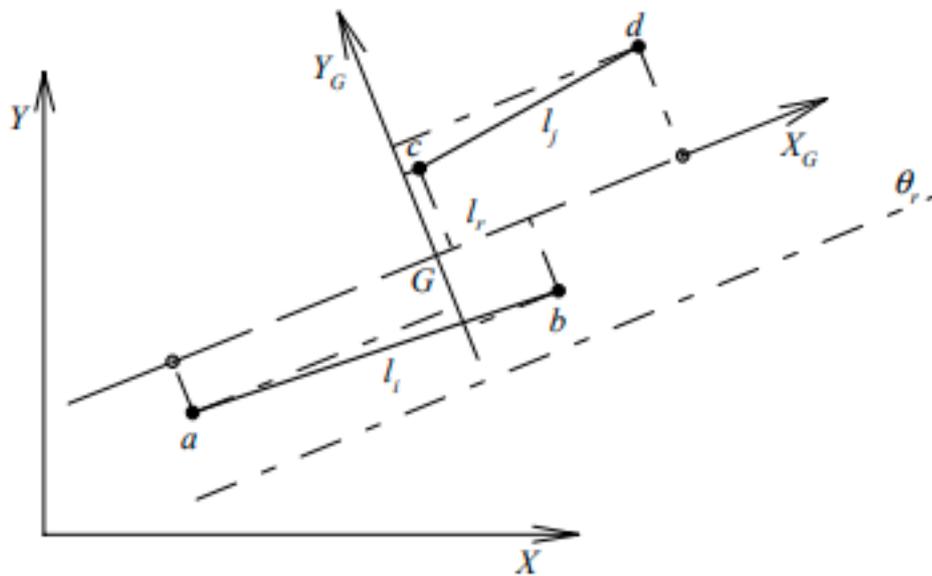
Os resultados do método proposto por TAVARES e PADILHA (1995) são mostrados nas figuras abaixo:

Figura 27 – Mescla de segmentos não sobrepostos.



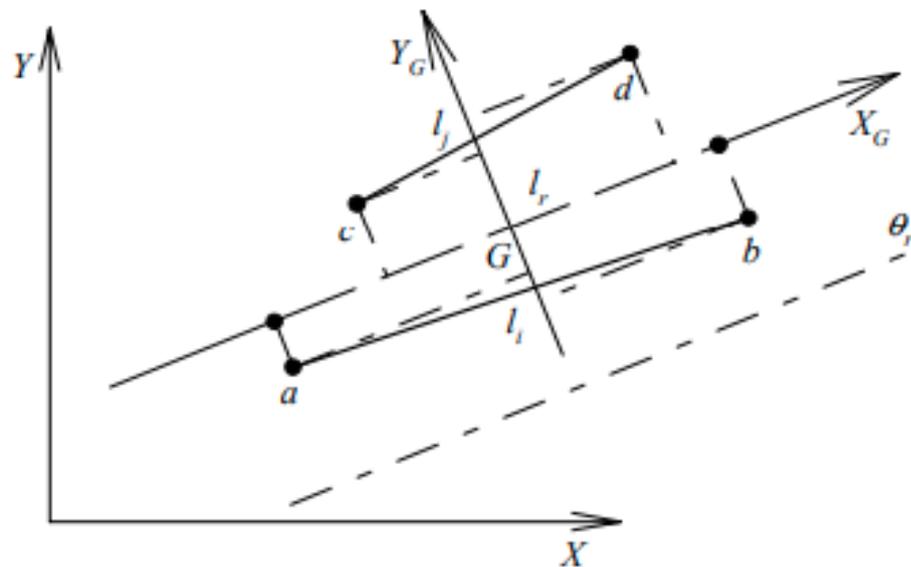
Fonte: Elaborado por TAVARES e PADILHA (1995).

Figura 28 – Mescla de segmentos parcialmente sobrepostos.



Fonte: Elaborado por TAVARES e PADILHA (1995).

Figura 29 – Mescla de segmentos totalmente sobrepostos.

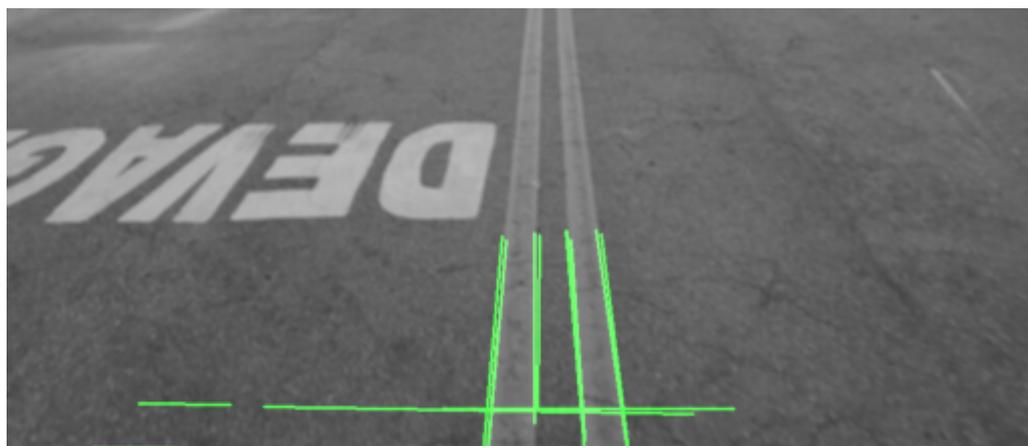


Fonte: Elaborado por TAVARES e PADILHA (1995).

#### 4.3.4 Eliminação de segmentos horizontais

Com a detecção das retas pelo algoritmo de Hough é percebido que alguns segmentos indesejados ficam evidenciados. Um destes são as retas horizontais que geralmente são detectadas através de outros objetos como carros, motos ou até mesmo a falta de regularidade do asfalto, como mostrado na Figura 30.

Figura 30 – Linhas horizontais identificadas pelo método de Hough.



Fonte: Elaborado pelo autor.

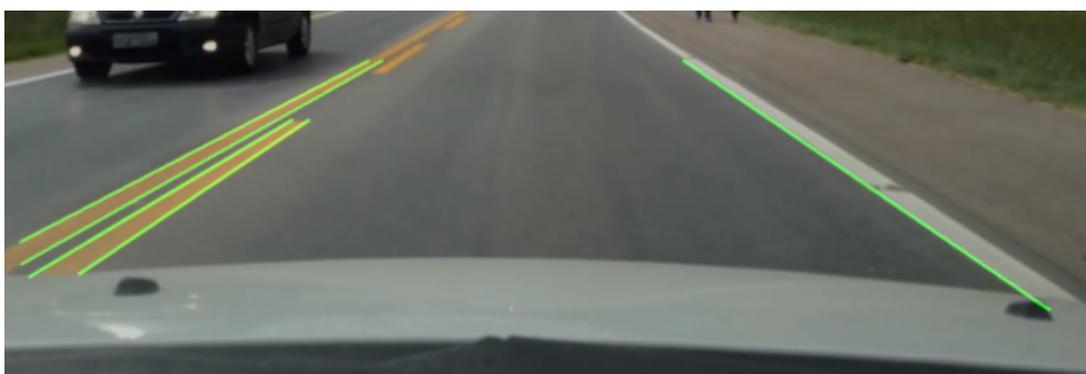
Para eliminar estes segmentos é necessário calcular o ângulo formado pelo par de pontos da reta. Para isto é chamado o método  $atan2(\Delta_y, \Delta_x)$ , que tem como retorno o arco tangente de  $y/x$  em radianos onde  $\Delta$  é definido pela Equação 7. Assim o resultado é convertido de radiano para grau. E caso o valor de  $\theta$  não for maior que  $20^\circ$  o segmento é descartado.

$$\begin{aligned}\Delta_y &= y_2 - y_1 \\ \Delta_x &= x_2 - x_1\end{aligned}\tag{7}$$

#### 4.4 Extração de Características

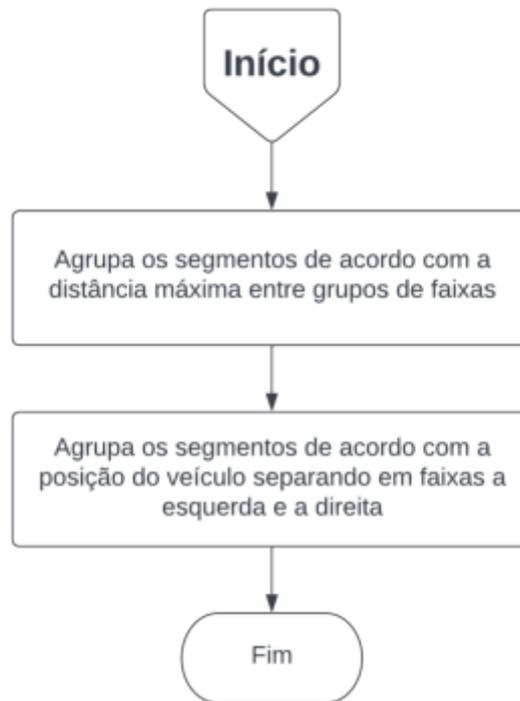
Esta etapa consiste no processo de identificação e classificação das faixas que determina quais são as retas que estão mais próximas do veículo, tanto do lado esquerdo quanto ao lado direito, como é mostrado na Figura 31. Para fazer essa identificação é seguido o fluxo demonstrado na figura 32.

Figura 31 – Identificação das faixas horizontais.



Fonte: Adaptado (Paula, 2020).

Figura 32 – Diagrama para identificação das faixas horizontais.



Fonte: Elaborado pelo autor.

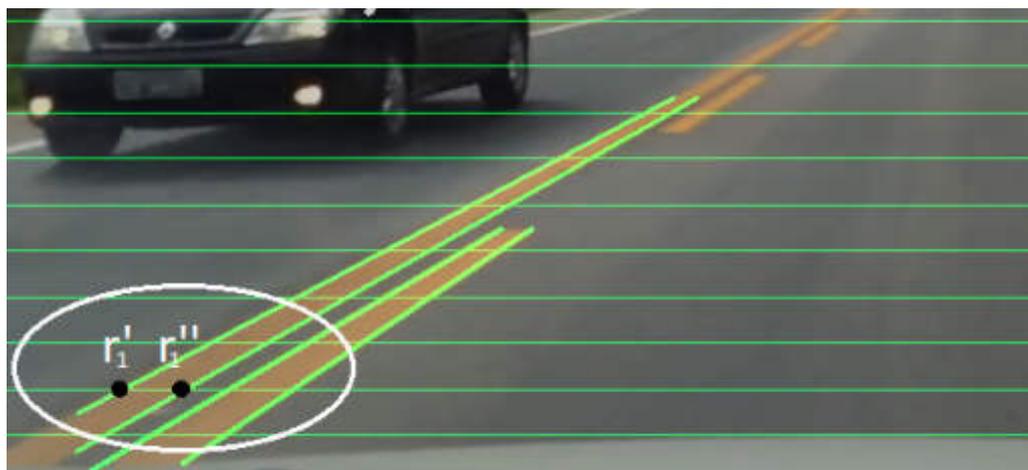
#### 4.4.1 Agrupamento dos segmentos de acordo com a distância entre grupos

Para a identificação das faixas é agrupado os segmentos de acordo com a distância máxima em que uma de faixa deve ter em relação a distância das outras faixas identificadas. Desta forma, faixas que estão dentro deste limite entram em um grupo conforme é demonstrado pela Equação 8. Onde  $r''$  é a faixa à direita da faixa  $r'$  e  $D_{max}$  a distância máxima entre os grupos.

$$\begin{aligned} \Delta &= r_1'' - r_1' \\ \Delta &< D_{max} \end{aligned} \quad (8)$$

Para definir os valores de  $r'$  e  $r''$  é dividido a imagem em dez partes iguais através de linhas horizontais. Logo após, é identificado em qual destas faixas intercepta tanto a reta  $r'$  quanto a reta  $r''$ . A partir da interceptação desta reta aos segmentos, é selecionado os pontos  $r_1''$  e  $r_1'$  como é mostrado na Figura 33.

Deste modo, é possível calcular de forma mais precisa a distância entre as retas sem o efeito da perspectiva. Já que, se fosse avaliado apenas a coordenada  $x$  dos segmentos os pontos que estão muito acima em relação ao eixo  $y$  seriam identificados como próximos.

Figura 33 – Definição dos pontos  $r_1'$  e  $r_1''$ .

Fonte: Adaptado Paula (2020).

#### 4.4.2 Agrupamento dos segmentos de acordo com a posição do veículo

Já nesta etapa, é identificado o primeiro grupo à esquerda e o primeiro grupo à direita em relação a câmera que está no centro do para-brisa do veículo. Para isto, é calculado o valor central da ROI, conforme mostrado pela Equação 9 e mostrado na Figura 34. Ao qual,  $ROI_c$  é o valor do centro da ROI e  $largura_{img}$  é o tamanho da largura da imagem.

$$ROI_c = \frac{largura_{img}}{2} \quad (9)$$

Figura 34 – Centro da ROI para identificação das faixas à esquerda e a direita.



Fonte: Adaptado (Paula, 2020).

Assim, é comparado os pontos das faixas de trânsito com o ponto central da ROI, valores inferiores ao ponto central são classificados como o grupo da faixa da esquerda e os superiores como o grupo da direita.

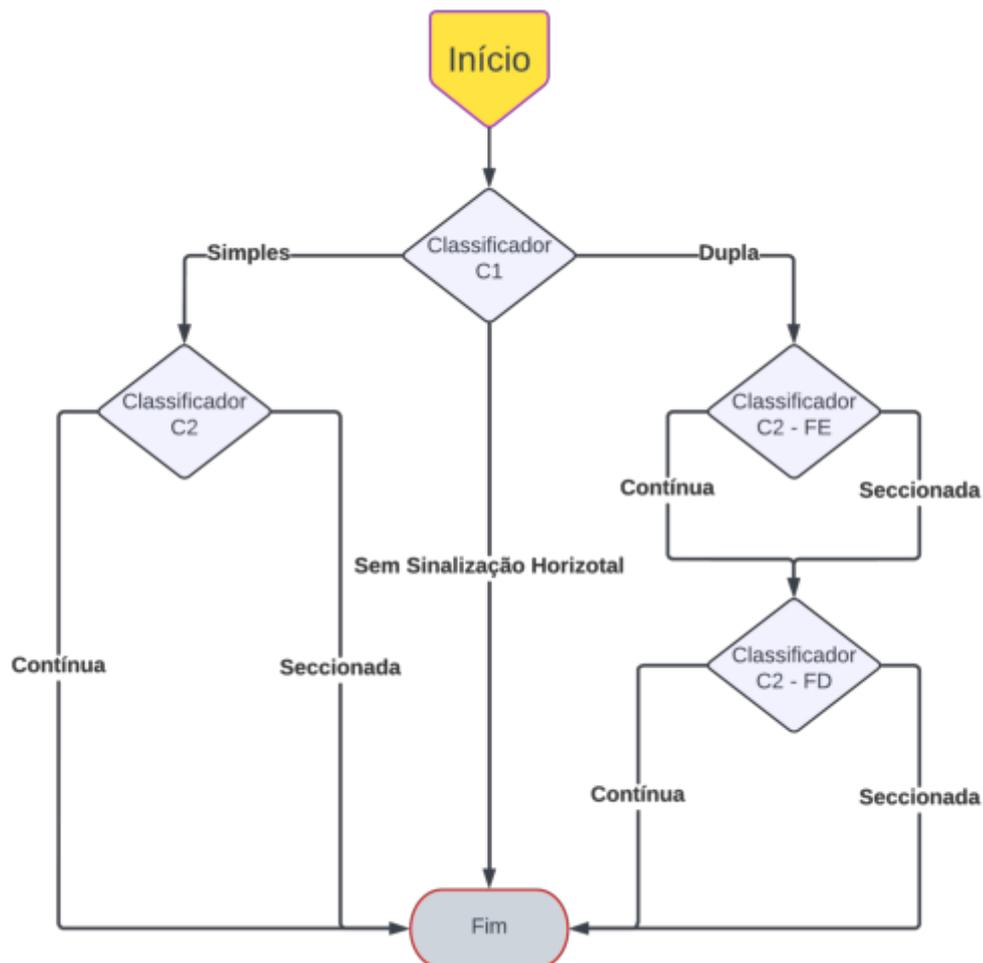
## 4.5 Classificação dos grupos de linhas

Formado os grupos de faixas à esquerda e a direita do veículo agora é possível classificar os tipos de faixas. A lista abaixo mostra todas as possibilidades possíveis que uma faixa pode ser classificada.

- **Faixa simples:** Contínua, Seccionada;
- **Faixa dupla:** Contínua/Contínua, Contínua/Seccionada, Seccionada/Contínua, Seccionada/Seccionada;
- **Sem marcação de faixa horizontal.**

O diagrama de fluxo abaixo mostra dois tipos de classificadores, sendo o C1 que tem como função identificar se a faixa é simples (apenas uma faixa) ou se a faixa é dupla e também verifica se não há sinalização horizontal. E o classificador C2 identifica se a faixa é contínua ou se é seccionada. No fluxograma identificado pela Figura 35, 'FE' significa o processamento da faixa da esquerda e 'FD' o processamento da faixa da direita, para o grupo de linhas identificado como faixa dupla.

Figura 35 – Diagrama de fluxo para classificação das faixas.

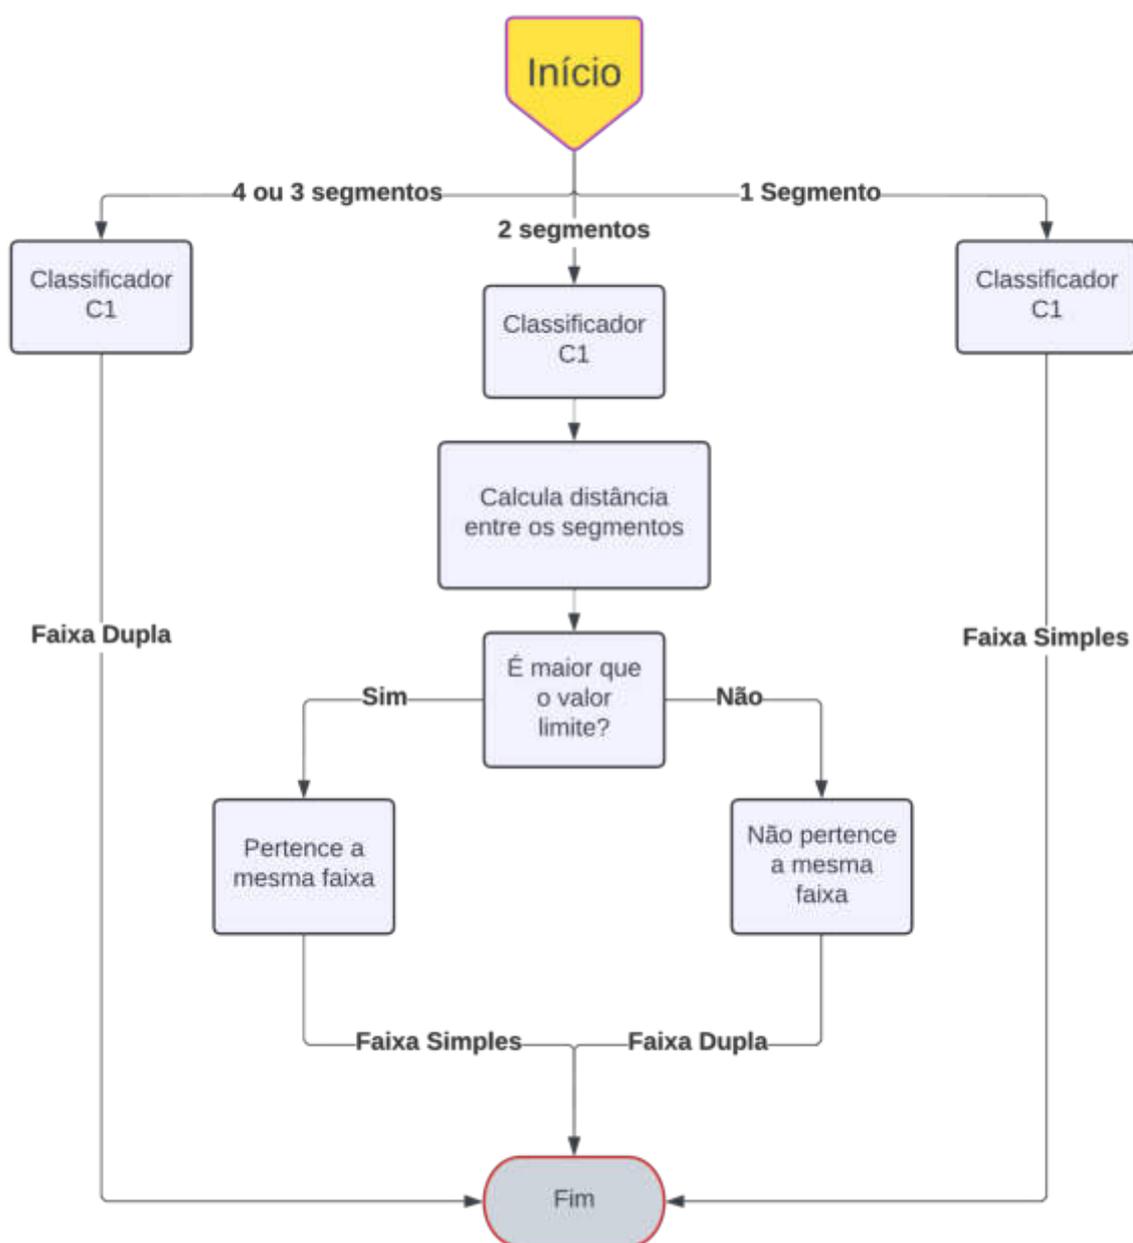


Fonte: Elaborado pelo autor.

### 4.5.1 Classificador C1

O classificador C1 tem como função identificar as faixas simples, duplas ou inexistentes. Para isso, ele verifica a quantidade de linhas encontradas e caso encontre dois segmentos é calculado a distância entre as linhas, a fim de averiguar em qual faixa o segmento se encontra, devido ao fato de que uma das retas que compõem a faixa pode não ter sido identificada. O diagrama é mostrado na Figura 36 abaixo.

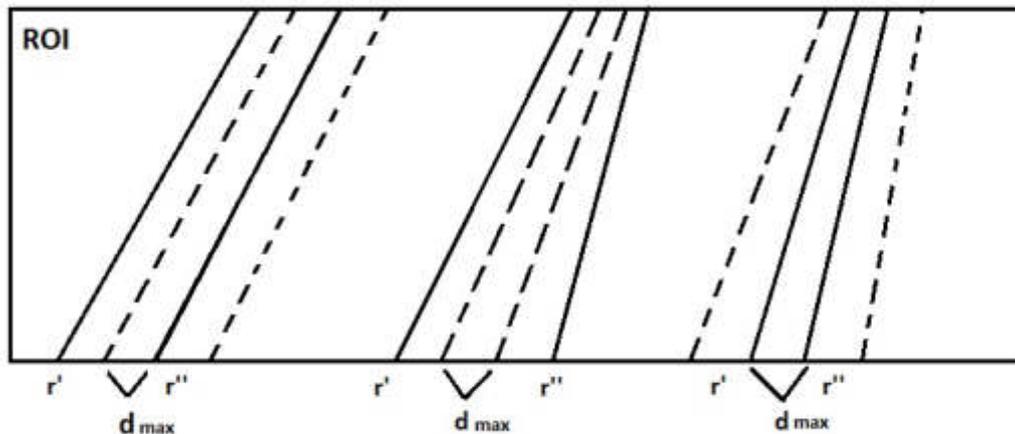
Figura 36 – Esquema do funcionamento do classificador C1.



Fonte: Elaborado pelo autor.

O cálculo da distância é realizado devido a possibilidade do algoritmo detectar apenas uma parte da linha da faixa horizontal, como ilustrado na Figura 37. As linhas que são pontilhadas ilustram a que ocorreu uma falha na identificação e as linhas contínuas são as linhas identificadas. Já o parâmetro  $d_{max}$  indica a distância máxima entre as linhas, assim sendo, quando a distância entre as linhas é menor que este parâmetro é classificada como pertencente a mesma faixa.

Figura 37 – Ilustração das possíveis maneiras em que ocorre a falha na detecção de uma linha.



Fonte: Elaborado pelo autor.

Em algumas situações pode ocorrer a falha na identificação de todas as linhas. Assim, o classificador C1 possui uma condição em que mantém o resultado por quadro quadros caso não seja possível ser encontrada nenhuma linha. Acima disto, é identificado que a rodovia não possui sinalização horizontal.

#### 4.5.2 Classificador C2

Já o classificador C2 tem como função identificar se uma faixa é contínua ou seccionada. Para isso, a ROI foi dividida em dez partes iguais conforme mostrado na Figura 38.

Figura 38 – Faixas horizontais que dividem a ROI.

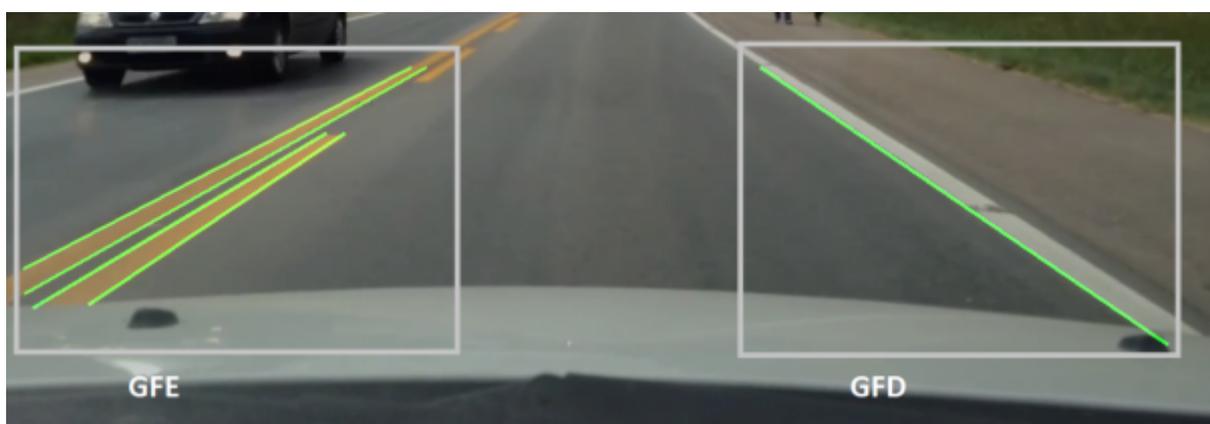


Fonte: Elaborado pelo autor.

Logo após, é ordenado as faixas de acordo com a interceptação da reta as faixas, este método foi explicado na Subseção 4.4.1. Assim, definido os pontos  $r'$  e  $r''$  é possível saber a posição das linhas e ordenar o grupo de linhas da faixa da esquerda e da direita.

Com as linhas ordenadas, agora é possível classificar os dois grupos de faixas, o grupo de faixas da esquerda (GFE) e o grupo de faixas da direita (GFD), estes são ilustrados na Figura 39. O procedimento é parecido com o classificador C1, é verificado a quantidade de linhas para cada grupo e também pode ser calculado a distância das linhas do grupo a depender de cada caso.

Figura 39 – Demonstração dos grupos de faixa localizadas a esquerda e a direita do veículo.



Fonte: Elaborado pelo autor.

**Caso 1:** Quando o grupo possui apenas uma linha é uma faixa simples que já está pronta para ser classificada.

**Caso 2:** Quando o grupo possui duas linhas é calculado a distância entre as faixas e é verificado se o valor da distância é maior que o valor limite  $d_{max}$ , se for maior é classificado as linhas como sendo pertencentes a faixas diferentes, caso contrário é classificado como pertencente a mesma faixa.

**Caso 3:** Quando o grupo possui três linhas é calculado a distância entre as linhas e é verificado qual das duas distâncias é a menor em relação a linha do meio, se a distância da linha comparada com a linha do meio for menor então essa linha é pertencente a faixa comparada.

**Caso 4:** Quando o grupo possui quatro linhas é uma faixa dupla que já está pronta para ser classificada.

Por fim, o classificador C2 analisa a intersecção de cada faixa com as dez linhas horizontais, caso a linha tenha sete ou mais pontos interceptados pelas linhas horizontais é classificado como uma faixa contínua, senão é classificado como uma faixa seccionada. E se a faixa a ser classificada for identificado mais de uma linha, a linha que tiver com o maior número de intersecções é a faixa que definirá a classificação.

## 4.6 Estabilização da classificação

A falta de regularidade do asfalto, as más condições da via e até mesmo a falta de uma iluminação correta, podem causar ruídos no processamento das imagens. Isto pode acarretar uma classificação incorreta das faixas horizontais de trânsito, pelo fato de que pode ser identificado uma faixa a mais, não ser identificado uma faixa ou classificar a faixa como sendo contínua ou seccionada de maneira inexata.

Para solucionar isso foi implementado a solução um método de estabilização do resultado do processamento. Como geralmente a base de dados possui uma quantidade grande de quadros por segundo (30fps), foi implementado um *buffer* contendo 25 informações dos últimos quadros, como é possível ver na Tabela 3. Onde, 'c' significa que a faixa foi classificada como contínua e 's' como seccionada.

Tabela 3 – Resultado da classificação das faixas com ruídos.

Quadro	0	1	2	3	4	5	6	7	8	9	10	11	12
Saída(q)	c	c	c	c	c	c	c	c	s	s	c	c	c
Quadro	13	14	15	16	17	18	19	20	21	22	23	24	X
Saída(q)	c	c	c	c	c	c	c	s	s	c	c	c	X

Deste modo, é possível perceber que no quadro 7 ao quadro 9 o algoritmo detectou a faixa como seccionada e logo nos quadros seguintes é classificado como contínua. Mas, é impossível que aconteça uma troca de faixas em um intervalo tão curto. Assim, com uma quantidade grande de amostras é possível calcular a estabilização do sistema em relação ao resultado da classificação dos quadros anteriores.

Este cálculo é feito contando a quantidade de cada classificação e depois é analisado qual classificação tem o maior número de representação, assim a faixa será classificada como a que tem o maior número de representações dentro do *buffer*. Como por exemplo, na tabela 3, há 21 resultados de faixas contínuas e de 4 faixas seccionadas, quando o próximo quadro é classificado como sendo uma faixa seccionada é armazenado no *buffer* e a faixa é classificada como contínua, pelo fato de que a faixa contínua tem o maior número de representações.

E para cada classificador, foi implementado uma função para estabilização, tendo como parâmetro o resultado da classificação e o grupo de faixas a ser classificado que é GFE ou GFD.

## 5 Resultados Experimentais

Para a análise da solução foram utilizados vídeos da base de dados de trabalhos relacionadas e vídeos das rodovias de Minas Gerais disponíveis na *internet*. Também foi utilizado algumas métricas para a análise do desempenho como a matriz de confusão e métodos estatísticos para cálculo da acurácia do algoritmo.

### 5.1 Matriz de confusão

Segundo [Deng et al. \(2016\)](#), a matriz de confusão é um conceito de aprendizado de máquina que possui informações reais e previstas feitas por um sistema de classificação. Essa matriz possui duas dimensões, a primeira é indexada pela classe de dados reais enquanto a outra é indexada pelos dados que o classificador prevê. A Tabela 4 apresenta a matriz de confusão, com as classes  $A_1$ ,  $A_2$  e  $A_n$ . Na matriz de confusão,  $N_{ij}$  é o número de amostras pertencentes as classes  $A_i$ , mas classificadas como  $A_j$ .

Tabela 4 – Estrutura da matriz de confusão para uma tarefa de classificação multiclasse.

		Previsto		
		$A_1$	... $A_j$ ...	$A_n$
Real	$A_1$	$N_{11}$	$N_{1j}$	$N_{1n}$
	.		.	
	.		.	
	$A_i$	$N_{i1}$	... $N_{ij}$ ...	$N_{in}$
	.		.	
.		.		
.		.		
$A_n$	$N_{n1}$	$N_{nj}$	$N_{nn}$	

Fonte: Adaptado ([DENG et al., 2016](#)).

$$\text{Acurácia} = \frac{\sum_{i=1}^n N_{ii}}{\sum_{i=1}^n \sum_{j=1}^n N_{ij}} \quad (10)$$

Várias medidas para o cálculo do desempenho podem ser medidas com base na matriz de confusão, mas a que será abordado neste trabalho é a taxa de acurácia definida pela Equação 10. Onde, a acurácia corresponde ao valor do total de previsões classificadas corretamente dividido pelo total de todas as amostras testadas.

## 5.2 Validação do processamento das imagens

Para validar as saídas do processamento das imagens foi criado dois arquivos no formato "txt", um que armazena as informações dos tipos de faixa simples e dupla e o outro que armazena as informações das faixas contínuas e seccionadas. Os dados presentes nestes arquivos foram adicionados contendo o código e a abreviação das faixas, mostrado na Tabela 5 e 6. E para cada quadro do vídeo foi analisado tanto a faixa da esquerda quanto a faixa da direita por um operador e foram salvos estes dados nos arquivos.

Tabela 5 – Abreviação das classificações das faixas.

<b>Código</b>	<b>Tipo de Faixa</b>
1	Simple
2	Dupla
-	Sem sinalização

Tabela 6 – Abreviação das classificações das faixas.

<b>Abreviação</b>	<b>Tipo de Faixa</b>
c	Contínua
s	Seccionada
cc	Contínua/Contínua
cs	Contínua/Seccionada
sc	Seccionada/Contínua
ss	Secciona/Seccionada
-	Sem sinalização

Em cada classificador sendo o C1 e o C2 é lido um arquivo que armazena os dados reais. E logo após é comparado com o resultado na saída dos classificadores C1 e C2. O resultado desta comparação irá ser armazenado para posteriormente ser gerado as matrizes do resultado geral e das matrizes de confusão para os classificadores. A Figura 40 abaixo mostra a estrutura destes arquivos, sendo que, a numeração de cada linha representa o quadro a ser analisado.

Figura 40 – Estrutura dos arquivos que contém os dados reais.

(a) Dados das faixas duplas e simples.      (b) Dados das faixas contínuas e seccionadas.

1	2	1	1	CS	C
2	2	1	2	CS	C
3	2	1	3	CS	C
4	2	1	4	CS	C
5	2	1	5	CS	C
6	2	1	6	CS	C
7	2	1	7	CS	C
8	2	1	8	CS	C
9	2	1	9	CS	C
10	2	1	10	CS	C

Fonte: Elaborado pelo autor.

### 5.3 Experimento 1

No vídeo 'clip\_iPad\_DMA190414\_' mostrado no trabalho de [Paula e Jung \(2015\)](#) disponibilizado por [Paula \(2020\)](#) no YouTube, contém 1500 quadros com a resolução de 1280x720 pixels com 15 quadros/s e a resolução utilizada no pré-processamento foi de 1200x650. O vídeo foi gravado a luz do dia com o veículo trafegando em linha reta. As faixas à direita do veículo ao longo do vídeo vão mudando de simples para dupla assim como também muda de seccionada para contínua e a faixa à esquerda permanece como simples e contínua durante todo o vídeo. Na Figura 41 abaixo é mostrado um quadro do vídeo.

Figura 41 – Captura de um quadro do vídeo "clip\_iPad\_DMA190414\_".



Fonte: ([Paula, 2020](#))

Nas tabelas e nos gráficos abaixo, é mostrado o resultado do classificador C1 que identifica os tipos de faixas simples e dupla.

Figura 42 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C1 para o vídeo 1.

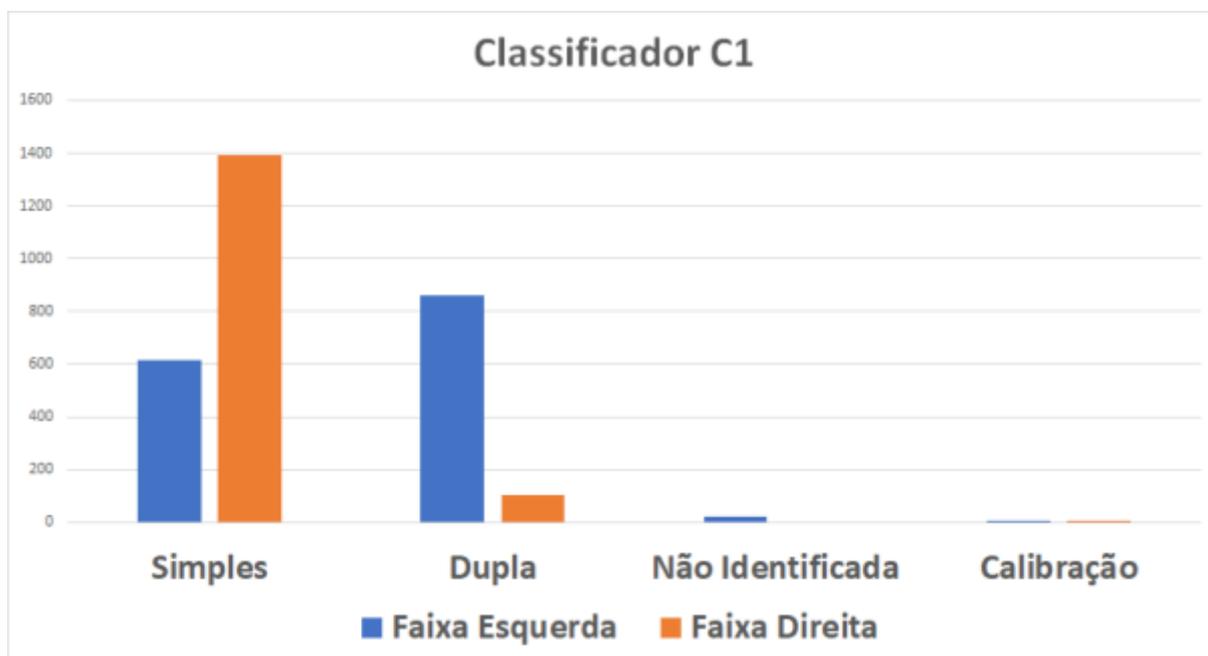


Tabela 7 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 1.

	Simples	Dupla
Simples	590	41
Dupla	25	818
<b>Taxa de acerto: 93,87%</b>		

Tabela 8 – Matriz de confusão da faixa à direita do classificador C1 para o vídeo 1.

	Simples	Dupla
Simples	1391	101
Dupla	0	0
<b>Taxa de acerto: 93,00%</b>		

Os gráficos e as tabelas a seguir é mostrado o resultado do processamento do classificador C2 que tem como função identificar se uma faixa é contínua ou seccionada.

Figura 43 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C2 para o vídeo 1.

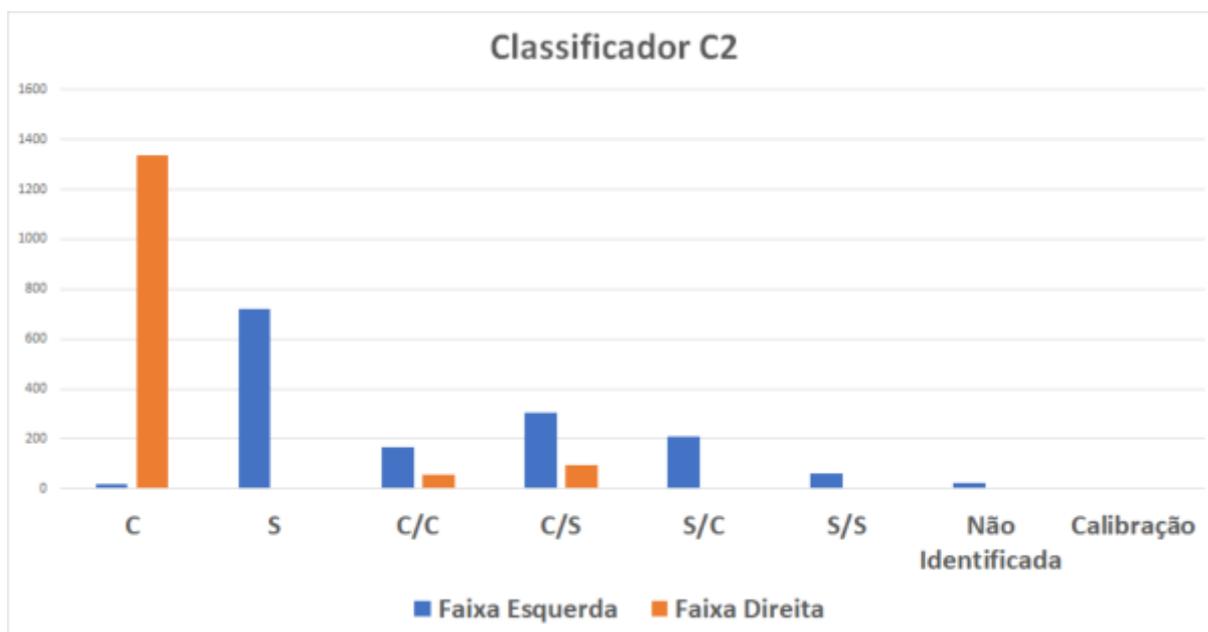


Tabela 9 – Matriz de confusão da faixa à esquerda do classificador C2 para o vídeo 1.

	<b>C</b>	<b>S</b>	<b>C/C</b>	<b>C/S</b>	<b>S/C</b>	<b>S/S</b>
<b>C</b>	0	9	3	3	3	0
<b>S</b>	0	613	45	56	4	0
<b>C/C</b>	0	0	135	21	10	0
<b>C/S</b>	0	0	18	283	2	0
<b>S/C</b>	0	0	94	7	107	0
<b>S/S</b>	0	9	29	19	4	0
<b>Acurácia: 75,87%</b>						

Assim, a solução de modo geral atingiu a acurácia média de 81,04%. Para a faixa à esquerda do veículo, a acurácia atingida foi de 73,13% e para faixa à direita a acurácia de 88,94%. Estas porcentagens são definidas através do classificador C1 e do classificador C2, quando ambos acertam o valor real. Em comparação com o trabalho de [Paula e Jung \(2015\)](#) que utilizou uma inteligência artificial para classificação, foi atingido o valor de 99,57%, com a resolução do vídeo em 1080x1920. A Figura 44 abaixo, mostra o resultado do processamento de um quadro da imagem feito pela solução proposta.

Tabela 10 – Matriz de confusão da faixa à direita do classificador C2 para o vídeo 1.

	<b>C</b>	<b>S</b>	<b>C/C</b>	<b>C/S</b>	<b>S/C</b>	<b>S/S</b>
<b>C</b>	1334	0	0	0	0	0
<b>S</b>	2	0	0	0	0	0
<b>C/C</b>	59	0	0	0	0	0
<b>C/S</b>	95	0	0	0	0	0
<b>S/C</b>	6	0	0	0	0	0
<b>S/S</b>	0	0	0	0	0	0
<b>Acurácia: 88,95%</b>						

Figura 44 – Captura de um quadro do vídeo 'clip\_iPad\_DMA190414\_' classificado pela solução.

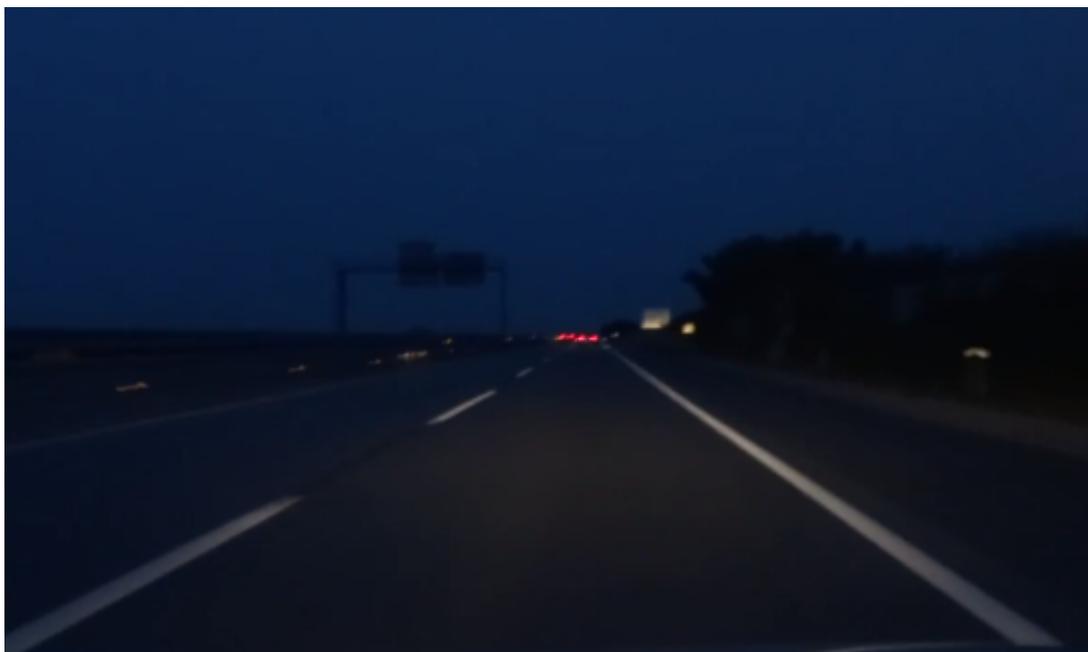


Fonte: Adptado (Paula, 2020).

## 5.4 Experimento 2

O vídeo disponibilizado em um canal do YouTube por [FightFCGIFU \(2013\)](#), mostra as ruas das cidades de Incheon e Busan na Coreia do Sul. E para o teste foi utilizado o intervalo a partir 16m até 16m50s que contém imagens noturnas com baixa luminosidade. Este vídeo possui 1519 quadros com a resolução de 1280x720 e taxa de exibição de 30 quadros/s, no pré-processamento a imagem foi redimensionada para resolução de 1100x560. A Figura 45 abaixo demonstra um quadro retirado do vídeo em questão.

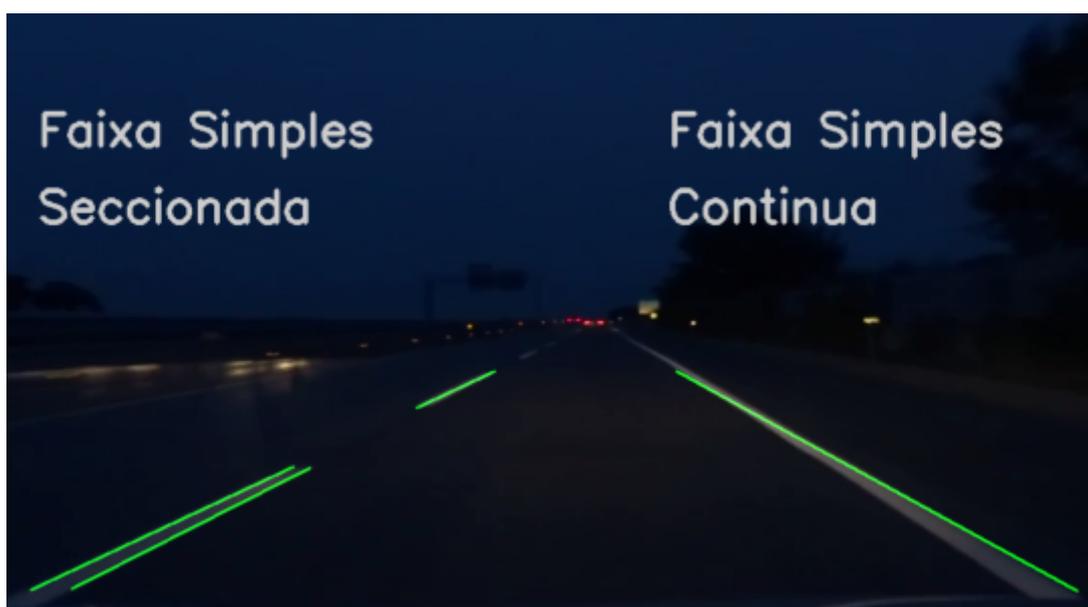
Figura 45 – Captura de um quadro do vídeo do segundo experimento em baixa luminosidade.



Fonte: (FIGHTFCGIFU, 2013).

Durante o percurso do veículo a faixa à esquerda permanece como seccionada durante todo o vídeo assim como também permanece a faixa à direita. A Figura 46 exibe um exemplo da classificação das faixas juntamente com as tabelas e os gráficos abaixo que demonstram o desempenho das classificações.

Figura 46 – Captura de um quadro do vídeo em baixa luminosidade .



Fonte: Adaptado (FIGHTFCGIFU, 2013).

Este vídeo também foi utilizado e testado com o método apresentado por JÚNIOR

Figura 47 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C1 para o vídeo 2.

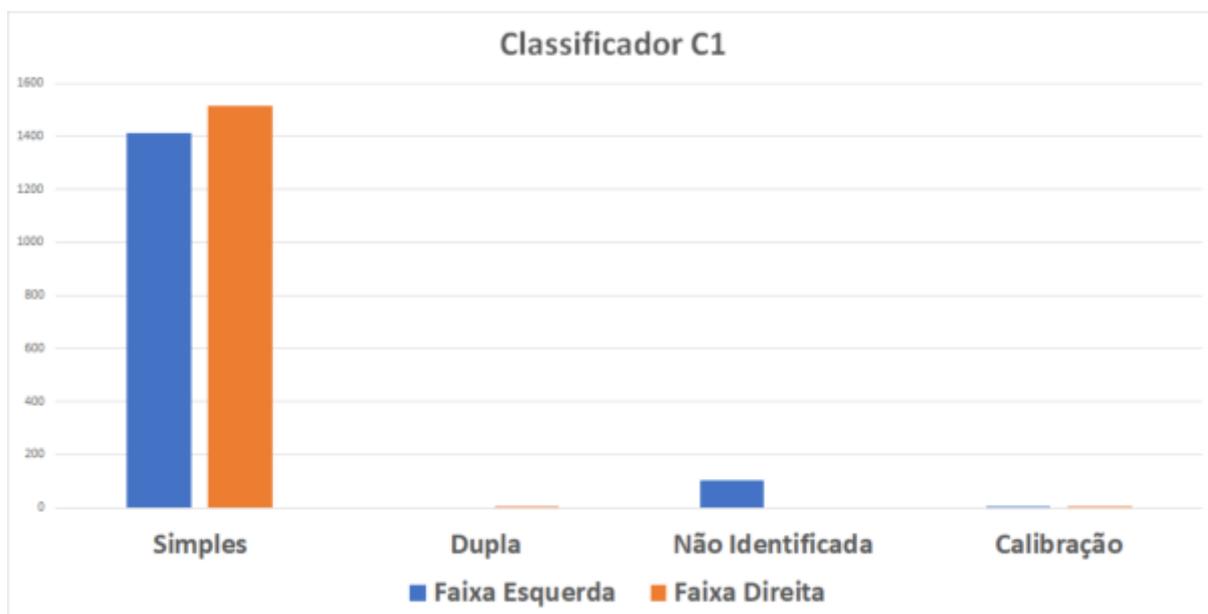


Tabela 11 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 3.

	Simples	Dupla
Simples	1410	0
Dupla	0	0
<b>Taxa de acerto: 92,88%</b>		

Tabela 12 – Matriz de confusão da faixa à direita do classificador C1 para o vídeo 2.

	Simples	Dupla
Simples	1512	2
Dupla	0	0
<b>Taxa de acerto: 99,60%</b>		

Tabela 13 – Matriz de confusão da faixa à esquerda do classificador C2 para o vídeo 2.

	C	S	C/C	C/S	S/C	S/S
C	0	32	0	0	0	0
S	0	1333	0	0	0	0
C/C	0	0	0	0	0	0
C/S	0	1	0	0	0	0
S/C	0	0	0	0	0	0
S/S	0	44	0	0	0	0
<b>Acurácia: 87,81%</b>						

Figura 48 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C2 para o vídeo 2.

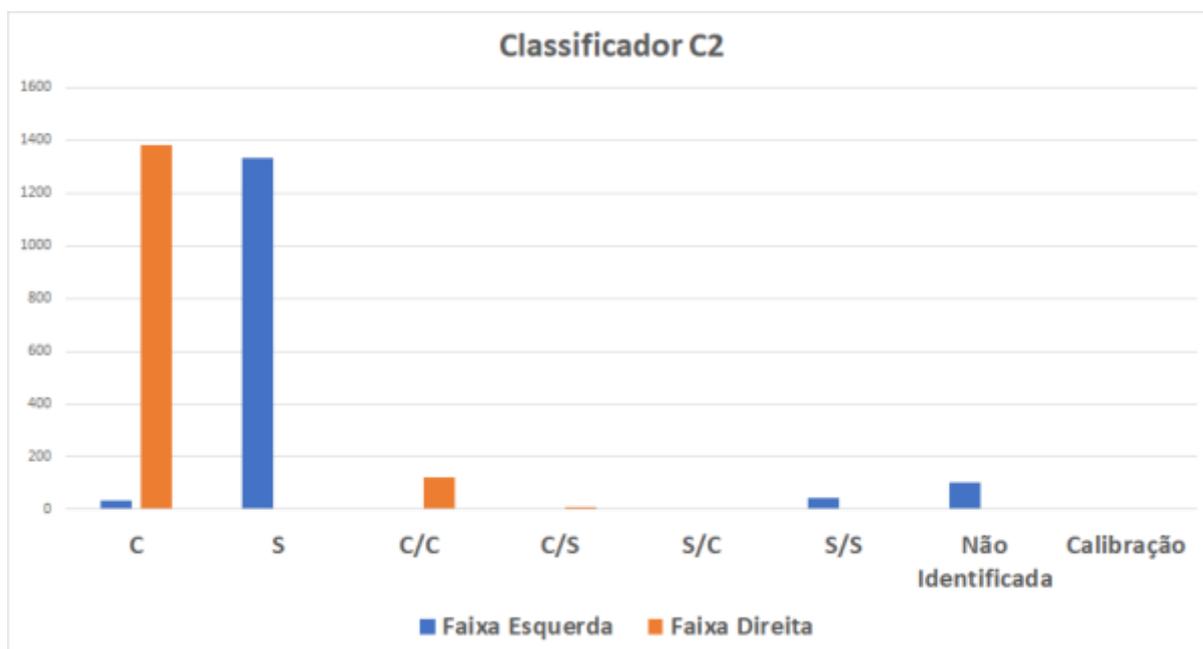


Tabela 14 – Matriz de confusão da faixa à direita do classificador C2 para o vídeo 2.

	<b>C</b>	<b>S</b>	<b>C/C</b>	<b>C/S</b>	<b>S/C</b>	<b>S/S</b>
<b>C</b>	1379	0	0	0	0	0
<b>S</b>	0	0	0	0	0	0
<b>C/C</b>	122	0	0	0	0	0
<b>C/S</b>	8	0	0	0	0	0
<b>S/C</b>	3	0	0	0	0	0
<b>S/S</b>	2	0	0	0	0	0
<b>Acurácia: 90,84%</b>						

(2016), no qual, atingiu a acurácia média de 86,58%. O intervalo de imagens não foi apresentado, mas foi utilizado 1185 quadros com a resolução de 640x360. Em comparação com o método que está sendo proposto, a acurácia média foi de 89,33%. Para a faixa à esquerda do veículo a taxa de acerto foi de 87,81% enquanto para a faixa à direita foi de 90,84%. Durante os testes com essas imagens noturnas foi percebido um ruído maior na identificação das faixas em comparação com imagens diurnas, no qual, para as imagens com pouca iluminação foi identificado muitas linhas duplas ou até mesmo a falta de identificação da faixa.

## 5.5 Experimento 3

Para o terceiro experimento foi utilizado o vídeo feito por [Leandro \(2022\)](#) e disponibilizado no YouTube, neste vídeo foi selecionado o trecho da região de Guararema em São Paulo na divisa das rodovias Airton Senna e Governador Carvalho Pinto, onde o intervalo de tempo do vídeo testado foi de 4m05s até 4m41s. Neste trecho o veículo trafega em linha reta com algumas curvas suaves. O vídeo contém 1073 quadros com a resolução de 1920x1080 e taxa de exibição de 30 quadros/s. No pré-processamento a imagem foi redimensionada para resolução de 1300x800. A Figura 49 abaixo mostra um quadro do vídeo.

Durante todo o percurso o veículo trafega na rodovia que contém a faixa à esquerda contínua e a faixa a direita seccionada, ambas sendo faixas simples. A Figura 50 exibe um exemplo da classificação das faixas juntamente com as tabelas e os gráficos que demonstram o resultado das classificações.

Figura 49 – Captura de um quadro do vídeo do terceiro experimento.



Fonte: Adaptado ([LEANDRO, 2022](#)).

Figura 50 – Captura de um quadro do vídeo do terceiro experimento com a classificação de faixas.



Fonte: Adaptado ([LEANDRO, 2022](#)).

Figura 51 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C1 para o vídeo 3.

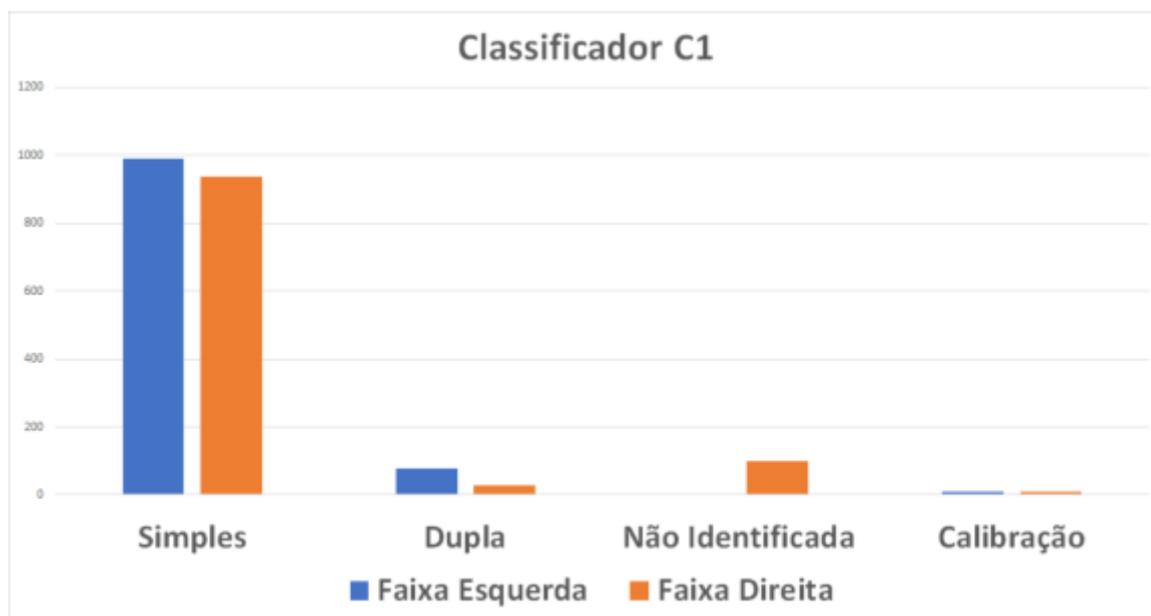


Figura 52 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C2 para o vídeo 3.

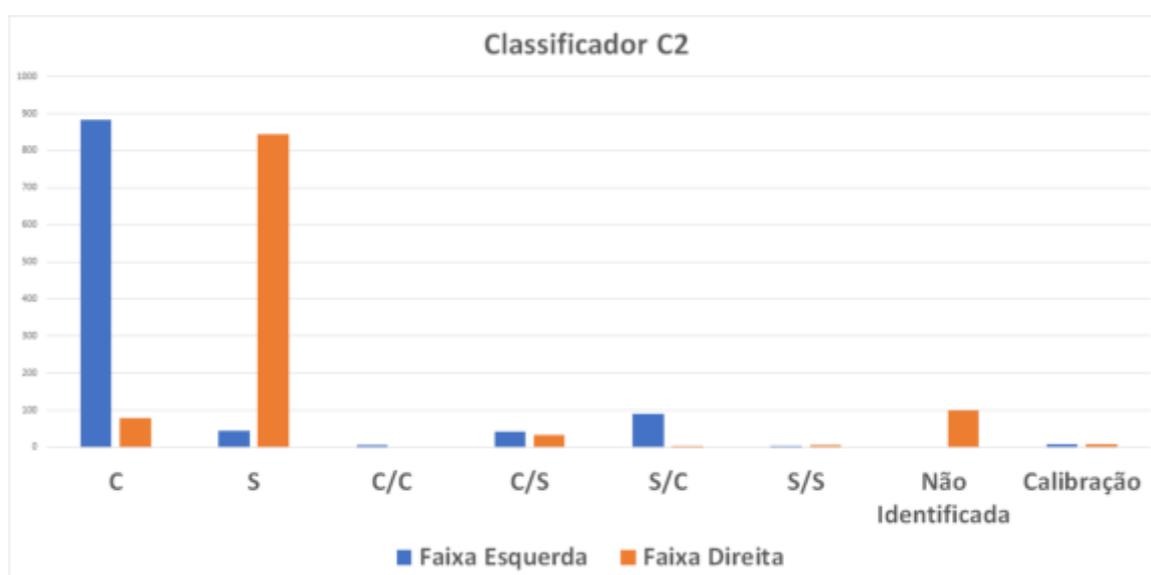


Tabela 15 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 3.

	Simples	Dupla
Simples	1410	0
Dupla	0	0
<b>Taxa de acerto: 92,88%</b>		

Tabela 16 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 3.

	<b>Simples</b>	<b>Dupla</b>
<b>Simples</b>	936	29
<b>Dupla</b>	0	0
<b>Taxa de acerto: 87,23%</b>		

Tabela 17 – Matriz de confusão da faixa à esquerda do classificador C2 para o vídeo 3.

	<b>C</b>	<b>S</b>	<b>C/C</b>	<b>C/S</b>	<b>S/C</b>	<b>S/S</b>
<b>C</b>	883	0	0	0	0	0
<b>S</b>	45	0	0	0	0	0
<b>C/C</b>	5	0	0	0	0	0
<b>C/S</b>	41	0	0	0	0	0
<b>S/C</b>	89	0	0	0	0	0
<b>S/S</b>	2	0	0	0	0	0
<b>Acurácia: 82,3%</b>						

Tabela 18 – Matriz de confusão da faixa à direita do classificador C2 para o vídeo 3.

	<b>C</b>	<b>S</b>	<b>C/C</b>	<b>C/S</b>	<b>S/C</b>	<b>S/S</b>
<b>C</b>	0	79	0	0	0	0
<b>S</b>	0	844	0	0	0	0
<b>C/C</b>	0	0	0	0	0	0
<b>C/S</b>	0	33	0	0	0	0
<b>S/C</b>	0	4	0	0	0	0
<b>S/S</b>	0	5	0	0	0	0
<b>Acurácia: 78,65%</b>						

Neste terceiro experimento a taxa de acurácia para a faixa à esquerda foi de 80,61% e para faixa à direita foi de 78,47% e acurácia média de 79,54%. Para a faixa à direita do veículo foi percebido que muitas vezes a faixa não pode ser identificada como é possível ver na Tabela ??, isso ocorreu devido a área de interesse que cobriu uma área pequena, sendo que algumas vezes a distância entre uma faixa seccionada a outra foi maior que o tamanho da região de interesse. Mas, ao aumentar a área de interesse não resolve o problema, pois com o aumento ocorre a distorção das faixas pelo efeito da perspectiva que se torna maior e que faz com que a taxa de acerto seja menor.

## 5.6 Experimento 4

Para o quarto experimento a gravação do vídeo decorreu em uma rodovia em Santa Terezinha localizada na Bahia e foi publicado por [Leandro \(2021\)](#) no YouTube, onde foi utilizado o intervalo de 8m30s até 9m10s do vídeo, possuindo uma resolução de 1920x1080 e contendo 1210 quadros com a taxa de 30 quadros/s. Para o pré-processamento a imagem foi redimensionada para resolução de 1420x555. A taxa de acurácia média alcançada foi de 77,6%, sendo que a faixa à esquerda teve a acurácia de 65,04% e a faixa à direita 90,17%.

O veículo trafega em linha reta durante todo o percurso, sendo que a faixa à direita permanece como contínua e simples durante todo o vídeo e a faixa à esquerda varia entre dupla e simples, assim como também de contínua para seccionada. Nas imagens abaixo é possível ver um trecho da via assim como também o resultado de uma classificação de um quadro. As tabelas e os gráficos mostram o desempenho da classificação.

Figura 53 – Captura de um quadro do vídeo do quarto experimento.



Fonte: Adaptado ([LEANDRO, 2021](#)).

Figura 54 – Captura de um quadro do vídeo do quarto experimento com a classificação de faixas.



Fonte: Adaptado ([LEANDRO, 2021](#)).

Figura 55 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C1 para o vídeo 4.

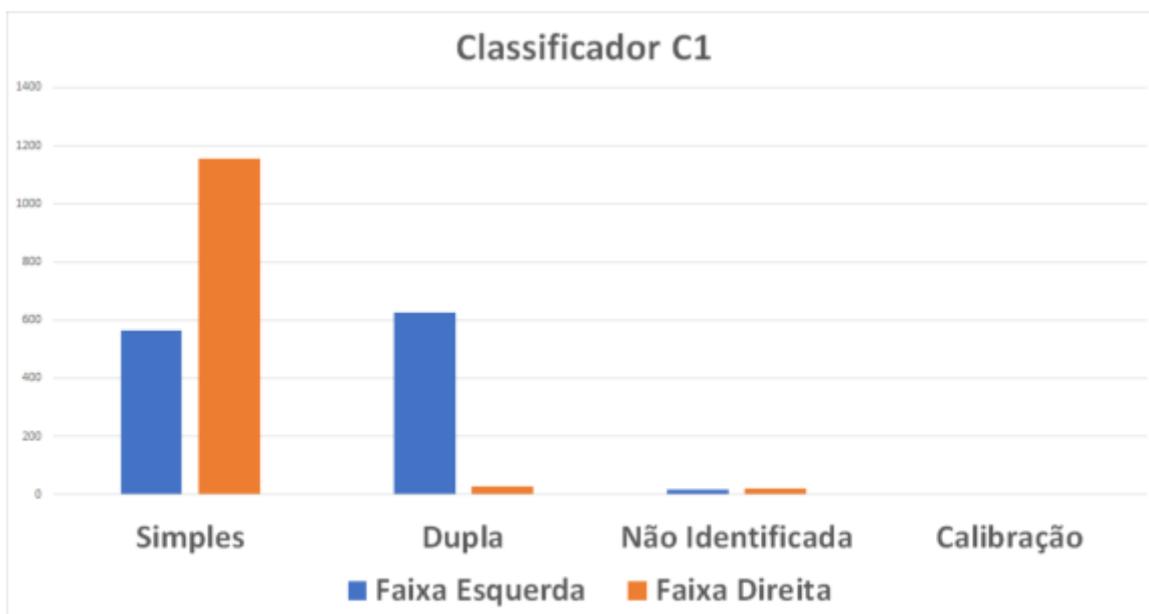


Figura 56 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C2 para o vídeo 4.

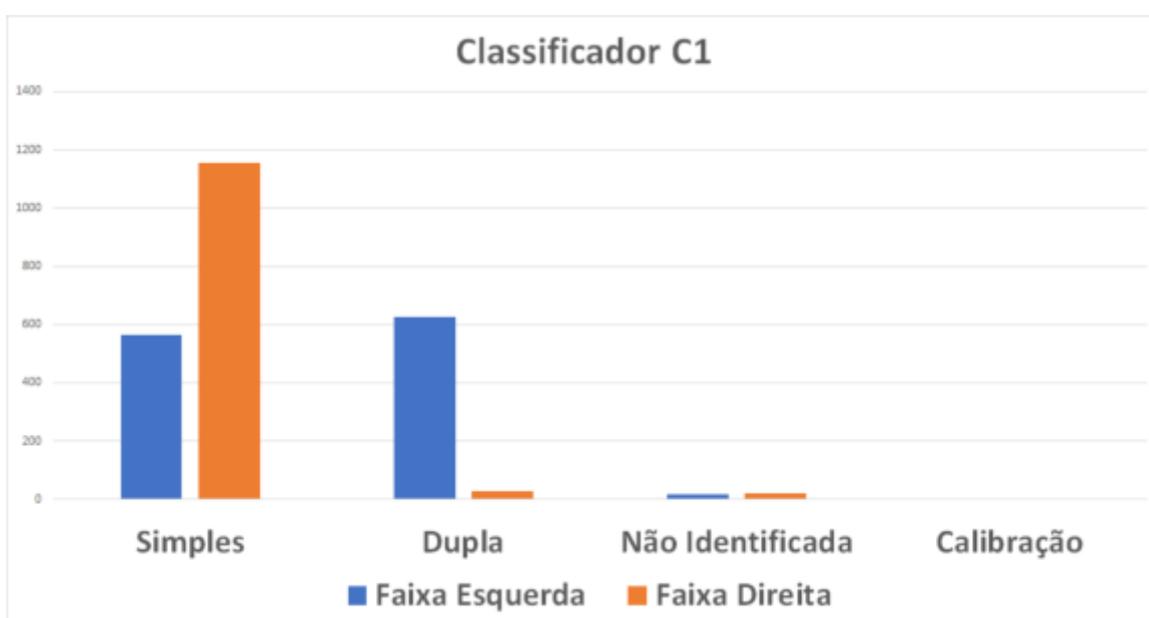


Tabela 19 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 4.

	<b>Simples</b>	<b>Dupla</b>
<b>Simples</b>	417	1
<b>Dupla</b>	146	625
<b>Taxa de acerto: 86,12%</b>		

Tabela 20 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 4.

	<b>Simple</b>	<b>Dupla</b>
<b>Simple</b>	1155	29
<b>Dupla</b>	0	0
<b>Taxa de acerto: 95,45%</b>		

Tabela 21 – Matriz de confusão da faixa à esquerda do classificador C2 para o vídeo 4.

	<b>C</b>	<b>S</b>	<b>C/C</b>	<b>C/S</b>	<b>S/C</b>	<b>S/S</b>
<b>C</b>	0	5	64	125	15	0
<b>S</b>	0	380	0	15	0	0
<b>C/C</b>	0	1	126	18	48	0
<b>C/S</b>	0	0	13	223	3	0
<b>S/C</b>	0	11	6	17	90	0
<b>S/S</b>	0	21	1	1	6	0
<b>Acurácia: 67,69%</b>						

Tabela 22 – Matriz de confusão da faixa à direita do classificador C2 para o vídeo 4.

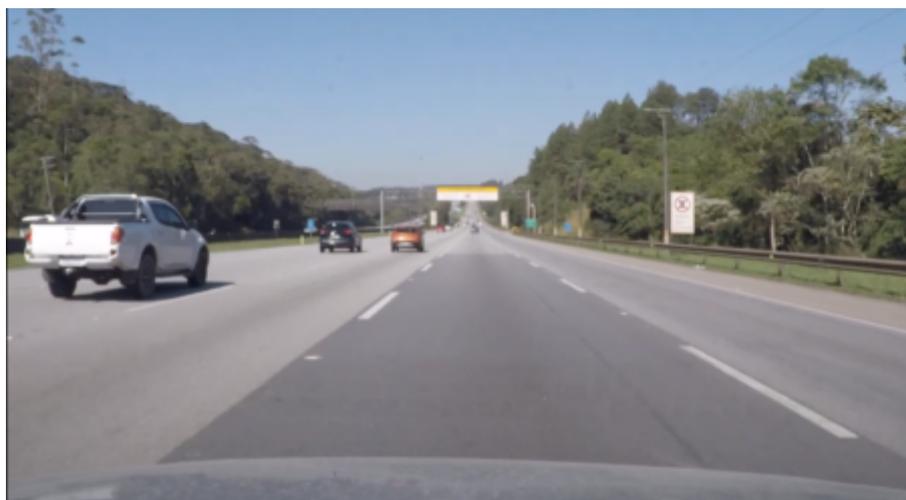
	<b>C</b>	<b>S</b>	<b>C/C</b>	<b>C/S</b>	<b>S/C</b>	<b>S/S</b>
<b>C</b>	1091	0	0	0	0	0
<b>S</b>	11	0	0	0	0	0
<b>C/C</b>	46	0	0	0	0	0
<b>C/S</b>	4	0	0	0	0	0
<b>S/C</b>	32	0	0	0	0	0
<b>S/S</b>	0	0	0	0	0	0
<b>Acurácia: 90,17%</b>						

Através dos resultados acima, é possível perceber que a faixa à esquerda do veículo teve uma taxa de acurácia abaixo dos 70%. Os fatores que causaram essa baixa taxa de acurácia quando comparado aos demais resultados foi o fato da falta de regularidade das faixas que possuem larguras diferentes e muitas vezes foi percebido algumas manchas ao centro da pista. Além disso, há uma grande quantidade de veículos trafegando a esquerda do automóvel, acarretando na classificação inexata das faixas.

## 5.7 Experimento 5

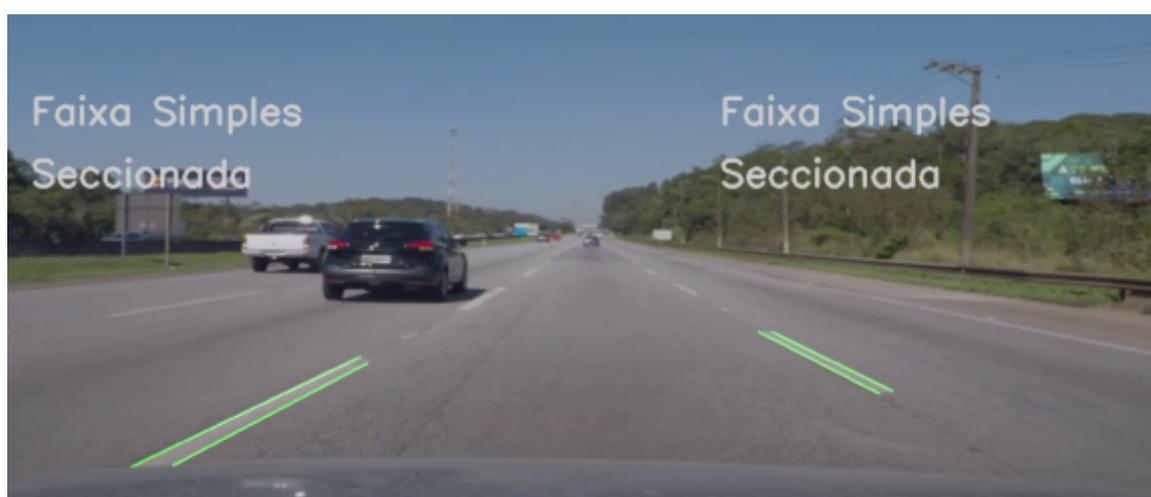
No quinto experimento, o vídeo foi gravado na Rodovia dos Imigrantes que pertence ao estado de São Paulo com 58,5 km de extensão. Ele foi gravado pelo [Tiago \(2022\)](#), onde o intervalo de tempo utilizado pelo vídeo original foi de 0m0s até 2m15s. No trecho selecionado, o carro trafega na rodovia em linha reta e por curvas suaves. Esta rodovia contém quatro pistas de rolamento com as faixas do tipo simples e seccionada, nas Figuras [57](#) e [58](#) é possível ver um trecho da rodovia e a classificação das faixas respectivamente.

Figura 57 – Captura de um quadro do vídeo do quinto experimento.



Fonte: Adaptado ([TIAGO, 2022](#)).

Figura 58 – Captura de um quadro do vídeo do quinto experimento com a classificação de faixas.



Fonte: Adaptado ([TIAGO, 2022](#)).

O vídeo contém 5277 quadros com a resolução de 1280x720 e taxa de exibição de 30 quadros/s. No pré-processamento a imagem foi redimensionada para resolução de 1300x560. As tabelas e os gráficos abaixo mostram o desempenho da classificação.

Figura 59 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C1 para o vídeo 5.

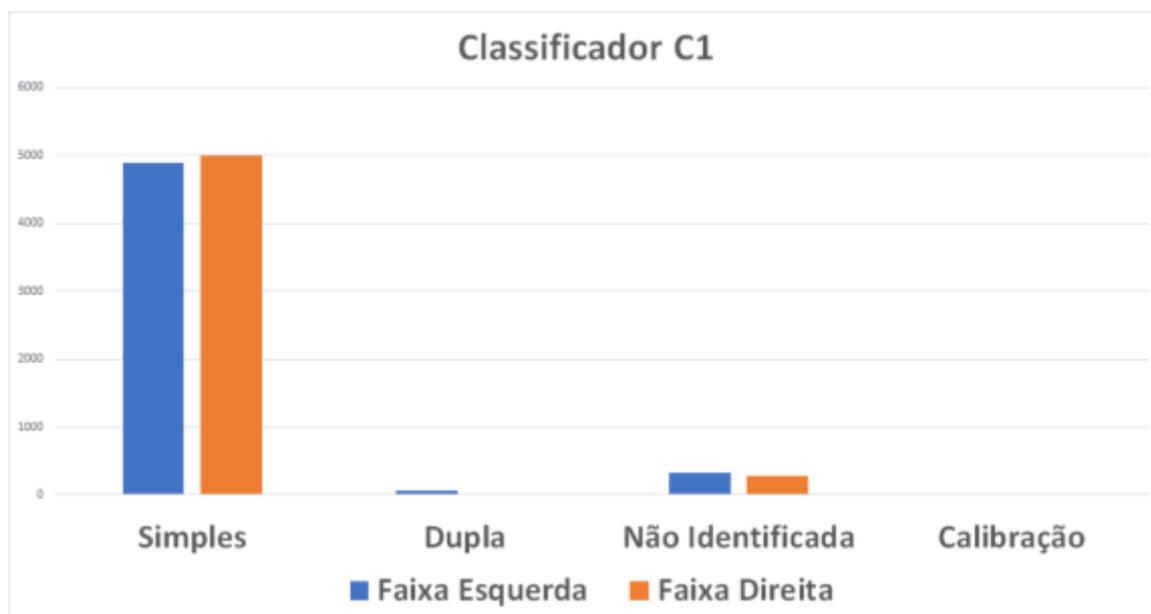


Figura 60 – Resultado geral da classificação das faixas à esquerda e à direita do veículo do classificador C2 para o vídeo 5.

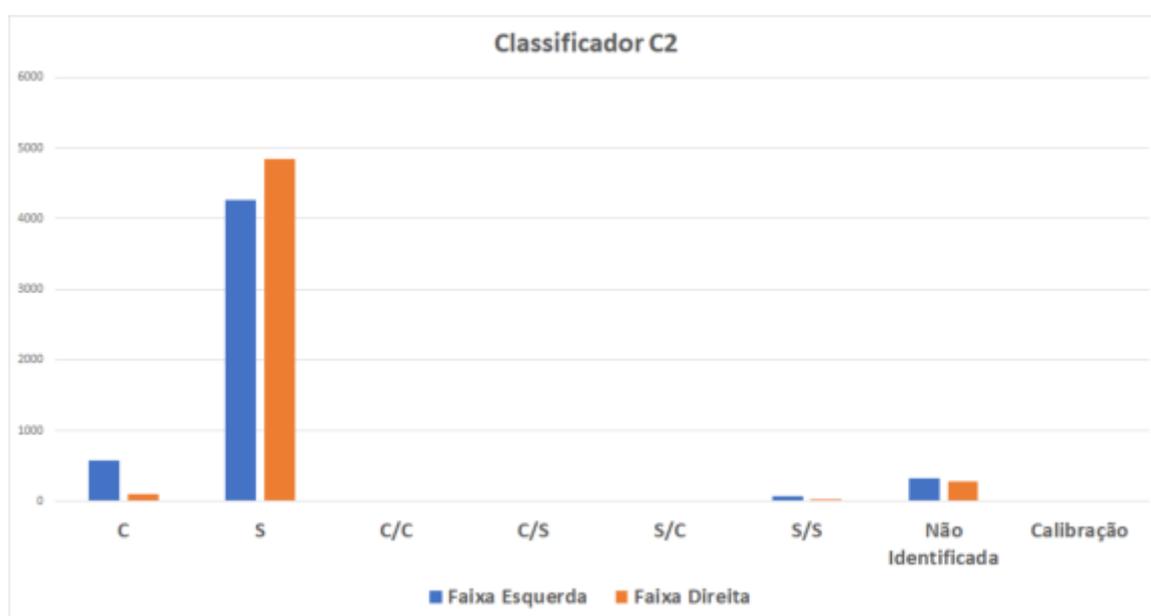


Tabela 23 – Matriz de confusão da faixa à esquerda do classificador C1 para o vídeo 5.

	Simples	Dupla
Simples	4889	56
Dupla	0	0
<b>Taxa de acerto: 92,65%</b>		

Tabela 24 – Matriz de confusão da faixa à direita do classificador C1 para o vídeo 5.

	<b>Simple</b>	<b>Dupla</b>
<b>Simple</b>	4995	0
<b>Dupla</b>	0	0
<b>Taxa de acerto: 94,66%</b>		

Tabela 25 – Matriz de confusão da faixa à esquerda do classificador C2 para o vídeo 5.

	<b>C</b>	<b>S</b>	<b>C/C</b>	<b>C/S</b>	<b>S/C</b>	<b>S/S</b>
<b>C</b>	0	576	0	0	0	0
<b>S</b>	0	4270	0	0	0	0
<b>C/C</b>	0	1	0	0	0	0
<b>C/S</b>	0	14	0	0	0	0
<b>S/C</b>	0	17	0	0	0	0
<b>S/S</b>	0	67	0	0	0	0
<b>Acurácia: 80,92%</b>						

Tabela 26 – Matriz de confusão da faixa à direita do classificador C2 para o vídeo 5.

	<b>C</b>	<b>S</b>	<b>C/C</b>	<b>C/S</b>	<b>S/C</b>	<b>S/S</b>
<b>C</b>	0	103	0	0	0	0
<b>S</b>	0	4850	0	0	0	0
<b>C/C</b>	0	0	0	0	0	0
<b>C/S</b>	0	7	0	0	0	0
<b>S/C</b>	0	0	0	0	0	0
<b>S/S</b>	0	35	0	0	0	0
<b>Acurácia: 92,00%</b>						

Neste quinto experimento a taxa de acurácia para a faixa à esquerda foi de 80,27% e para faixa à direita foi de 91,90% e acurácia média de 86,09%. Para as faixas à esquerda e a direita do veículo foi percebido que muitas vezes a faixa foi detectada como contínua, como é possível ver nas Tabelas 25 e 26, este problema ocorreu devido a intensidade da variação de gradiente da pista, no qual, em certas áreas fica com uma tonalidade mais escura de um lado e mais clara de outro. Outro fator que também gerou uma classificação inexata foi a grande quantidade de fluxo de carros e manchas de pneu na pista, o que acarretou na identificação de faixas inexistentes.

### 5.7.1 Avaliação dos resultados

O método foi submetido a cinco experimentos, a tabela 27 demonstra a acurácia alcançada pela solução e a comparação com outros estudos sobre a classificação das faixas horizontais de trânsito. Assim, a solução atingiu a acurácia média entre os cinco experimentos de 82,80%.

Tabela 27 – Tabela com o resultado de todos os cinco experimentos submetidos a solução apresentada.

Experimento	Resolução	Resolução		Acurácia Média**	Acurácia de Trabalhos Relacionados	Autor do Trabalho ***
		Pré-Processamento	Sinalizações*			
1	1280 x 720	1200 x 650	c, s, cc, cs, sc	81,04%	99,57%	Paula e Jung (2015)
2	1280 x 720	1100 x 560	c, s	89,33%	86,58%	JÚNIOR (2016)
3	1920 x 1080	1300 x 800	c, s	79,54%	-	-
4	1920 x 1080	1420 x 555	c, s, cc, cs, sc	77,66%	-	-
5	1280 x 720	1300 x 560	s	86,09%	-	-

\*Sinalizações contidas no vídeo do experimento.

\*\*Média entre a acurácia da faixa à esquerda e a direita do veículo através da classificação pelo método proposto.

\*\*\*Refere-se ao autor do trabalho correlato.

Nos resultados de Paula e Jung (2015) mostrados no Experimento 1, a taxa de acurácia atingida foi de 99,57% como é possível ver na tabela 27 enquanto a taxa de acurácia atingida pelo método proposto foi de 73,13%. Porém, existem um fator que pode ter inviabilizado a comparação direta do resultado que é a perda de qualidade ao enviar o vídeo pelo serviço de hospedagem do YouTube. Nessa condição, quando o veículo passa por uma ponte as faixas à esquerda deixam de ser detectadas ou são parcialmente detectadas, é neste trecho que o classificador teve a maior falha.

Já no Experimento 2 é avaliado a detecção das faixas no período noturno. No trabalho de JÚNIOR (2016) a taxa de acurácia atingida foi de 86,58% enquanto no método proposto foi de 89,33%. Os resultados foram próximos mostrando uma vantagem para o trabalho apresentado de 3,18%. Assim, para imagens noturnas a solução apresentou um bom resultado na classificação, apesar do alto nível ruído na identificação das faixas que não prejudicou a classificação.

## 6 Conclusão

De modo geral, a acurácia do método exposto apresenta bons resultados, quando se comparado com os trabalhos de [Paula e Jung \(2015\)](#) e de [JÚNIOR \(2016\)](#). Assim, foi atingido pela solução a acurácia média entre os experimentos de 82,80%, sendo que a maioria das classificações inexatas nos experimentos ocorreram devido as más condições da via, como manchas no asfalto e irregularidade das vias.

De acordo com o referencial teórico, com o estudo de trabalhos correlatos e nas pesquisas sobre as técnicas de visão computacional, este trabalho propôs uma solução para a classificação horizontal de trânsito. Assim, o referido trabalho descreve as técnicas de visão computacional e apresenta o cálculo da acurácia de cada um dos classificadores que compõem o método, assim como também, a acurácia para cada grupo de faixas. Com a análise destes pontos, o objetivo geral foi alcançado.

E quanto aos objetivos específicos também foram alcançados, uma vez que as técnicas utilizadas foram capazes de delimitar a área de interesse, identificar as retas que compõem as faixas, classificar as faixas e eliminar os ruídos durante a classificação através da estabilização do sistema em tempo real. Assim, foi possível classificar e avaliar a taxa de acurácia das rodovias brasileiras obtendo bons resultados, com a acurácia média entre os experimentos 3, 4 e 5 de 82%.

Como contribuição, este trabalho apresentou a detecção de bordas de Sobel aliado a técnicas de visão computacional, sendo que os métodos apresentados de trabalhos correlatos apresentava em substituição do método de Sobel a detecção de bordas de Canny ou em alguns casos apresentava o Filtro de Sobel, mas, aliado a técnicas de visão computacional e de inteligência artificial para a classificação das faixas.

No desenvolvimento desse projeto algumas dificuldades foram encontradas sendo a principal que foi a aquisição de imagens das rodovias brasileiras para compor a base de dados. Pois, muitas imagens encontradas na *internet* a câmera de bordo não se encontravam na posição ideal, impactando assim na identificação das faixas.

Outras dificuldades encontradas foram em classificar as faixas em curva acentuadas, em identificar a troca de pista de rolamento e na calibração dos parâmetros do algoritmo de forma automática, sendo estas as limitações do trabalho.

Para trabalhos futuros as seguintes melhorias são propostas:

- Implementar a identificação da troca da pista de rolamento e emitir um alerta sobre a troca irregular segundo a classificação das faixas;
- Elaborar a função de detecção de faixas em curvas acentuadas;
- Aprimorar o método para remoção de segmentos procedentes de manchas no asfalto;
- Analisar o desempenho do algoritmo em relação ao tempo de processamento e propor melhorias de otimização de performance para execução em tempo real;
- Implementar um método para calibrar os parâmetros do algoritmo de forma automática.

# Referências

- AGÊNCIA BRASIL. Mortes nas rodovias brasileiras no carnaval aumentaram 8%. 2020. Disponível em: <<https://agenciabrasil.ebc.com.br/geral/noticia/2020-02/mortes-nas-rodovias-brasileiras-no-carnaval-aumentaram-8-0>>. Acesso em: 19 abr. 2020. Citado na página 2.
- ALMEIDA, R. H. P.; CORSO, D. A.; BRITTO, A. S. Visão computacional - sistemas de visão aplicados à inspeção industrial. 2009. Disponível em: <<https://enetec.deinfo.uepg.br/trabalhos/Rubens%20Henrique%20Pailo%20de%20Almeida.pdf>>. Acesso em: 04 dez. 2020. Citado na página 22.
- ANDRADE, A. C.; FRANCISCO, C. N.; ALMEIDA, C. M. de. **Desempenho de Classificadores Paramétrico e não Paramétrico na Classificação da Fisionomia Vegetal**. Tese (Doutorado) — Universidade Federal de Pernambuco, 2013. Disponível em: <<http://www.seer.ufu.br/index.php/revistabrasileiracartografia/article/download/43917/23181/>>. Acesso em: 30 nov. 2020. Citado na página 17.
- ATLAS, D. A. N. T. B. Distribuição de acidentes por causa. 2019. Disponível em: <<https://www.atlasacidentesnotransporte.com.br/consulta?grafico=acidente#graph>>. Acesso em: 12 jul. 2022. Citado na página 2.
- CFM. Em dez anos, acidentes de trânsito consomem quase r\$ 3 bilhões do sus. 2019. Disponível em: <[https://portal.cfm.org.br/index.php?option=com\\_content&view=article&id=28254:2019-05-22-21-49-04&catid=3](https://portal.cfm.org.br/index.php?option=com_content&view=article&id=28254:2019-05-22-21-49-04&catid=3)>. Acesso em: 21 abr. 2020. Citado na página 1.
- CHAN, C.-Y. Advancements, prospects, and impacts of automated driving systems. **International Journal of Transportation Science and Technology**, v. 6, p. 208–216, 2017. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2046043017300035>>. Acesso em: 05 jul. 2020. Citado 2 vezes nas páginas 3 e 4.
- Cheng, H. . et al. Environment classification and hierarchical lane detection for structured and unstructured roads. **IET Computer Vision**, v. 4, n. 1, p. 37–49, 2010. Disponível em: <<https://ieeexplore.ieee.org/document/5356272>>. Acesso em: 16 ago. 2020. Citado 3 vezes nas páginas ix, 18 e 19.
- CHENG, Y. Mean shift, mode seeking, and clustering. **IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE**, v. 17, n. 8, p. 790–798, 1995. Disponível em: <[http://home.ku.edu.tr/mehyilmaz/public\\_html/mean-shift/00400568.pdf](http://home.ku.edu.tr/mehyilmaz/public_html/mean-shift/00400568.pdf)>. Acesso em: 16 ago. 2020. Citado na página 19.
- Collado, J. M. et al. Detection and classification of road lanes with a frequency analysis. In: **IEEE Proceedings. Intelligent Vehicles Symposium, 2005**. [s.n.], 2005. p. 78–83. Disponível em: <<https://ieeexplore.ieee.org/document/1505081>>. Acesso em: 16 ago. 2020. Citado na página 19.
- CONTRAN. Manual básico de segurança no trânsito - resolução 160/2004 - anexo ii do ctb. v. 7, n. 1, p. 64, 2004. Citado na página 7.
- CONTRAN. Manual brasileiro de sinalização de trânsito - volume iv - sinalização horizontal. 2007. Disponível em: <<http://www.capacidades.gov.br/biblioteca/detalhar/id/120/titulo/man>>

[ual-brasileiro-de-sinalizacao-de-transito-volume-4---sinalizacao-horizontal](#)>. Acesso em: 07 nov. 2020. Citado na página 6.

DENG, X. et al. An improved method to construct basic probability assignment based on the confusion matrix for classification problem. **Information Sciences**, v. 340, 01 2016. Citado na página 40.

EISENKRAEMER, M. F. **Sistema de Detecção de Veículos e Avaliação De Eixos por Meio De Máquina De Vetor De Suporte**. Tese (Trabalho de Conclusão de Curso) — Universidade de Santa Cruz do Sul, 2017. Disponível em: <<https://repositorio.unisc.br/jspui/bitstream/11624/2125/1/Mateus%20Eisenkraemer.pdf>>. Acesso em: 28 nov. 2020. Citado na página 9.

FIGHTFCGIFU. Rent-a-car atravessando a coreia 07.1] vídeo a bordo gunsan-gochoang na west coast expressway 1x velocidade. 11 2013. Disponível em: <<https://www.youtube.com/watch?v=vkwJnOi1RZY>>. Acesso em: 25 jun. 2022. Citado 2 vezes nas páginas 45 e 46.

Gonzalez, R. C.; Woods, R. E. In: **Processamento Digital de Imagens**. [S.l.: s.n.], 1992. v. 2. ed. Massachusetts, p. 331. Citado na página 11.

Gonzalez, R. C.; Woods, R. E. In: **Digital Image Processing**. [S.l.: s.n.], 2008. v. 3rd ed. Pearson Education, New Jersey, p. 954. Citado na página 11.

Gonzalez, R. C.; Woods, R. E. Digital image processing. In: **Real-time detection and classification of road lane markings**. [S.l.: s.n.], 2010. v. 3. ed. São Paulo: Pearson Prentice Hall. Citado 2 vezes nas páginas 8 e 11.

Haidar, L. **Técnicas de Detecção de Bordas Sobel vs. Canny: Implementação Passo a Passo**. 2021. Disponível em: <<https://medium.com/@haidarlina4/sobel-vs-canny-edge-detection-techniques-step-by-step-implementation-11ae6103a56a>>. Acesso em: 04 jun. 2022. Citado na página 13.

HOUGH. **Method and means for recognizing complex patterns (U.S. Patent 3069654)**. 1962. Disponível em: <<https://patentimages.storage.googleapis.com/9f/9f/f3/87610ddec32390/US3069654.pdf>>. Acesso em: 05 jun. 2022. Citado na página 15.

JÚNIOR, F. A. D. O. Identificação e classificação de sinalização horizontal em autovias utilizando opencv. 2016. Disponível em: <<https://repositorio.ifpb.edu.br/jspui/handle/177683/266>>. Acesso em: 11 out. 2020. Citado 5 vezes nas páginas 3, 21, 48, 58 e 59.

LEANDRO. Br-116 - de santo estevão a milagres na bahia. 11 2021. Disponível em: <<https://www.youtube.com/watch?v=eTGuZ2sF-n4&t>>. Acesso em: 05 jul. 2022. Citado na página 52.

LEANDRO. De são paulo a ubatuba (via oswaldo cruz) parte 1. 3 2022. Disponível em: <<https://www.youtube.com/watch?v=mwGKsbDpN0I&t>>. Acesso em: 02 jul. 2022. Citado na página 49.

LEAVERS. **Preprocessing, Shape Detection in Computer Vision Using Hough Transform**. [S.l.: s.n.], 1992. 39–64 p. Citado na página 15.

LEE, S. Lines detection with hough transform an algorithm to find lines in images. 2020. Disponível em: <<https://towardsdatascience.com/lines-detection-with-hough-transform-84020b3b1549>>. Acesso em: 5 jun. 2022. Citado 2 vezes nas páginas 15 e 16.

Maia, G.; Porfírio, A. **Processo de Detecção de Bordas de Canny**. Tese (Tese de Mestrado) — Universidade Estadual Paulista, 2002. Citado 2 vezes nas páginas 12 e 13.

MISRA, S.; WU, Y. Machine learning assisted segmentation of scanning electron microscopy images of organic-rich shales with feature extraction and feature ranking. In: MISRA, S.; LI, H.; HE, J. (Ed.). **Machine Learning for Subsurface Characterization**. Gulf Professional Publishing, 2020. p. 289 – 314. ISBN 978-0-12-817736-5. Disponível em: <<http://www.sciencedirect.com/science/article/pii/B9780128177365000107>>. Citado na página 9.

MOREIRA, M. A. Fundamentos do sensoriamento remoto e metodologias de aplicação. v. 1º ed. São José dos Campos, São Paulo, 2001. Citado na página 17.

NAÇÕES UNIDAS BRASIL. Década de ação pela segurança no trânsito 2011-2020 é lançada oficialmente hoje (11) em todo o mundo, atualizada em dezembro de 2016. 2011. Disponível em: <<https://nacoesunidas.org/decada-de-acao-pela-seguranca-no-transito-2011-2020-e-lancada-oficialmente-hoje-11-em-todo-o-mundo/>>. Acesso em: 19 abr. 2020. Citado na página 1.

NAÇÕES UNIDAS BRASIL. Guia da oms em português orienta sobre ações da sociedade civil pelo trânsito seguro. 2015. Disponível em: <<https://nacoesunidas.org/guia-da-oms-em-portugues-orienta-sobre-acoes-da-sociedade-civil-pelo-transito-seguro>>. Acesso em: 19 abr. 2020. Citado na página 1.

NASCIMENTO, M. C. **Detecção de Objetos em Imagens**. Tese (Trabalho de Graduação) — Universidade Federal de Pernambuco, 2007. Disponível em: <<http://www.cin.ufpe.br/~tg/2007-2/mcn2.doc>>. Acesso em: 30 nov. 2020. Citado na página 17.

OPAS/OMS. Portfólio de cooperação técnica opas/oms representação no brasil. p. 30, 2015. Disponível em: <[https://www.paho.org/bra/images/stories/GCC/miolo\\_portfolio\\_opas.pdf?ua=1](https://www.paho.org/bra/images/stories/GCC/miolo_portfolio_opas.pdf?ua=1)>. Acesso em: 19 abr. 2020. Citado na página 1.

OPAS/OMS. Folha informativa - acidentes de trânsito. 2019. Disponível em: <[https://www.paho.org/bra/index.php?option=com\\_content&view=article&id=5147:acidentes-de-transito-fo-lha-informativa&Itemid=779](https://www.paho.org/bra/index.php?option=com_content&view=article&id=5147:acidentes-de-transito-fo-lha-informativa&Itemid=779)>. Acesso em: 19 abr. 2020. Citado na página 2.

OPENCV. About - opencv. 2020. Disponível em: <<https://opencv.org/about/>>. Acesso em: 30 nov. 2020. Citado na página 17.

Paula, M. B.; Jung, C. R. Automatic detection and classification of road lane markings using onboard vehicular cameras. **IEEE Transactions on Intelligent Transportation Systems**, v. 16, n. 6, p. 3160–3169, 2015. Disponível em: <<https://ieeexplore.ieee.org/document/7128388>>. Acesso em: 16 ago. 2020. Citado 7 vezes nas páginas ix, 18, 21, 42, 44, 58 e 59.

Paula, M. B. d. clip\_ipad\_dma190414\_1. 06 2020. Disponível em: <[https://www.youtube.com/watch?v=NFZ\\_UQcEol4](https://www.youtube.com/watch?v=NFZ_UQcEol4)>. Acesso em: 22 jun. 2022. Citado 6 vezes nas páginas 16, 17, 32, 34, 42 e 45.

Paula, M. B. d.; Jung, C. R. Real-time detection and classification of road lane markings. In: **2013 XXVI Conference on Graphics, Patterns and Images**. [S.l.: s.n.], 2013. p. 83–90. Citado na página 3.

PEDRINE, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações**. [S.l.], 2008. 528 p. Citado na página 14.

Ross, P. E. Thus spoke the autobahn. **IEEE Spectrum**, v. 52, n. 1, p. 52–55, 2015. Acesso em: 16 out. 2020. Citado na página 3.

SEABRA. Estudo de caso: como a beta engenharia obteve sucesso fazendo os seus projetos de forma mais rápida. 2020. Disponível em: <<https://seabrasolucoes.com.br/estudo-de-caso-como-a-beta-engenharia-obteve-sucesso-fazendo-os-seus-projetos-de-forma-mais-rapida/>>. Acesso em: 28 nov. 2020. Citado 4 vezes nas páginas 9, 10, 12 e 14.

SENADO FEDERAL. Estudo da organização mundial da saúde (oms) sobre mortes por acidentes de trânsito em 178 países é base para década de ações para segurança. 2013. Disponível em: <<http://www.senado.gov.br/noticias/Jornal/emdiscussao/motos/saude/estudo-da-organizacao-mundial-da-saude-oms-sobre-mortes-por-acidentes-de-transito-em-178-paises-e-base-para-decada-de-aco-es-para-seguranca.aspx>>. Acesso em: 19 abr. 2020. Citado na página 1.

Silva, T. D. C. A.; Tavares, J. M. R. S. Algoritmos de segmentação de imagens e sua aplicação em imagens do sistema cardiovascular. 2011. Disponível em: <<https://repositorio-aberto.up.pt/bitstream/10216/56020/2/66817.pdf>>. Acesso em: 29 nov. 2020. Citado na página 11.

Stankiewicz, O.; Domański, M. Image and video processing and analysis and computer vision. v. 6, 2018. Disponível em: <<https://www.sciencedirect.com/topics/engineering/stereo-matching>>. Acesso em: 22 dez. 2021. Citado na página 20.

TAVARES, J. M. R. S.; PADILHA, A. J. A new approach for merging edge line segments. 1995. Disponível em: <<https://paginas.fe.up.pt/~tavares/downloads/publications/artigos/recpad%2095%202.pdf>>. Acesso em: 12 jun. 2022. Citado 3 vezes nas páginas 29, 30 e 31.

TIAGO. Audi a3 turbo, passeio de domingo na imigrantes. 07 2022. Disponível em: <[https://www.youtube.com/watch?v=-Rd64nvA\\_yI](https://www.youtube.com/watch?v=-Rd64nvA_yI)>. Acesso em: 06 jul. 2022. Citado na página 55.

WAZLAWICK, R. S. Uma reflexão sobre a pesquisa em ciência da computação à luz da classificação das ciências e do método científico. Revista de Sistemas de Informação da FSMA, n. 6, p. 8, 2010. Disponível em: <<http://www.fsma.edu.br/si/sistemas.html>>. Acesso em: 30 nov. 2020. Citado na página 23.

Xiangjing An; Mo Wu; Hangen He. A novel approach to provide lane departure warning using only one forward-looking camera. In: **International Symposium on Collaborative Technologies and Systems (CTS'06)**. [s.n.], 2006. p. 356–362. Disponível em: <<https://ieeexplore.ieee.org/document/1644157>>. Acesso em: 15 ago. 2020. Citado na página 18.

Yaokun Wu et al. Machine learning for locating organic matter and pores in scanning electron microscopy images of organic-rich shales. In: . [s.n.], 2019. Volume 253, p. 662–676. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0016236119307628>>. Acesso em: 19 dez. 2021. Citado na página 12.

Zang, J. et al. Traffic lane detection using fully convolutional neural network. In: **2018 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC)**. [s.n.], 2018. p. 305–311. Disponível em: <<https://ieeexplore.ieee.org/document/8659684>>. Acesso em: 17 ago. 2020. Citado 3 vezes nas páginas ix, 3 e 20.