

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA  
MESTRADO EM ENGENHARIA ELÉTRICA**

**DAVID CARVALHO ANDRADE**

**ESTRATÉGIA PARA DETECÇÃO E RASTREAMENTO DE FAIXAS  
RODOVIÁRIAS UTILIZANDO UMA CÂMERA MONOCULAR**

**DISSERTAÇÃO**

**PONTA GROSSA**

**2017**

**DAVID CARVALHO ANDRADE**

**ESTRATÉGIA PARA DETECÇÃO E RASTREAMENTO DE FAIXAS  
RODOVIÁRIAS UTILIZANDO UMA CÂMERA MONOCULAR**

Dissertação apresentada como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica, do Departamento de Eletrônica, da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Angelo Marcelo Tuset

Co-orientador: Prof. Dr. Max Mauro Dias Santos

**PONTA GROSSA**

**2017**

Ficha catalográfica elaborada pelo Departamento de Biblioteca  
da Universidade Tecnológica Federal do Paraná, Campus Ponta Grossa  
n.23/17

A553 Andrade, David Carvalho

Estratégia para detecção e rastreamento de faixas rodoviárias utilizando uma  
câmera monocular / David Carvalho Andrade. -- 2017.  
97 f. : il. ; 30 cm.

Orientador: Prof. Dr. Angelo Marcelo Tuset  
Coorientador: Prof. Dr. Max Mauro Dias Santos

Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação  
em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Ponta  
Grossa, 2017.

1. Segurança no trânsito. 2. Motoristas. 3. Processamento de imagens. 4.  
Engenharia elétrica. I. Tuset, Angelo Marcelo. II. Santos, Max Mauro Dias. III.  
Universidade Tecnológica Federal do Paraná. IV. Título.

CDD 621.3



**Universidade Tecnológica Federal do  
Paraná Campus de Ponta Grossa**  
Diretoria de Pesquisa e Pós-Graduação  
**PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA ELÉTRICA**



## **FOLHA DE APROVAÇÃO**

Título de Dissertação Nº **26/2017**

### **ESTRATÉGIA PARA DETECÇÃO E RASTREAMENTO DE FAIXAS RODOVIÁRIAS UTILIZANDO UMA CÂMERA MONOCULAR**

por

**David Carvalho Andrade**

Esta dissertação foi apresentada às **8 horas e 30 minutos** do dia **24 de abril de 2017** como requisito parcial para a obtenção do título de MESTRE EM ENGENHARIA ELÉTRICA, com área de concentração em Controle e Processamento de Energia, Programa de Pós-Graduação em Engenharia Elétrica. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

**Prof. Dr. José Manoel Balthazar (UNESP)**

**Prof. Dr. Frederic Conrad Janzen (UTFPR)**

**Prof. Dr. Sergio Okida (UTFPR)**

**Prof. Dr. Angelo Marcelo Tuset (UTFPR)**  
*Orientador*

**Prof. Dr. Claudinor Bitencourt Nascimento**  
Coordenador do PPGE

- A Folha de Aprovação assinada encontra-se arquivada na Secretaria Acadêmica -

Dedico este trabalho à Dayane Isabella  
Lima, minha namorada, por sua amada  
companhia.

## AGRADECIMENTOS

Agradeço a Deus por todas as oportunidades concedidas, sobretudo pelo presente da vida.

Aos meus pais, José do Porto e Hilda, e aos meus avós, Raimundo e Geralda, pois são as pessoas a quem eu realmente devo tudo, pela manifestação do amor, pela motivação e pelos conselhos valiosos.

Aos orientadores Prof. Dr. Angelo Marcelo Tuset e Prof. Dr. Max Mauro Dias Santos, pela paciência, pela disponibilidade, pelos ensinamentos e pela confiança depositada ao me convidarem para trabalhar no seu grupo de pesquisa.

Aos colegas do Grupo de Sistemas Automotivos (GSA), em especial aos envolvidos no projeto com a FCA (Fiat Chrysler Automobiles) com os quais tive o prazer de trabalhar neste período. Ao Neme, pela liderança em frente à equipe. Ao Rodrigo Adamshuk e ao Felipe Bueno, que permitiram a utilização dos *softwares* de mapeamento em perspectiva inversa e de avaliação do algoritmo. Ao Felipe Franco, que é uma referência interna, por sua capacidade de desenvolvimento. Ao Omoto, com quem trabalhei na etapa de desenvolvimento do processamento de nível médio. Ao Erick e ao Farinelli, que participaram ativamente na instrumentação do veículo e na etapa de testes em rodovias.

Aos colegas de mestrado, principalmente ao Luiz, ao Jéssimon, ao Fernando e ao Régis, pelo acolhimento, pelo companheirismo, pelos momentos de trabalho duro e também de descontração.

Ao Saulo e sua esposa Lilian, por todo o auxílio, amizade e companhia desde minha chegada à cidade de Ponta Grossa.

Enfim, agradeço aos colegas da FCA em Betim, com os quais tenho trabalhado em parceria há mais de um ano, pela crítica construtiva, pela experiência transmitida e pelos conhecimentos adquiridos no decorrer do projeto.

Meu filho, guarde consigo a sensatez e o equilíbrio, nunca os perca de vista; tração vida a você e serão um enfeite para o seu pescoço. Então você seguirá o seu caminho em segurança e não tropeçará; quando se deitar não terá medo e o seu sono será tranquilo. (Provérbios 3:21-24)

## RESUMO

ANDRADE, David Carvalho. **Estratégia para detecção e rastreamento de faixas rodoviárias utilizando uma câmera monocular**. 2017. 97 p. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2017.

No setor automotivo, os sistemas de auxílio ao condutor são desenvolvidos para reduzir os efeitos colaterais do nível de mobilidade atingido atualmente, como os acidentes de trânsito e os congestionamentos. Em uma perspectiva futura, pretende-se atingir o nível de direção autônoma e cooperativa baseada em redes de sensores. A estratégia de detecção e rastreamento de faixas rodoviárias proposta neste trabalho se enquadra nos requisitos funcionais de alguns desses sistemas, como o *Lane Departure Warning* (Aviso de Saída de Faixa) e o *Lane Keep Assist* (Assistência de Manutenção de Faixa). O desenvolvimento do algoritmo foi organizado em três níveis de processamento; baixo, médio e alto. Na etapa de processamento de baixo nível realizam-se as operações de preparação e melhoramento da imagem de entrada, na etapa de nível médio realiza-se a extração das características de interesse e a etapa de alto nível consiste da técnica de rastreamento da posição das faixas. Avaliou-se a resposta do algoritmo, para as amostras escolhidas, por meio de métricas baseadas no distanciamento das faixas rastreadas em relação à posição original das mesmas. Constatou-se que a estratégia apresenta boa precisão nos cenários considerados ideias, inclusive com a presença de sombras, curvas, aclive e declive na estrada. Contudo, essa precisão é comprometida quando a faixa é segmentada, mal sinalizada e quando o reflexo na pista ou o ofuscamento afeta a captura da imagem pela câmera.

**Palavras-chave:** Sistemas de Auxílio ao Condutor. Processamento de Imagens Digitais. Detecção de Faixas. Rastreamento de Faixas.



## ABSTRACT

ANDRADE, David Carvalho. **Road lane detection and tracking strategy using a monocular camera**. 2017. 97 p. Dissertação (Mestrado em Engenharia Elétrica) - Federal Technology University - Paraná. Ponta Grossa, 2017.

In the automotive field, driver assistance systems are developed to reduce the collateral effects of the actual level of mobility, such as traffic jams and accidents. In a future perspective, it is intended to achieve the level of autonomous and cooperative driving based on sensor networks. The proposed strategy for road lanes detection and tracking fits as a functional requirement for some of these systems, as the Lane Departure Warning and Lane Keep Assist. The algorithm development was structured based in three processing levels: low, mid and high levels. The low-level processing enhances the input image, the mid-level processing is an interest feature extractor, and the high-level is the lane position tracking strategy. The algorithm's response evaluation, for the chosen samples, was realized with metrics based on the deviation between the tracked and the original lane. The strategy shows good accuracy levels at the ideal scenario, including shadows, curves, and road slope. However, the accuracy is impaired if the lane is dashed, badly signalized and if road reflection or dazzle harm the image capture by the camera.

**Keywords:** Driver Assistance Systems. Digital Image Processing. Lane Detection. Lane Tracking.

## LISTA DE FIGURAS

Figura 1 – Sistema LDW. (a) Monitoramento da pista. (b) Alarme. ....	15
Figura 2 – Sistema de direção elétrica. ....	16
Figura 3 – Funcionamento do sistema FCW. ....	16
Figura 4 – Detecção de pedestres pela câmera. ....	17
Figura 5 – Funcionamento do sistema TSR. ....	17
Figura 6 – Efeito visual da variação da densidade da amostragem. ....	26
Figura 7 – Sistema de coordenadas para representação de imagens digitais. ....	27
Figura 8 – Filtragem no domínio espacial. ....	27
Figura 9 – Métodos de preenchimento da região de limite das imagens filtradas. ....	29
Figura 10 – Perfil de intensidade de alguns tipos de bordas ideais. ....	30
Figura 11 – Máscaras unidimensionais para cálculo da magnitude do gradiente nos eixos x e y. ....	31
Figura 12 – Operadores de Roberts, Prewitt e Sobel. ....	32
Figura 13 – Estágios do algoritmo detector de bordas de Canny. ....	34
Figura 14 – Conexão de pontos utilizando a limiarização por histerese. ....	36
Figura 15 – Etapas do algoritmo detector de bordas de Canny. ....	36
Figura 16 – Diagrama de blocos do algoritmo <i>Steerable Filter</i> . ....	37
Figura 17 – Máscara do filtro gaussiano para a) $\theta = 0^\circ$ , b) $\theta = 45^\circ$ , c) $\theta = 90^\circ$ e d) $\theta = 135^\circ$ . ....	38
Figura 18 – O conceito de elemento estruturante e sondagem. ....	40
Figura 19 – Operação morfológica de erosão. ....	41
Figura 20 – Operação morfológica de dilatação. ....	42
Figura 21 – Operação morfológica de abertura. ....	43
Figura 22 – Operação morfológica de fechamento. ....	44
Figura 23 – Máscara de vizinhança 4 e máscara de vizinhança 8. ....	44
Figura 24 – Rotulação das componentes conectadas com máscaras de vizinhança 4 e 8. ....	45
Figura 25 – Princípio da transformada de Hough. (a) Espaço da imagem. (b) Espaço de parâmetros k, q. ....	46
Figura 26 – Detecção de linha com a transformada de Hough. ....	46
Figura 27 – Representação da linha na forma polar. ....	47
Figura 28 – Transformada de Hough no espaço $\rho, \theta$ . (a) Espaço da imagem. (b) Espaço de parâmetros $\rho, \theta$ . ....	48
Figura 29 – Aplicação da transformada de Hough em uma imagem real. (a) Imagem de entrada. (b) Bordas. ....	48
Figura 30 – Aplicação da transformada de Hough em uma imagem real. (a) Vetor acumulador. (b) Linhas detectadas pelo algoritmo. ....	49
Figura 31 – Diagrama de blocos representativo das etapas do processamento de baixo nível. ....	50

Figura 32 – Diagrama de blocos da etapa de acumulação recursiva.....	52
Figura 33 – Visão em perspectiva inversa com ROI de 150 linhas. ....	53
Figura 34 – Desentrelaçamento por interpolação linear.....	54
Figura 35 – Saída da etapa de processamento de baixo nível.....	54
Figura 36 – Diagrama de blocos representativo do processamento de nível médio. ....	55
Figura 37 – Detector de bordas Canny. ....	56
Figura 38 – Orientação do gradiente na região de uma faixa. ....	56
Figura 39 – Mudanças na orientação angular das faixas em diferentes cenários. ....	57
Figura 40 – Algoritmo de ajuste de parâmetros por meio da velocidade lateral do veículo. ....	58
Figura 41 – Filtragem sobre a orientação do gradiente da imagem. ....	59
Figura 42 – Aplicação da dilatação para conexão dos pontos de interesse.....	59
Figura 43 – Rotulação da saída da imagem dilatada. ....	60
Figura 44 – Algoritmo para filtragem da imagem baseado na análise dos componentes conectados.....	61
Figura 45 – Saída do processamento de nível médio. ....	61
Figura 46 – Divisão das seções da ROI e coordenadas detectadas. ....	62
Figura 47 – Comparação entre os ângulos formados pela borda interna e externa da faixa.....	64
Figura 48 – Exemplo da saída do processo de seleção de coordenadas. ....	65
Figura 49 – Resposta em magnitude do filtro Butterworth passa-baixas. ....	66
Figura 50 – Análise do comportamento das funções de interpolação. ....	67
Figura 51 – Saída do algoritmo em uma reta. ....	68
Figura 52 – Resposta do algoritmo nos períodos (a) diurno e (b) noturno. ....	69
Figura 53 – Ofuscamento causado pelo farol do veículo em sentido oposto. ....	70
Figura 54 – Desativação visual da seção superior da faixa rastreada. ....	71
Figura 55 – Repetição das últimas coordenadas válidas. ....	72
Figura 56 – Detecção de bordas relacionadas ao contraste do asfalto.....	73
Figura 57 – Reflexo na pista causado pela chuva.....	74
Figura 58 – Desativação do rastreamento devido a sinalização do motorista.....	75
Figura 59 – Processo de marcação de <i>ground truth</i> . ....	76
Figura 60 – Etapa de operação do <i>software</i> de avaliação de desempenho.....	76
Figura 61 – Métricas de avaliação: Precisão por linha e por quadro.....	77
Figura 62 – Etapa de comparação do <i>software</i> .....	77
Figura 63 – Gráfico de superfície do índice PPL para a primeira amostra. ....	79
Figura 64 – Gráfico de superfície do índice PPL para a segunda amostra. ....	81
Figura 65 – Gráfico de superfície do índice PPL para a terceira amostra.....	83
Figura 66 – Gráfico de superfície do índice PPL para a quarta amostra.....	85
Figura 67 – Gráfico de superfície do índice PPL para a quinta amostra, ....	87
Figura 68 – Gráfico de superfície do índice PPL para a sexta amostra. ....	88

## LISTA DE TABELAS

Tabela 1 – Funções de interpolação $k_j(\theta)$ em função da ordem polinomial do filtro. ....	39
Tabela 2 – Distância percorrida até o tempo médio de reação para frenagem. ....	52
Tabela 3 – Relação alcance/altura da ROI. ....	53
Tabela 4 – Índices de avaliação da faixa à esquerda (Amostra 1). ....	78
Tabela 5 – Índices de avaliação da faixa à direita (Amostra 1). ....	79
Tabela 6 – Índices de avaliação da faixa à esquerda (Amostra 2). ....	80
Tabela 7 – Índices de avaliação da faixa à direita (Amostra 2). ....	81
Tabela 8 – Índices de avaliação da faixa à esquerda (Amostra 3). ....	82
Tabela 9 – Índices de avaliação da faixa à direita (Amostra 3). ....	82
Tabela 10 – Índices de avaliação da faixa à esquerda (Amostra 4). ....	84
Tabela 11 – Índices de avaliação da faixa à direita (Amostra 4). ....	84
Tabela 12 – Índices de avaliação da faixa à esquerda (Amostra 5). ....	85
Tabela 13 – Índices de avaliação da faixa à direita (Amostra 5), ....	86
Tabela 14 – Índices de avaliação da faixa à esquerda (Amostra 6). ....	87
Tabela 15 – Índices de avaliação da faixa à direita (Amostra 6). ....	88

## LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

ABS	<i>Anti-lock Brake System</i>
ACC	<i>Adaptive Cruise Control</i>
CAN	<i>Controller Area Network</i>
CPU	<i>Central Processing Unit</i>
CTB	Código de Trânsito Brasileiro
DAM	Desvio absoluto médio
DAS	<i>Driver Assistance Systems</i>
DP	Desvio Padrão
ESC	<i>Electronic Stability Control</i>
EUA	Estados Unidos da América
FCA	<i>Fiat Chrysler Automobiles</i>
FCW	<i>Forward Collision Warning</i>
FHWA	<i>Federal Highway Administration</i>
FPS	<i>Frames per second</i>
GSA	Grupo de Sistemas Automotivos da UTFPR-PG
IIR	<i>Infinite Impulse Response</i>
IMU	<i>Inertial Measurement Unit</i>
IPM	<i>Inverse Perspective Mapping</i>
LDW	<i>Lane Departure Warning</i>
LKA	<i>Lane Keeping Assist</i>
LIDAR	<i>Light Detection and Ranging</i>
LSA	Laboratório de Sistemas Automotivos da UTFPR-PG
NCAP	<i>New Car Assessment Program</i>
NHTSA	<i>National Highway Traffic Safety Administration</i>
NSC	<i>National Safety Council</i>
PCM	<i>Pedestrian Collision Mitigation</i>
Pixel	<i>Picture Element</i>
PPL	Precisão por linha
PPQ	Precisão por quadro
PRF	Polícia Rodoviária Federal
PROMETHEUS	<i>Program for a European Traffic with highest efficiency and unprecedented safety</i>
RADAR	<i>Radio Detection and Ranging</i>

RANSAC	<i>Random Sample Consensus</i>
RGB	<i>Red Green Blue</i>
ROI	<i>Region of Interest</i>
TCS	<i>Traction Control System</i>
TSR	<i>Traffic Sign Recognition</i>
UTFPR	Universidade Tecnológica Federal do Paraná
WHO	<i>World Health Organization</i>
XML	<i>Extensive Markup Language</i>

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>13</b>
1.1 VISÃO GERAL DOS SISTEMAS DE AUXÍLIO BASEADOS EM CÂMERA.....	14
1.1.1 Aviso de Saída de Faixa ( <i>Lane Departure Warning – LDW</i> ).....	15
1.1.2 Assistência de Manutenção de Faixa ( <i>Lane Keeping Assist – LKA</i> ).....	15
1.1.3 Aviso de Colisão Frontal ( <i>Forward Collision Warning – FCW</i> ).....	16
1.1.4 Mitigação de Colisão de Pedestres ( <i>Pedestrian Collision Mitigation – PCM</i> ) .	16
1.1.5 Reconhecimento de Sinais de Trânsito ( <i>Traffic Sign Recognition – TSR</i> ) .....	17
1.2 REVISÃO BIBLIOGRÁFICA.....	18
1.3 TEMA .....	21
1.4 JUSTIFICATIVA .....	21
1.5 PROBLEMA .....	22
1.6 OBJETIVOS.....	22
1.6.1 Objetivo Geral .....	22
1.6.2 Objetivos Específicos.....	22
1.7 ESTRUTURA DO TRABALHO .....	23
<b>2 PROCESSAMENTO DIGITAL DE IMAGENS .....</b>	<b>24</b>
2.1 REPRESENTAÇÃO DE IMAGENS COMO FUNÇÕES .....	24
2.2 FILTRAGEM ESPACIAL.....	27
2.3 ANÁLISE DO GRADIENTE.....	29
2.3.1 Magnitude do Gradiente .....	30
2.3.2 Direção do Gradiente.....	32
2.4 TÉCNICAS APLICADAS PARA DETECÇÃO DE BORDAS .....	33
2.4.1 Filtro Canny.....	33
2.4.2 Filtro Direcionável ( <i>Steerable Filter</i> ).....	36
2.5 MORFOLOGIA MATEMÁTICA BINÁRIA.....	40
2.5.1 Erosão .....	41
2.5.2 Dilatação.....	42
2.5.3 Abertura e Fechamento .....	43
2.5.4 Análise dos Componentes Conectados - Rotulação.....	44
2.6 TRANSFORMADA DE HOUGH PARA O RASTREAMENTO DE RETAS.....	45
<b>3 ESTRATÉGIA PARA DETECÇÃO E RASTREAMENTO DE FAIXAS RODOVIÁRIAS.....</b>	<b>50</b>
3.1 PROCESSAMENTO DE BAIXO NÍVEL.....	50

3.2 PROCESSAMENTO DE NÍVEL MÉDIO .....	55
3.3 PROCESSAMENTO DE ALTO NÍVEL.....	62
<b>4 RESULTADOS E DISCUSSÕES .....</b>	<b>69</b>
4.1 ANÁLISE QUALITATIVA DOS RESULTADOS.....	69
4.2 ANÁLISE QUANTITATIVA DOS RESULTADOS.....	75
<b>5 CONCLUSÃO .....</b>	<b>90</b>
<b>REFERÊNCIAS.....</b>	<b>93</b>



## 1 INTRODUÇÃO

A mobilidade é um importante fator social e econômico para a humanidade, pois proporciona qualidade de vida e é a espinha dorsal do comércio. Por consequência, os habitantes de países industrializados atingiram um alto grau de mobilidade devido à produção de veículos em massa e os investimentos em infraestrutura rodoviária.

Entretanto, a popularização dos automóveis tem causado alguns problemas logísticos, como os congestionamentos e os riscos dos acidentes de trânsito (HOLDEN, 2012; SCHRANK; EISELE; LOMAX, 2012). Segundo dados da Administração Nacional de Segurança no Tráfego Rodoviário dos Estados Unidos (NHTSA – *National Highway Traffic Safety Administration*), 94% das falhas críticas da cadeia de eventos que precedem um acidente são associados ao condutor, dados que justificam o investimento em sistemas de apoio (NHTSA, 2015).

No Brasil, a Polícia Rodoviária Federal (PRF) disponibiliza em seu portal dados sobre acidentes de trânsito dos últimos dez anos. No ano de 2016, os acidentes envolvendo representam em torno de 17% do número total de acidentes de trânsito (PRF, 2016). O número de mortes por uma população de 100000 pessoas passou de cerca de 18, em 2003, para cerca de 22, em 2012 (WHO, 2015).

Em um estudo conduzido pela Volvo Trucks (2013) sobre acidentes em estradas europeias, foi constatado que cerca de 22% dos acidentes envolvendo caminhões são relacionados a saída da pista ou a colisão com a traseira de outros veículos. Segundo a Administração Federal de Rodovias dos Estados Unidos (FHWA – *Federal Highway Administration*) 54% das fatalidades em acidentes de trânsito no ano de 2014 foram causadas pela saída do veículo de sua via de condução (FHWA, 2016). Nesse contexto, projetos de lei e programas de avaliação de desempenho de segurança automotiva, impulsionam o desenvolvimento de sistemas de auxílio ao condutor (DAS – *Driver Assistance Systems*), como as exigências da NHTSA sobre a implantação de tecnologia de visibilidade traseira para os veículos leves fabricados nos EUA (Estados Unidos da América) até 2018 e o sistema de classificação da EURO NCAP (*European New Car Assessment Programme*) que torna pública as avaliações das funcionalidades de segurança dos veículos fabricados na Europa (EURO NCAP, 2016; NAYLOR, 2014).

Os sistemas de auxílio ao condutor oferecem soluções para redução dos efeitos causados pelos problemas supracitados. Bengler et al. (2014) analisa as três décadas de desenvolvimento de DAS e os organiza de acordo com o ponto de vista tecnológico:

- Do fim da década de 70 a meados da década de 90: Os sistemas eram baseados em sensores proprioceptivos<sup>1</sup> com o objetivo de estabilizar a dinâmica veicular, como o ABS (*Anti-lock Brake System*), TCS (*Traction Control System*) e o ESC (*Electronic Stability Control*);
- Do início da década de 90 ao fim dos anos 2000: Foram implementados os sistemas baseados em sensores exteroceptivos<sup>2</sup> com funções de informação, alarme e conforto, como o LDW (*Lane Departure Warning*), ACC (*Adaptive Cruise Control*) e o *Park Assist*;
- De meados dos anos 2000 até 2030: Pretende-se atingir o nível de direção autônoma e cooperativa baseada em redes de sensores.

A aplicação do processamento digital de imagens em sistemas de auxílio ao condutor merece destaque, devido aos sistemas já implementados e ao potencial de desenvolvimento de novos sistemas. Tendo em vista este cenário, é importante contextualizar os principais sistemas baseados na tomada de decisões sobre as manipulações dos dados coletados da câmera.

## 1.1 VISÃO GERAL DOS SISTEMAS DE AUXÍLIO BASEADOS EM CÂMERA

As funcionalidades de segurança relativas aos sistemas de auxílio ao condutor são abundantes, no entanto destacam-se aquelas que têm o objetivo de manter o veículo em sua via de condução, de prevenir as colisões, tanto com os veículos, quanto com os pedestres, e a detecção de sinalizações da via. Nas seções seguintes, são apresentados os principais sistemas de acordo com o levantamento realizado pelo Grupo de Sistemas Automotivos (GSA) da Universidade Tecnológica Federal do Paraná (UTFPR).

---

<sup>1</sup> **Sensores proprioceptivos:** sensores que monitoram o condicionamento interno do veículo.

<sup>2</sup> **Sensores exteroceptivos:** sensores que adquirem informações externas ao veículo.

### 1.1.1 Aviso de Saída de Faixa (*Lane Departure Warning – LDW*)

Os benefícios à segurança do condutor trazidos por este sistema são relacionados à detecção da saída do veículo de sua via de condução. Conforme ilustrado na Figura 1(a) o sensoriamento é baseado em uma câmera de visão frontal que monitora a posição do veículo em relação às delimitações da pista, assim, quando a saída da pista é detectada, um alarme visual e/ou sonoro é emitido ao condutor de acordo com a Figura 1(b).

**Figura 1 – Sistema LDW. (a) Monitoramento da pista. (b) Alarme.**



Fonte: NSC (2017).

### 1.1.2 Assistência de Manutenção de Faixa (*Lane Keeping Assist – LKA*)


O LKA é uma função de conveniência que auxilia o condutor a manter o veículo na pista atuando diretamente sobre o controle do sistema de direção elétrica do veículo. Contudo, este sistema não deve ser considerado como uma funcionalidade de direção autônoma, portanto torna-se necessário a solicitação de retomada do controle do veículo ao condutor.

O monitoramento da pista é realizado conforme Figura 1(a), a correção da trajetória do veículo é realizada por meio da atuação no sistema de direção elétrica (Figura 2).



colisões. O funcionamento deste sistema é ilustrado pela Figura 4. Além das funções de detecção de pedestres, é necessário estimar a trajetória dos mesmos com base no comportamento identificado a partir do rastreamento da posição.

**Figura 4 – Detecção de pedestres pela câmera.**



**Fonte: Eckert, Hohm e Lueke (2013).**

#### 1.1.5 Reconhecimento de Sinais de Trânsito (*Traffic Sign Recognition – TSR*)

O sistema de reconhecimento de sinais de trânsito (TSR) é baseado na segmentação da região das placas e no reconhecimento de padrões (limite de velocidade, parada obrigatória, sentido da via, etc.). O sistema não é projetado para substituir a ação do condutor, mas pode auxiliá-lo quanto a alguma informação passada em despercebido devido à concentração em outra atividade com prioridade superior ou por um momento de distração do condutor. A Figura 5 ilustra um exemplo de aplicação deste sistema.

**Figura 5 – Funcionamento do sistema TSR.**



**Fonte: Skoda (2017).**

A partir desta sucinta contextualização, é possível observar que tais sistemas requerem o uso extensivo de processamento digital de imagens, seja para

extração das características da rodovia ou para o rastreamento de objetos de interesse. Na seção seguinte, uma revisão bibliográfica sobre as técnicas de processamento digital de imagens e sua aplicação em DAS é apresentada.

## 1.2 REVISÃO BIBLIOGRÁFICA

A explosão de interesse pelo campo de processamento digital de imagens e visão computacional durante os anos 70 e 80 foi concomitante com o surgimento dos primeiros microprocessadores, computadores pessoais e a integração em larga escala de componentes. O amadurecimento resultante das últimas três décadas culminou no crescimento significativo de aplicações ativas; sensoriamento remoto, diagnóstico, biomédica, veículos autônomos e vigilância automática são as áreas de desenvolvimento mais avançadas (GONZALEZ; WOODS, 2008; SONKA; HLAVAC; BOYLE, 2014).

No mesmo período, as primeiras pesquisas em torno do desenvolvimento de veículos inteligentes foram iniciadas no Japão, na década de 70, e na Europa, no fim da década de 80 e início dos anos 90. No Japão, as empresas MITI, Nissan e Fujitsu foram pioneiras nessa área de pesquisa com o projeto “*Personal Vehicle System*”. Na Europa, o projeto PROMETHEUS (*Program for a European Traffic with highest efficiency and unprecedented safety*), envolveu cerca de 13 montadoras e várias unidades de pesquisa. Os problemas abertos pelos sistemas de transporte inteligentes, tais como, rastreamento de faixas, detecção de veículos e objetos abriram portas para a integração dessa área com o campo de visão computacional (BERTOZZI *et al.*, 2002; SUN; BEBIS; MILLER, 2004).

Nas últimas décadas, várias funcionalidades têm sido adicionadas gradativamente nos veículos em direção à autonomia total. Nos sistemas de visão baseados em câmeras, existem as modalidades de visão monocular e de visão estéreo. Para aplicações baseadas em visão frontal, como o ACC, as câmeras monoculares com lente convencional atingem nível de precisão satisfatório em distâncias relevantes. As lentes grande-angular (ou olho de peixe) são aplicadas em sistemas de visão lateral e traseira devido a sua maior cobertura do campo de visão (as lentes convencionais cobrem cerca de 45°, ao passo que as lentes grande-angular podem cobrir até 180°). A aplicação de visão estéreo é vantajosa nas

aplicações ligadas a reconstrução de cenários tridimensionais, detecção e rastreamento de objetos. (HUGHES et al., 2009; NEDEVSKI et al., 2004; SHUNGUANG et al., 2009; STEIN; MANO; SHASHUA, 2003).

Estratégias de combinação entre os dados de sensores proprioceptivos (normalmente extraídos do barramento de comunicação serial do veículo) e exteroceptivos têm sido exploradas em DAS, tanto para extração de características, quanto para tomada de decisões. A fusão de dados dos sensores LIDAR (*Light Detection And Ranging*) e câmera frontal é uma das abordagens mais populares, sendo aplicada para detecção de faixas (SHIN; SHIM; KWEON, 2015), para escolha da região ótima de tráfego do veículo (LI et al., 2014), para detecção de pedestres (PREMEBIDA; NUNES, 2013) e detecção de obstáculos (HAN et al., 2012).

A funcionalidade DAS mais básica e, conseqüentemente, mais explorada é o LDW que, basicamente, consiste no monitoramento do estado do veículo em relação às faixas mais próximas e emissão de um alarme caso ocorra uma saída indesejada da pista. As pesquisas de McCall e Trivedi (2006) e Hillel et al. (2014) se complementam no sentido de fornecerem uma visão global sobre as principais técnicas aplicadas no desenvolvimento desses sistemas nos últimos anos.

Na implementação do algoritmo detector de faixas, Jung e Kelber (2004) propuseram o modelo de rodovia linear-parabólico. Com a divisão da região de interesse (ROI - *Region of interest*) em duas seções, denominadas campo próximo e campo distante. Aproximou-se as bordas das faixas do campo próximo por uma função de interpolação linear e as bordas das faixas do campo distante por uma função de interpolação parabólica. A métrica de LDW foi implementada em função da simetria entre orientação das faixas à esquerda e a direita, sob a premissa de que a câmera é instalada no centro do para-brisa do veículo.

Na sucessão do trabalho sugeriu-se uma métrica de LDW baseada no comportamento temporal da posição lateral do veículo em relação às faixas. A função para cálculo da posição lateral não depende dos parâmetros intrínsecos e extrínsecos da câmera, no entanto é necessário o conhecimento *a priori* da distância entre as faixas, tornando obrigatório o desenvolvimento de uma função para o cálculo da distância ou a assunção de sua invariância (JUNG; KELBER, 2005).

Com a finalidade de obter resultados satisfatórios na extração de características das faixas em ambientes afetados por sombra, mudança de luminosidade e variação das marcações na pista, McCall e Trivedi (2004) utilizaram

o *Steerable Filter*, que é baseado na combinação linear das contribuições individuais de um filtro base, gaussiano, orientado por um número finito de ângulos. Sivaraman e Trivedi (2013), também aplicaram filtros direcionáveis para extração de características das faixas. Os parâmetros do modelo da rodovia foram obtidos por meio da técnica RANSAC (*Random access consensus*) e a detecção dos veículos é realizada por uma técnica baseada em aprendizado ativo integrada com o filtro de partículas. A abordagem sinérgica de rastreamento de faixas e veículos possibilitou a classificação, de forma precisa, da faixa na qual os veículos se situam.

Wang, Teoh e SHEN (2004) segmentaram a ROI em um número finito de seções, aplicando a transformada de Hough para detecção de pontos pertencentes a segmentos de retas em cada seção e efetuaram a interpolação desses pontos pelo algoritmo B-Snake. A aplicação do algoritmo B-Snake é justificada pela capacidade de se adequar a modelos arbitrários de rodovia. Nesse trabalho, a aproximação dos pontos de controle da B-Snake com a borda da imagem é obtida por meio do método de minimização do erro médio quadrático, enquanto Li et al. (2015) utilizaram o filtro de Kalman para prever e refinar os resultados do rastreamento das faixas.

Ying e Li (2016) utilizaram o mapeamento em perspectiva inversa (IPM), a abordagem adotada consiste na adaptação dos parâmetros baseado na extração dos limites da pista, Jeong e Kim (2016) tornaram o modelo adaptativo a partir do cálculo dos parâmetros de movimento da câmera ( $x$ ,  $y$ ,  $z$ ,  $yaw$ ,  $pitch$  e  $roll$ ) obtidos por meio da odometria visual. O IPM remove o efeito de perspectiva da imagem capturada, utilizando como entrada o posicionamento da câmera em relação ao terreno e seus parâmetros. O modelo se adequa a várias aplicações, dentre elas, detecção de distância, mapeamento de rodovias e sistemas de assistência para estacionamento. No entanto, o modelo básico, com parametrização estática, do IPM sofre distorções devido a mudanças severas no movimento e na inclinação da pista. Para amenizar o problema, as pesquisas atuais focam na implementação do IPM de forma adaptativa.

Uma alternativa a aplicação do IPM é o uso de imagens espaço-temporais. Estas são imagens geradas a partir do agrupamento de um conjunto de pixels amostrados em uma linha de varrimento horizontal com localização fixa em uma janela de tempo. Por meio do alinhamento de imagens espaço-temporais do ponto de vista de diferentes linhas de varrimento Jung, Youn e Sull (2016) atingiram um



alto índice de acertos na detecção de faixas, com eficiência computacional superior em relação a alguns trabalhos pertinentes.

Tipicamente, o desempenho de um algoritmo de rastreamento de faixas é avaliado quanto à precisão e/ou robustez, que envolve a análise da precisão apresentada em vários cenários (SHIN; XU; KLETTE, 2014). Para tanto, é usual a comparação entre as coordenadas de referência, marcadas manualmente (*ground-truth*), e as coordenadas obtidas pela técnica de rastreamento aplicada. McCall e Trivedi (2006) avaliaram seu sistema por meio de três métricas, a média absoluta e o desvio padrão do erro de posição da faixa, e o desvio da taxa de variação da posição lateral. Na avaliação de seu sistema, Borkar, Hayes e Smith (2012) consideram uma detecção correta quando mais da metade dos pontos detectados estão a uma distância aceitável do *ground truth* e caso ocorra detecção de faixas onde não há marcação de *ground truth*, a detecção é classificada como falso positivo.

### 1.3 TEMA

Detecção e rastreamento de faixas de rodovias para aplicação em sistemas de auxílio ao condutor.

### 1.4 JUSTIFICATIVA

A aplicação de técnicas de processamento digital de imagens em sistemas automotivos é um objeto de pesquisas recentes, com resultados que promovem um aumento potencial no nível de segurança dos condutores. Atualmente, os sistemas de rastreamento de faixas mais avançados são compostos por um arranjo de sensores. Tal composição aumenta o grau de percepção do veículo sobre o ambiente, contudo a complexidade e os custos envolvidos ainda dificultam, ou até mesmo inviabilizam a implementação desses sistemas em veículos populares. Neste trabalho, pretende-se investigar a performance da técnica proposta de processamento de imagens, baseada nas informações obtidas por meio de uma câmera monocular e do barramento serial de comunicação do veículo, proposta em

diferentes cenários, incluindo reflexo, ofuscamento da câmera, sombra e em rodovias com sinalização comprometida.

## 1.5 PROBLEMA

Determinar uma estratégia de integração de técnicas de processamento de imagens, utilizando uma câmera monocular e os sinais do barramento do veículo, que possibilite o rastreamento das faixas rodoviárias de forma eficiente.

## 1.6 OBJETIVOS

Os objetivos a serem alcançados no desenvolvimento deste trabalho são descritos a seguir.

### 1.6.1 Objetivo Geral

Desenvolver um sistema de visão computacional de baixo custo, que possa realizar a extração de características e o rastreamento das faixas mais próximas do automóvel em rodovias, auxiliando o motorista de forma eficiente quanto à tarefa condução do veículo.

### 1.6.2 Objetivos Específicos

- Propor uma estratégia de extração de características para extração das bordas relativas às faixas rodoviárias;
- Analisar a viabilidade da aplicação de sinais provenientes do barramento de comunicação serial automotivo no desenvolvimento de algoritmos de processamento de imagens;
- Aplicar um algoritmo para rastreamento de segmentos de reta a partir dos objetos extraídos da imagem de entrada;
- Aplicar técnicas de interpolação de pontos para ajustes de curva;

- Análise quantitativa e qualitativa dos resultados obtidos em cenários extraídos da base de dados do GSA (Grupo de Sistemas Automotivos).

## 1.7 ESTRUTURA DO TRABALHO

O trabalho está estruturado da seguinte forma:

- No capítulo 2, o funcionamento de algumas técnicas clássicas no campo de processamento digital de imagens é discutido;
- No capítulo 3 apresenta-se a estratégia de processamento de imagens desenvolvida, segmentada em etapas de processamento de baixo, médio e alto nível;
- No capítulo 4, os resultados obtidos são revelados e analisados, com base no desempenho observado em cada um dos cenários propostos;
- Finalmente, no capítulo 5, é apresentada a conclusão, bem como a sugestão para trabalhos futuros.

## 2 PROCESSAMENTO DIGITAL DE IMAGENS

Um possível modelo de classificação dos processos envolvendo o processamento digital de imagens consiste na divisão entre processos de baixo, médio e alto nível. Os processos de baixo nível envolvem operações primárias como o pré-processamento para redução de ruídos, melhoramento do contraste e nitidez, caracterizando-se pelo fato de que a entrada e a saída do processo são imagens com o mesmo formato. Os processos de nível médio se caracterizam pelo fato de que sua entrada normalmente é uma imagem, mas a saída são informações extraídas da imagem, tais como, bordas, contornos e objetos identificados. O objetivo da aplicação dos processos de alto nível é interpretar, eletronicamente, um conjunto de objetos identificados, por meio de funções cognitivas normalmente associadas com a visão, como é o caso da visão computacional (GONZALEZ; WOODS, 2008; SONKA; HLAVAC; BOYLE, 2014).

Neste capítulo as principais técnicas de processamento de imagens vinculadas ao desenvolvimento deste trabalho são apresentadas, o conteúdo é dividido respeitando a sequência de processos de acordo com o paradigma, para fornecer uma transição linear entre os tópicos apresentados.

### 2.1 REPRESENTAÇÃO DE IMAGENS COMO FUNÇÕES

Uma imagem digital pode ser representada como uma função bidimensional na forma  $f(x, y)$ , cuja intensidade é proporcional à energia irradiada por uma fonte física, por exemplo, ondas eletromagnéticas. A função  $f(x, y)$  é composta por dois componentes: (1) a quantidade de iluminação incidente no cenário visualizado, normalmente chamada de iluminância, e (2) a quantidade de iluminação refletida pelos objetos do cenário, normalmente chamada de refletância, denotados por  $i(x, y)$  e  $r(x, y)$  (GONZALEZ; WOODS, 2008).

A imagem é obtida a partir do produto das duas funções, como em (2.1).

$$f(x, y) = i(x, y)r(x, y) \quad (2.1)$$

onde

$$0 < i(x, y) < \infty \quad (2.2)$$

e

$$0 < r(x, y) < 1. \quad (2.3)$$


A intensidade da função de iluminância é definida pelo sensor utilizado para aquisição da imagem e deve ser finita. A refletância do objeto é limitada entre 0 e 1, sendo que 0 representa a absorção total e 1 representa a reflexão total.

No ambiente natural os sinais e imagens são analógicos, no sentido de que o sinal existe num domínio espaço/tempo contínuo, e que seus valores também são representados dentro de um espaço contínuo de possibilidades (BOVIK, 2009). No entanto, para processar as imagens em um ambiente computacional é necessário digitalizar esse sinal, com os processos de amostragem e quantização.

De acordo com Pedrini e Schwartz (2008), amostragem é o processo de discretização do domínio de definição da imagem nas direções  $x$  e  $y$ , gerando uma matriz de  $M \times N$  amostras, onde cada elemento dessa matriz é chamado pixel (*picture element*). Quanto maior o número de linhas e colunas da imagem, maior o nível de detalhamento da amostragem, contudo o correto espaçamento entre as amostras tomadas da imagem contínua é essencial para evitar a perda de informações no processo de amostragem.

Na Figura 6 é possível visualizar o efeito da variação da densidade da amostragem em uma imagem. Na primeira amostragem a imagem foi discretizada em uma matriz  $256 \times 256$ , em sequência foi discretizada, respectivamente, em uma matriz  $128 \times 128$  e em uma matriz  $64 \times 64$ .

Figura 6 – Efeito visual da variação da densidade da amostragem.



Fonte: Adaptado de MathWorks (2016a).


A outra etapa do processo de digitalização da imagem é a quantização, onde a intensidade dos pixels da imagem é definida em função da intensidade luminosa que incide sobre o elemento sensor. Quando um pixel é quantizado, ele é associado a um número dentro de um *range* finito de valores. O passo de variação da intensidade do pixel dentro desse *range* de valores é uma variável ajustável, mas por conveniência conceitual e facilidade de formatação digital, a intensidade do pixel é mapeada por uma transformação linear em um conjunto de valores inteiros não negativos (2.4).

$$\{0, \dots, K-1\} \quad (2.4)$$

onde  $K$  é uma potência de 2:  $K = 2^B$ . Portanto, o número de níveis de intensidade possíveis é  $K$ , e  $B$  é número de bits necessários para realizar a quantização. Normalmente utilizam-se 1 ou 8 bits, uma imagem quantizada com  $B=1$  é uma imagem binarizada e uma imagem quantizada com  $B=8$  possui 256 níveis de intensidade (BOVIK, 2009). Por convenção a cor preta é atribuída ao menor valor de intensidade, que seria o “0”, e a cor branca é atribuída ao maior valor de intensidade  $K$ .

Após a digitalização obtém-se  $f(x, y)$ , cuja orientação do sistema de coordenadas é apresentado na Figura 7. Observa-se que o eixo das ordenadas é invertido em relação ao plano cartesiano.

Figura 7 – Sistema de coordenadas para representação de imagens digitais.

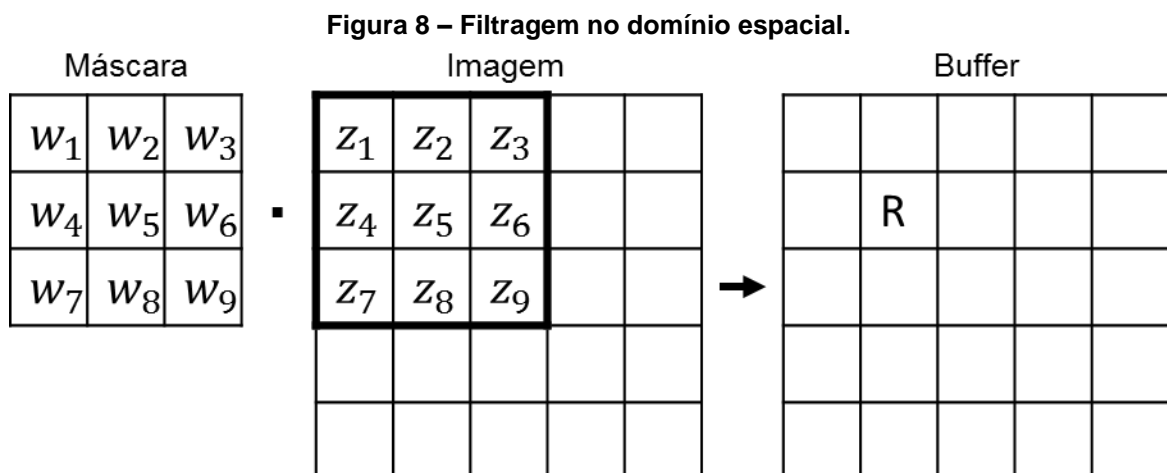


Fonte: Autoria própria.

## 2.2 FILTRAGEM ESPACIAL

Normalmente, a filtragem no domínio espacial de uma imagem é realizada por meio de matrizes de ganhos denominadas máscaras, as quais são aplicadas sobre a imagem (PEDRINI; SCHWARTZ, 2008). Tal processo consiste, basicamente, em sobrepor a máscara na imagem, multiplicar os valores coincidentes e somar todos os resultados. Isto é equivalente a encontrar o produto interno da máscara com a imagem subjacente (UMBAUGH, 2010).

Na Figura 8 pode-se observar uma etapa do processo de filtragem no domínio espacial.



Fonte: Autoria própria.

Considerando a máscara e a região da imagem representados na Figura 8, o resultado de um passo da operação de filtragem é dado por (2.5).

$$R = w_1 z_1 + w_2 z_2 + \dots + w_9 z_9 \quad (2.5)$$

O resultado do passo é armazenado em um *buffer* na posição do pixel central da máscara, conforme Figura 8. A máscara é então deslocada para a próxima posição na imagem e o processo se repete até que todas as posições tenham sido cobertas.

A partir da filtragem espacial, derivam-se dois conceitos, a correlação e a convolução.

Seja  $w$  a máscara do filtro e  $f$  a imagem, a operação de correlação  $w \cdot f$  é expressa em (2.6), de acordo com Pedrini e Schwartz (2008).

$$w \cdot f(x, y) = \sum_{i=-m/2}^{m/2} \sum_{j=-n/2}^{n/2} w(i, j) f(x+i, y+j) \quad (2.6)$$

O processo de convolução é similar ao de correlação, com a diferença de que o filtro  $w$  deve sofrer uma reflexão, ou seja, uma rotação de  $180^\circ$  antes de ser aplicado à imagem. Sendo assim, a operação de convolução, representada por  $w * f$ , é dada por (2.7).

$$w * f(x, y) = \sum_{i=-m/2}^{m/2} \sum_{j=-n/2}^{n/2} w(i, j) f(x-i, y-j) \quad (2.7)$$

Por análise, constata-se que as operações de correlação e convolução produzem respostas idênticas no caso específico onde a máscara do filtro aplicada é simétrica, isto é  $w' = w$ .

Outra observação que deve ser considerada refere-se à intensidade dos pixels nos limites do quadro da imagem, que na operação padrão de filtragem são nulos, pois não se aplica a máscara além da fronteira da imagem. Tal efeito é indesejado em algumas aplicações, por isso, existem métodos na literatura que fornecem alternativas a operação padrão, tais como o método simétrico e o método



de preenchimento por repetição. O método simétrico consiste na reflexão das bordas horizontais e verticais da imagem para preenchimento dos pontos nulos. Ao passo que no método de preenchimento por repetição, o valor válido mais próximo da borda é repetido até o limite da imagem.

Na Figura 9, os métodos listados são apresentados, observa-se que na região central as imagens são iguais.

**Figura 9 – Métodos de preenchimento da região de limite das imagens filtradas.**



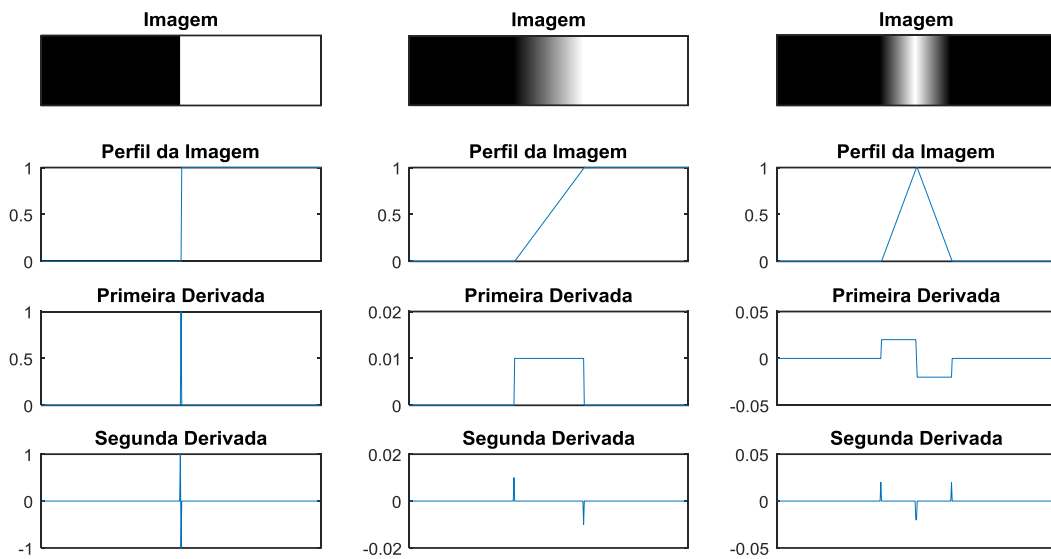
**Fonte: Adaptado de MathWorks (2016b).**

O processo de filtragem espacial é fundamental nas aplicações relacionadas a processamento de imagens, uma das aplicações tradicionais trata-se da obtenção da derivada da imagem nos eixos vertical e horizontal, o resultado obtido também é conhecido como gradiente da imagem.

### 2.3 ANÁLISE DO GRADIENTE

A maioria dos algoritmos para detecção de bordas são baseados na análise do gradiente da imagem. A detecção de mudanças na intensidade da imagem, com o objetivo de localizar suas bordas, pode ser conseguida aplicando as derivadas de primeira ou segunda ordem (GONZALEZ; WOODS, 2008). Considerando as formas ilustradas na Figura 10, analisando o perfil de intensidade e as derivadas é possível tomar nota sobre o reconhecimento de padrões para alguns tipos de bordas ideais.

**Figura 10 – Perfil de intensidade de alguns tipos de bordas ideais.**



**Fonte: Autoria própria.**

Conclui-se que a primeira derivada pode ser usada para detectar a presença de uma borda em um ponto da imagem. De modo similar, a segunda derivada pode ser usada para determinar se um pixel na região da borda se localiza na região de maior ou menor intensidade (GONZALEZ; WOODS, 2008).

### 2.3.1 Magnitude do Gradiente

Tratando a imagem como uma função  $f(x, y)$ , seu gradiente é denotado por  $\nabla f$ . Portanto, o gradiente de  $f$  nas coordenadas  $(x, y)$  é definido conforme o vetor coluna bidimensional:

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix}. \quad (2.8)$$

A aproximação discreta para a Equação (2.8) é conseguida por meio das equações seguintes:

$$G_x = f(x+1, y) - f(x, y) \quad (2.9)$$

e

$$G_y = f(x, y+1) - f(x, y). \quad (2.10)$$

A Figura 11 ilustra as máscaras de convolução utilizadas para implementar as Equações (2.9) e (2.10) em algoritmos de processamento de imagem. Nota-se que as máscaras utilizadas são unidimensionais.

**Figura 11 – Máscaras unidimensionais para cálculo da magnitude do gradiente nos eixos x e y.**

$$\begin{array}{c}
 G_x \\
 \begin{array}{|c|}
 \hline
 -1 \\
 \hline
 1 \\
 \hline
 \end{array}
 \end{array}
 \quad
 \begin{array}{c}
 G_y \\
 \begin{array}{|c|c|}
 \hline
 -1 & 1 \\
 \hline
 \end{array}
 \end{array}$$

**Fonte: Adaptado de Gonzalez e Woods (2008).**

Na literatura, encontram-se alternativas a máscara de convolução padrão, como os operadores de Roberts, Prewitt e Sobel, que são ilustrados na Figura 12 (GONZALEZ; WOODS, 2008).

O operador proposto por Roberts (1963) foi implementado usando duas máscaras de convolução 2 x 2, projetadas para destacarem a intensidade das bordas a  $\pm 45^\circ$  da grade de pixels. Assim como o operador da Figura 11, os *kernels* de Roberts retornam os componentes de gradiente da imagem,  $G_x$  e  $G_y$ .

No entanto, para obter as componentes separáveis nos eixos x e y, utiliza-se o operador de Prewitt (1970). Outra vantagem está no fato de que os *kernels* de tamanho 2 x 2 não são tão úteis para o cálculo da direção da borda como os *kernels* que são simétricos em relação ao ponto central (GONZALEZ; WOODS, 2008), cujo menor tamanho é 3 x 3 (como é o caso dos operadores de Prewitt e Sobel).

A diferença entre a máscara de Prewitt e a máscara proposta por Sobel e Feldman (1968) está no fato que Sobel e Feldman (1968) implementam a derivada em uma direção e uma ponderação gaussiana (aproximada) na outra. A vantagem disso é a suavização da região da borda, o que reduz a influência de ruídos ou pixels isolados na resposta do filtro (SOLOMON; BRECKON, 2011).

Na Figura 12 pode-se observar os operadores de Roberts, Prewitt e Sobel.

Figura 12 – Operadores de Roberts, Prewitt e Sobel.

	Roberts	Prewitt	Sobel																						
Derivada em X	<table border="1"> <tr><td>0</td><td>-1</td></tr> <tr><td>1</td><td>0</td></tr> </table>	0	-1	1	0	<table border="1"> <tr><td>1</td><td>0</td><td>-1</td></tr> <tr><td>1</td><td>0</td><td>-1</td></tr> <tr><td>1</td><td>0</td><td>-1</td></tr> </table>	1	0	-1	1	0	-1	1	0	-1	<table border="1"> <tr><td>1</td><td>0</td><td>-1</td></tr> <tr><td>2</td><td>0</td><td>-2</td></tr> <tr><td>1</td><td>0</td><td>-1</td></tr> </table>	1	0	-1	2	0	-2	1	0	-1
0	-1																								
1	0																								
1	0	-1																							
1	0	-1																							
1	0	-1																							
1	0	-1																							
2	0	-2																							
1	0	-1																							
Derivada em Y	<table border="1"> <tr><td>-1</td><td>0</td></tr> <tr><td>0</td><td>1</td></tr> </table>	-1	0	0	1	<table border="1"> <tr><td>1</td><td>1</td><td>1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>-1</td><td>-1</td></tr> </table>	1	1	1	0	0	0	-1	-1	-1	<table border="1"> <tr><td>1</td><td>2</td><td>1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>-1</td><td>-2</td><td>-1</td></tr> </table>	1	2	1	0	0	0	-1	-2	-1
-1	0																								
0	1																								
1	1	1																							
0	0	0																							
-1	-1	-1																							
1	2	1																							
0	0	0																							
-1	-2	-1																							

Fonte: Adaptado de Solomon e Breckon (2011).

A magnitude do vetor resultante da operação de convolução entre as máscaras propostas e a imagem de entrada é:

$$\nabla f = \text{mag}(\nabla f) = [G_x^2 + G_y^2]^{1/2}. \quad (2.11)$$

### 2.3.2 Direção do Gradiente

Outra informação que pode ser extraída a partir da análise do gradiente da imagem é sua direção, principalmente ao trabalhar com detecção de bordas em aplicações onde seja possível prever a orientação do objeto de interesse. A direção do gradiente obtida a partir de  $G_x$  e  $G_y$  de um filtro separável é:

$$\theta = \tan^{-1}\left(\frac{G_y}{G_x}\right). \quad (2.12)$$

Para o operador de Roberts é necessário compensar o efeito da rotação em  $\pm 45^\circ$  do *kernel*:

$$\theta = \tan^{-1}\left(\frac{G_y}{G_x}\right) + \frac{1}{4}\pi. \quad (2.13)$$

Na próxima seção serão apresentados dois algoritmos para detecção de bordas, o filtro de Canny e o *Steerable Filter*.

## 2.4 TÉCNICAS APLICADAS PARA DETECÇÃO DE BORDAS

A base para os algoritmos de detecção de bordas é análise da variação da intensidade de cor da imagem, introduzido na seção anterior. Dois dos algoritmos de maior representatividade são apresentados nesta seção, o filtro Canny, que é um detector de bordas clássico, com aplicações globais, e o *Steerable Filter*, que tem sido aplicado na literatura em sistemas relacionados à detecção de faixa nas estradas.

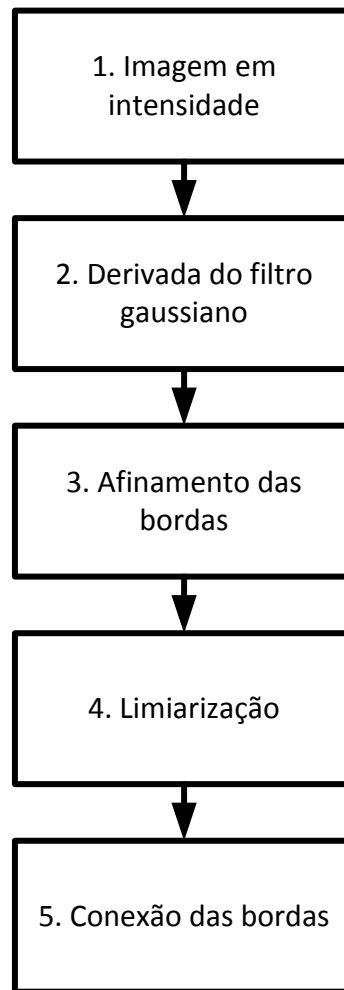
### 2.4.1 Filtro Canny

Em meados da década de 80, John Canny publicou um algoritmo ótimo para detecção de bordas, que ficou conhecido como o algoritmo detector de bordas de Canny, com base nos critérios seguintes (CANNY, 1986):

1. Boa detecção. Deve haver uma baixa probabilidade de ocorrência de falhas de marcação de pontos de bordas reais, e baixa probabilidade de marcação errônea de pontos que não correspondem a bordas. Em resumo, este critério corresponde à maximização da relação sinal/ruído.
2. Boa localização. Os pontos marcados como bordas pelo operador devem se localizar o mais próximo possível do centro da borda verdadeira.
3. Somente uma resposta por borda. Se forem capturadas duas respostas para a mesma borda, uma delas deve ser considerada falsa.

O fluxograma da Figura 13 ilustra os estágios do algoritmo detector de bordas de Canny. O algoritmo foi dividido em cinco estágios, incluindo, respectivamente, a conversão do espaço de cores, a aplicação do filtro gaussiano, a limiarização, o afinamento das bordas e a conexão das mesmas.

Figura 13 – Estágios do algoritmo detector de bordas de Canny.



Fonte: Autoria própria.

A entrada do filtro é a imagem em intensidade (ou escala de cinza), para as aplicações em processamento de imagem, é comum a aquisição da amostra em R'G'B' e, de acordo com a aplicação, realizar as conversões no espaço de cores. A justificativa para a conversão em escala de cinza está na redução das camadas de matrizes necessárias para representar a imagem de 3 (R'G'B) para 1 (escala de cinza). O padrão NTSC para conversão de R'G'B' para escala de cinza é a soma ponderada apresentada na equação:

$$I_{Intensidade} = 0,2989 \times R' + 0,5870 \times G' + 0,1140 \times B'. \quad (2.14)$$

A segunda etapa consiste da aplicação da derivada do filtro gaussiano para supressão dos ruídos e computar o gradiente da imagem, assim como sua magnitude e orientação.

A etapa de afinamento das bordas, tecnicamente chamada de *non-maximal suppression*, é uma etapa necessária para atender o critério de localização. O processo consiste na detecção de áreas com gradiente de alta intensidade e análise do valor de pico na direção do gradiente. Dessa forma, somente os pontos mais significativos da região da borda são mantidos, enquanto todos os outros são suprimidos (NIXON; AGUADO, 2006).


Em seguida, aplica-se a limiarização sobre a matriz de gradiente com as bordas afinadas para obtenção da imagem binarizada. A limiarização é uma técnica de processamento de imagem que consiste na comparação de cada pixel de uma imagem de entrada  $f(x, y)$  por um limiar  $T$ , resultando em uma saída binarizada  $g(x, y)$  (ZHOU; WU; ZHANG, J., 2010):

$$g(x, y) = \begin{cases} 1 & \text{se } f(x, y) \geq T \\ 0 & \text{se } f(x, y) < T \end{cases} \quad (2.15)$$

Os pixels com intensidade 1 são as bordas e os pixels com intensidade 0 correspondem ao *background*. O algoritmo de Canny introduz uma dupla limiarização também chamada histerese de limiarização. A aplicação do limiar alto (*high threshold*) tem como objetivo a detecção das bordas de maior intensidade, o limiar baixo (*low threshold*) é utilizado para detecção das bordas fracas.

Finalmente, na etapa de conexão, analisa-se as saídas geradas pela limiarização por histerese, o algoritmo define se a união de dois segmentos de bordas fortes utilizando uma borda fraca é razoável. Esse procedimento é ilustrado pela Figura 14, o resultado da aplicação do limiar alto é apresentado em (a), o resultado da aplicação do limiar baixo é apresentado em (b), em (c) é possível analisar as bordas conectadas.

Figura 14 – Conexão de pontos utilizando a limiarização por histerese.




Fonte: Nixon e Aguado (2006).

Percebe-se que todas as bordas de (a) estão presentes em (c), no entanto percebe-se que as bordas de (b) são usadas para complementar (c).

Em resumo, as etapas do algoritmo são apresentadas na Figura 15. A suavização da imagem em escala de cinza utilizando o filtro gaussiano é ilustrada em (a), a magnitude do gradiente de (a) é ilustrada em (b), a etapa de afinamento das bordas é apresentada em (c), por fim, a limiarização por histerese e a conexão dos pontos resultando na saída do filtro Canny é apresentado em (d).

Figura 15 – Etapas do algoritmo detector de bordas de Canny.



Fonte: Nixon e Aguado (2006).


#### 2.4.2 Filtro Direcionável (Steerable Filter)

O nome *Steerable Filter* foi proposto por Freeman e Adelson (1991) e trata-se, resumidamente, de uma técnica de sintetização de um filtro base em orientações arbitrárias a partir da operação de combinação linear das contribuições individuais de cada orientação. O diagrama de blocos do algoritmo é ilustrado na Figura 16. A



operação de convolução entre a imagem de entrada e o filtro base é efetuada  $n$  vezes, com a orientação do filtro sendo alterada a cada iteração. A contribuição de cada orientação do filtro base é ponderada por um ganho  $K_n$ . Após a combinação linear das contribuições individuais de cada orientação é realizada a operação de limiarização para obtenção da imagem binarizada de saída.

Figura 16 – Diagrama de blocos do algoritmo *Steerable Filter*.



Fonte: Autoria própria.

Considerando a função gaussiana bidimensional circularmente simétrica,  $G(x, y)$ , escrita nas coordenadas cartesianas  $x$  e  $y$ :

$$G(x, y) = e^{-(x^2+y^2)} \quad (2.16)$$

Onde, por conveniência, a constante de normalização foi definida como 1. A Equação (2.16) pode ser escrita na forma separável para acelerar o processamento do filtro. Separando os filtros em componentes  $x$  e  $y$ , a convolução do filtro com a imagem pode ser dividida em duas convoluções (MCCALL; TRIVEDI, 2006). A primeira derivada da função em relação a  $x$ ,  $G_1^{0^\circ}$ , é escrita como:

$$G_1^{0^\circ} = \frac{\partial}{\partial x} e^{-(x^2+y^2)} = -2xe^{-(x^2+y^2)}. \quad (2.17)$$

A derivada da mesma função em relação a  $y$  é representada por  $G_1^{90^\circ}$ :


$$G_1^{90^\circ} = \frac{\partial}{\partial y} e^{-(x^2+y^2)} = -2ye^{-(x^2+y^2)}. \quad (2.18)$$

O filtro base  $G_1$  rotacionado por um ângulo  $\theta$  é obtido por meio da combinação linear entre  $G_1^{0^\circ}$  e  $G_1^{90^\circ}$ :

$$G_1^\theta = \cos(\theta)G_1^{0^\circ} + \sin(\theta)G_1^{90^\circ}. \quad (2.19)$$

A representação visual da máscara do filtro gaussiano da Equação (2.19), obtida para diferentes valores de  $\theta$  é apresentada na Figura 17. Em (a)  $\theta=0^\circ$ , portanto a contribuição de  $G_1^{90^\circ}$  é nula. Em (b) a máscara é rotacionada em  $45^\circ$ , tendo contribuição equivalente de  $G_1^{0^\circ}$  e  $G_1^{90^\circ}$ , assim como em (d) onde a máscara é rotacionada em  $135^\circ$ . Em (c)  $\theta=90^\circ$ , portanto a contribuição de  $G_1^{0^\circ}$  é nula.

Figura 17 – Máscara do filtro gaussiano para a)  $\theta = 0^\circ$ , b)  $\theta = 45^\circ$ , c)  $\theta = 90^\circ$  e d)  $\theta = 135^\circ$ .



Fonte: Autoria própria.

Sendo  $I$  a imagem de entrada e  $*$  representando o operador de convolução, obtém-se as componentes separáveis da imagem filtrada  $R_1^{0^\circ}$  e  $R_1^{90^\circ}$ :

$$R_1^{0^\circ} = G_1^{0^\circ} * I \quad (2.20)$$

$$R_1^{90^\circ} = G_1^{90^\circ} * I \quad (2.21)$$

Então, a imagem filtrada é obtida por meio da combinação linear entre (2.20) e (2.21).

$$R_1^\theta = \cos(\theta)R_1^{0^\circ} + \sin(\theta)R_1^{90^\circ}. \quad (2.22)$$

Após a obtenção das imagens filtradas a partir da orientação do filtro base, Freeman e Adelson (1991) propuseram o uso de funções de interpolação  $k_j(\theta)$  para ponderar a contribuição de cada orientação durante a sintetização dos resultados. Na Tabela 1 encontram-se as equações sugeridas para determinação de  $k_j(\theta)$  em função da ordem polinomial do filtro.

**Tabela 1 – Funções de interpolação  $k_j(\theta)$  em função da ordem polinomial do filtro.**

Ordem Polinomial	Função de interpolação
1	$k_j(\theta) = \frac{1}{2} [2 \cos(\theta - \theta_j)]$
2	$k_j(\theta) = \frac{1}{3} [1 + 2 \cos(2(\theta - \theta_j))]$
3	$k_j(\theta) = \frac{1}{4} [2 \cos(\theta - \theta_j) + 2 \cos(3(\theta - \theta_j))]$
4	$k_j(\theta) = \frac{1}{5} [1 + 2 \cos(2(\theta - \theta_j)) + 2 \cos(4(\theta - \theta_j))]$
5	$k_j(\theta) = \frac{1}{6} [2 \cos(\theta - \theta_j) + 2 \cos(3(\theta - \theta_j)) + 2 \cos(5(\theta - \theta_j))]$

**Fonte: Freeman e Adelson (1991).**

Finalizando o algoritmo, na etapa de limiarização obtém-se a imagem de saída binarizada. O limiar pode ser constante ou adaptativo, como na abordagem de Otsu (1975), que é uma técnica de limiarização ótima. No algoritmo de Otsu assume-se duas classes de pixels para uma imagem (pixels de *foreground* e pixels de *background*), o limiar ótimo é calculado separando as duas classes, garantindo-se mínima variância intra-classe e máxima variância inter-classe.

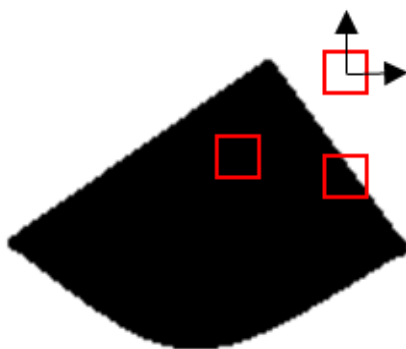
Na seção seguinte discorre-se sobre as técnicas de morfologia matemática binária em processamento de imagens digitais, que podem ser aplicadas tanto para extração de características da imagem quanto para otimização da relação sinal/ruído.

## 2.5 MORFOLOGIA MATEMÁTICA BINÁRIA

A morfologia matemática é um ramo do estudo de processamento de imagens, desenvolvida inicialmente por Matheron e Serra, que se concentra na análise da estrutura geométrica da imagem. A ideia principal consiste na sondagem de uma imagem com um elemento estruturante (ou sonda) e analisar o modo como o elemento estruturante se adapta (ou não) na imagem (DOUGHERTY; LOTUFO, 2003).

Para elucidar o parágrafo anterior, a Figura 18 apresenta um elemento estruturante quadrado e um objeto aleatório representado na forma de uma imagem binarizada. O elemento estruturante é colocado sobre duas regiões, uma na qual ele se adapta e outra em que não se adapta. A escolha adequada do elemento estruturante depende do tipo de informação desejado, como o foco deste trabalho é a detecção de faixas de rodovias, é razoável a aplicação de elementos estruturantes no formato de linhas.

**Figura 18 – O conceito de elemento estruturante e sondagem.**



**Fonte: Autoria própria.**

A seguir serão apresentados os operadores e algoritmos utilizados para efetuar as operações morfológicas binárias de erosão, dilatação, abertura, fechamento e análise dos componentes conectados.

### 2.5.1 Erosão

O entendimento das definições de translação e sondagem em morfologia matemática se torna necessário para a realização do processo de erosão de uma imagem  $A$  por um elemento estruturante  $B$ .

Portanto, pode-se denotar a translação de um conjunto  $A$  por um ponto  $x$  como  $A_x$ , que matematicamente é definida como:

$$A_x = \{a+x : a \in A\}. \quad (2.23)$$

Já o processo de sondagem consiste na marcação das posições (translações) de um elemento estruturante onde ele se adapta a uma imagem (DOUGHERTY; LOTUFO, 2003).

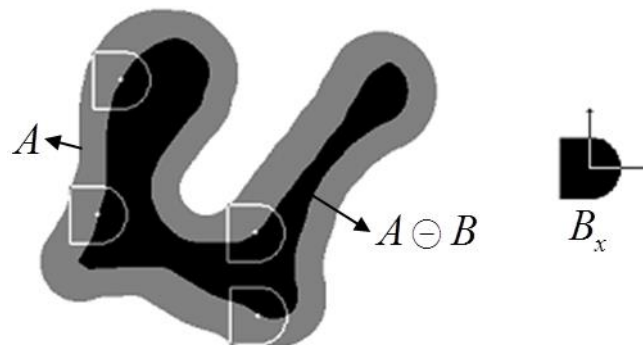
Andrade (2014) afirma que, sendo  $A$  e  $B$  conjuntos no espaço  $\mathbb{R}^2$ , a erosão de  $A$  por  $B$ , denotada  $A \ominus B$ , é definida como:

$$A \ominus B = \{x : B_x \subset A\} \quad (2.24)$$

Onde  $\subset$  denota a relação do subconjunto,  $A$  é a imagem de entrada e  $B$  o elemento estruturante.  $A \ominus B$  consiste de todos os pontos  $x$  para qual a translação de  $B$  por  $x$  se adapta dentro de  $A$ .

Essa operação é ilustrada na Figura 19.

**Figura 19 – Operação morfológica de erosão.**



Fonte: Adaptado de Dougherty e Lotufo (2003).

A imagem original é representada em cinza e o resultado da erosão é sobreposto em preto. O elemento estruturante utilizado é demonstrado à direita imagem e a demonstração de algumas translações do elemento estruturante pode ser vista em branco sobre a imagem original.

### 2.5.2 Dilatação

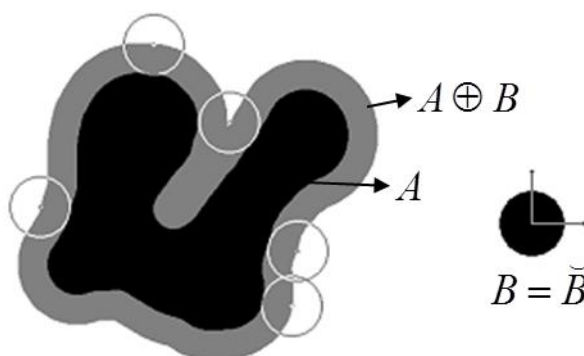
Sejam  $A$  e  $B$  conjuntos no espaço  $\mathbb{R}^2$  e seja  $\emptyset$  o conjunto vazio. A dilatação de  $A$  por  $B$ , denotada  $A \oplus B$ , é definida como:

$$A \oplus B = (A^c \ominus \check{B})^c \quad (2.25)$$

Onde  $A^c$  denota o complemento de  $A$  e  $\check{B}$  é a reflexão de  $B$  (também pode ser definido como uma rotação de  $180^\circ$  sobre a origem). Assim para realizar a operação  $A \oplus B$ , realiza-se a operação de erosão de  $A^c$  por  $\check{B}$ , então é retirado o complemento do resultado.

Em resumo erosão e dilatação são operações complementares, a erosão reduz a dimensionalidade da imagem e a dilatação expande a imagem. Um exemplo de aplicação da operação de dilatação, com um elemento estruturante circular, é ilustrado na Figura 20. A imagem de entrada é ilustrada em preto e o efeito da dilatação é ilustrado em cinza.

**Figura 20 – Operação morfológica de dilatação.**



Fonte: Adaptado de Dougherty e Lotufo (2003).

### 2.5.3 Abertura e Fechamento

As operações de erosão e dilatação são base para a aplicação de outros filtros morfológicos, como a abertura e o fechamento. “A abertura, em geral, suaviza o contorno de uma imagem e elimina proeminências delgadas. O fechamento, por sua vez, funde pequenas quebras, elimina pequenos orifícios e preenche fendas no contorno” (ANDRADE, 2014).

Baseado na definição apresentada em Filho e Neto (1999), sendo  $A$  um conjunto e  $B$  um elemento estruturante, a abertura de  $A$  por  $B$ , denotada por  $A \circ B$ , é definida como:

$$A \circ B = (A \ominus B) \oplus B. \quad (2.26)$$

Portanto,  $A \circ B$  é a erosão de  $A$  por  $B$ , seguida da dilatação do resultado por  $B$ , essa sequência é exemplificada na Figura 21. Apresenta-se em sequência a imagem de entrada, o resultado da operação de erosão e o resultado da operação de dilatação, utilizando um elemento estruturante circular.




**Fonte: Autoria própria.**

Sendo  $A$  um conjunto e  $B$  o elemento estruturante, o fechamento de  $A$  por  $B$ , denotado por  $A \bullet B$ , é definido como:

$$A \bullet B = (A \oplus B) \ominus B \quad (2.27)$$

Portanto,  $A \bullet B$  é a dilatação de  $A$  por  $B$ , seguida da erosão do resultado obtido por  $B$ , essa sequência é exemplificada na Figura 22.

Figura 22 – Operação morfológica de fechamento.




Fonte: Autoria própria.

#### 2.5.4 Análise dos Componentes Conectados - Rotulação

A análise dos componentes conectados em uma imagem binarizada também é realizada por meio da sondagem da imagem por um elemento estruturante, durante o processo são atribuídos rótulos para as regiões de pixels conectados da imagem. No entanto, as atribuições dos rótulos não podem ser feitas até que todo o perímetro do componente conectado seja examinado (FOLTZ, 1997). Uma sondagem simples da imagem não é suficiente, a maioria dos algoritmos sonda a imagem pelo menos duas vezes, de baixo para cima e da esquerda para a direita.

Os elementos estruturantes normalmente utilizados são a máscara de vizinhança 4 e a máscara de vizinhança 8. Conforme ilustrado na Figura 23, a máscara de vizinhança 4 tem o formato de uma cruz em torno do pixel central e a máscara de vizinhança 8 tem o formato de um quadrado ao redor do pixel central.

Figura 23 – Máscara de vizinhança 4 e máscara de vizinhança 8.



Fonte: Autoria própria.

No exemplo de aplicação da Figura 24, a rotulação das componentes conectadas de uma matriz 4x4 utilizando máscaras de vizinhança 4 e 8 é ilustrada. Na matriz do lado esquerdo, como resultado da aplicação da máscara de vizinhança



4, são retirados três rótulos, o rótulo 1 com área 4, o rótulo 2 com área 2 e o rótulo 3 com área 1. Na matriz do lado direito, como consequência da aplicação da máscara de vizinhança 8, o resultado é um único rótulo de área 6. É possível observar que além dos vizinhos laterais e verticais, com a máscara de vizinhança 8 os vizinhos das diagonais também recebem os mesmos rótulos.

**Figura 24 – Rotulação das componentes conectadas com máscaras de vizinhança 4 e 8.**

1	1	1		1	1	1	
	1		3		1		1
		2				1	
		2				1	


**Fonte: Autoria própria.**

As etapas de detecção de bordas e pós-filtragem preparam a imagem para a aplicação de um algoritmo que, de alguma forma, interprete as características extraídas da imagem de entrada, seja por meio de identificação de padrões, rastreamento de pontos, adaptação de formas ou outra função cognitiva associada a visão. O algoritmo proposto por Hough (1962) foi projetado para obtenção dos parâmetros de um modelo analítico que representa linhas retas ou curvas, sem o conhecimento prévio da posição desses objetos.

## 2.6 TRANSFORMADA DE HOUGH PARA O RASTREAMENTO DE RETAS

Considerando um problema de detecção de linhas em uma imagem a partir de um conjunto de bordas nas coordenadas  $(x_i, y_i)$ . Um segmento de reta é representado por dois pontos  $A=(x_1, y_1)$  e  $B=(x_2, y_2)$ , conforme Figura 25 (a). Todas as possíveis retas que passam sobre o ponto  $A$  obedecem à equação  $y_1 = ax_1 + b$ , isso significa que a mesma equação pode ser interpretada como uma equação no espaço de parâmetros  $a, b$ ; apresentado na Figura 25 (b). Nota-se que um ponto no espaço da imagem é representado por uma reta no espaço de parâmetros. O ponto de interseção entre as retas no espaço de parâmetros  $a, b$ , representa os parâmetros da equação da reta que conecta os pontos  $A$  e  $B$  no espaço da imagem (SONKA; HLAVAC; BOYLE, 2014).

Figura 25 – Princípio da transformada de Hough. (a) Espaço da imagem. (b) Espaço de parâmetros  $k, q$ .




Fonte: Adaptado de Sonka, Hlavac e Boyle (2014).<sup>3</sup>

Na transformada de Hough  $A(a,b)$  é o vetor acumulador inicializado em zero que representa uma versão discretizada do espaço de parâmetros, como efeito, o número de pares  $(a,b)$  possíveis é delimitado. Quando um pixel da borda  $(x_i, y_i)$  é analisado, todas as células  $(a,b)$  em  $A$  que satisfaçam  $y_i = ax_i + b$  são incrementadas.

Após a análise de todos os pixels, as possíveis linhas existentes na imagem de entrada podem ser detectadas a partir dos máximos locais do vetor acumulador (DUDEK; JENKIN, 2010). A Figura 26 é um exemplo de detecção de linha com a transformada de Hough.

Figura 26 – Detecção de linha com a transformada de Hough.



Fonte: Adaptado de Illingworth e Kittler (1988).<sup>3</sup>

<sup>3</sup> O sistema de coordenadas da bibliografia original foi alterado para adequação ao sistema adotado neste trabalho.

Onde (a) representa os pontos que representam os pixels com valor 1 da imagem, (b) o espaço de parâmetros e (c) o acumulador. Como a representação de uma reta na imagem tende a ser um ponto no espaço de parâmetros, os parâmetros da equação da reta são extraídos a partir do máximo local do acumulador.

Apesar de ser muito utilizada para explanação dos princípios do algoritmo, a aplicação da equação paramétrica  $y = ax + b$  na transformada de Hough é limitada por dois fatores:


1. O modelo não é indicado para detecção de linhas verticais, onde  $a \rightarrow \infty$ ;
2. A discretização não-linear do parâmetro  $a$ .

Portanto, é comum utilizar a representação da linha na forma polar (2.28).

$$\rho = x \cos \theta + y \sin \theta \quad (2.28)$$

Onde  $\rho$  é a distância perpendicular da linha até a origem e  $\theta$  é o ângulo entre a perpendicular e o eixo  $x$  (Figura 27).


**Figura 27 – Representação da linha na forma polar.**



**Fonte: Autoria própria.**

Dessa forma, cada ponto no espaço da imagem é representado por uma senoide no espaço de parâmetros, conforme ilustrado na Figura 28. Essa abordagem resolve as limitações da equação paramétrica  $y = ax + b$ .

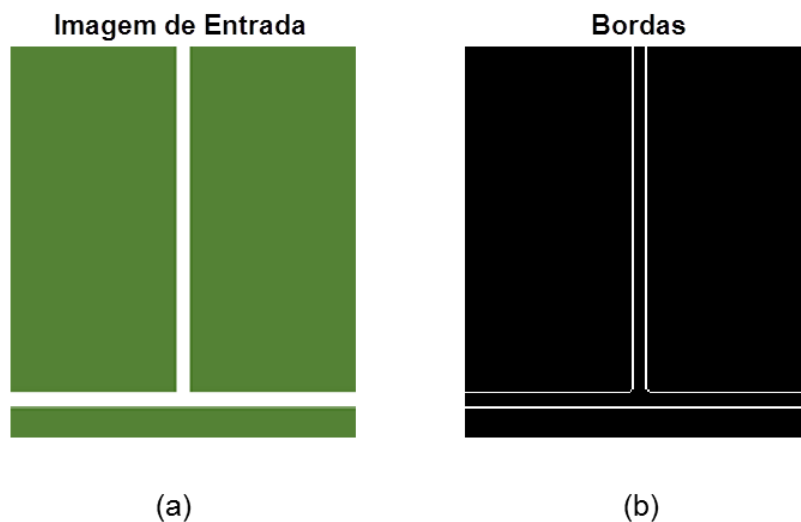
Figura 28 – Transformada de Hough no espaço  $\rho, \theta$ . (a) Espaço da imagem. (b) Espaço de parâmetros  $\rho, \theta$ .



Fonte: Autoria própria.

Para exemplificar a aplicação da transformada Hough para detecção de linhas em um cenário real, utilizou-se como amostra o ambiente da Figura 29 (a). Como o algoritmo deve receber uma imagem binária na entrada, aplicou-se o algoritmo Canny para detecção de bordas, resultando na imagem da Figura 29 (b).

Figura 29 – Aplicação da transformada de Hough em uma imagem real. (a) Imagem de entrada. (b) Bordas.



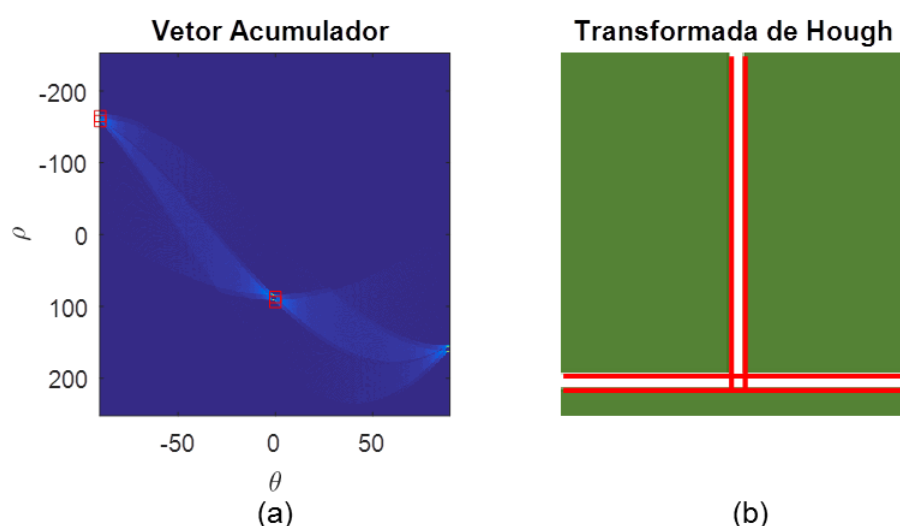
Fonte: Autoria própria.

O vetor acumulador do espaço de parâmetros obtido pela varredura dos pixels das bordas da imagem de entrada é ilustrado pela Figura 30 (a), os máximos

locais do vetor foram evidenciados nas regiões delimitadas pelos quadrados vermelhos. Os coeficientes extraídos dos máximos locais do espaço de parâmetros são relativos às linhas traçadas em vermelho sobre a Figura 30 (b). A quantidade de linhas na saída do algoritmo depende da limiarização imposta sobre vetor acumulador e/ou da especificação do programador com relação à quantidade mínima e máxima de elementos a serem detectados pelo algoritmo.

A transformada de Hough é um método de visão computacional robusto para o rastreamento de linhas, mesmo havendo a presença de outras estruturas (curvas, objetos), assim como em imagens ruidosas ou imagens com pontos perdidos (ILLINGWORTH; KITTLER, 1988).

**Figura 30 – Aplicação da transformada de Hough em uma imagem real. (a) Vetor acumulador. (b) Linhas detectadas pelo algoritmo.**



**Fonte: Autoria própria.**

Por procurar diversas ocorrências de uma forma no mesmo passo de processamento, o método exige muito armazenamento de dados (para os vetores de dimensões elevadas) e um custo computacional alto, considerando a abordagem convencional de computação sequencial. No entanto, a possibilidade de tornar seu processamento paralelo dá ao método o potencial de implementação em tempo real (SONKA; HLAVAC; BOYLE, 2014).

A transformada de Hough é comumente aplicada na etapa de processamento de alto nível de estratégias de rastreamento das faixas rodoviárias. Por este motivo, é um dos tópicos tratados no próximo capítulo, que aborda o desenvolvimento da estratégia proposta neste trabalho.

### 3 ESTRATÉGIA PARA DETECÇÃO E RASTREAMENTO DE FAIXAS RODOVIÁRIAS

Dentre os modelos utilizados para dividir as etapas de uma aplicação envolvendo processamento de imagens digitais, optou-se neste trabalho pelo modelo de divisão em níveis apresentado em Gonzalez e Woods (2008). No processamento de baixo nível realiza-se a conversão do espaço de cores da imagem, o corte da região de interesse e a filtragem para remoção dos artefatos de movimento da imagem. No processamento de nível médio é realizada a extração de características dos objetos de interesse da imagem, neste trabalho, as bordas das faixas de rodovias. Por fim, no processamento de alto nível é realizada a interpretação das características extraídas da imagem por meio do rastreamento da posição das faixas.

As amostras de vídeos utilizadas neste trabalho foram extraídas da base de dados local do GSA, localizado no campus de Ponta Grossa da UTFPR (Universidade Tecnológica Federal do Paraná). A base reúne dados coletados do barramento CAN (*Controller Area Network*) de comunicação serial automotiva, do GPS (*Global Positioning System*) e de uma câmera frontal instalada no para-brisa do veículo.

#### 3.1 PROCESSAMENTO DE BAIXO NÍVEL

As operações relacionadas ao processamento de baixo nível são apresentadas na Figura 31, que inclui as etapas de tratamento interno da imagem na própria câmera e a aplicação de técnicas desenvolvidas em software.

**Figura 31 – Diagrama de blocos representativo das etapas do processamento de baixo nível.**



**Fonte: Autoria própria.**

Utilizou-se uma câmera monocular, com tamanho de saída matricial de 480x640 (480 linhas e 640 colunas) na taxa de aquisição de 30fps (frames por segundo) para captura das imagens. Dentre as opções de processamento *onboard*

disponíveis para o modelo utilizado, a opção de foco automático foi desabilitada para garantir uniformidade das amostras e evitar falhas relacionadas às mudanças no cenário, tal como a perda do foco devido à incidência da luz do farol dos veículos que trafegam no sentido oposto da via. As opções de compensação de pouca luz e exposição à luz foram habilitadas. A compressão H.264, realizada na própria placa da câmera, reduz os níveis de utilização e de consumo de potência da CPU (*Central Processing Unit*) (LOGITECH, 2012).

A etapa de conversão do espaço de cores RGB (*Red Green Blue*) para escala de cinza (ou intensidade) é aplicada para reduzir a dimensionalidade da imagem de entrada de três para uma camada, facilitando a manipulação da imagem digital nas etapas subsequentes do processamento. O método mais popular para realização da conversão é baseado no padrão NTSC CCIR 601 e foi aplicado no desenvolvimento deste trabalho, a conversão é realizada de acordo com a equação (3.1) (BALLABENI *et al.*, 2015).

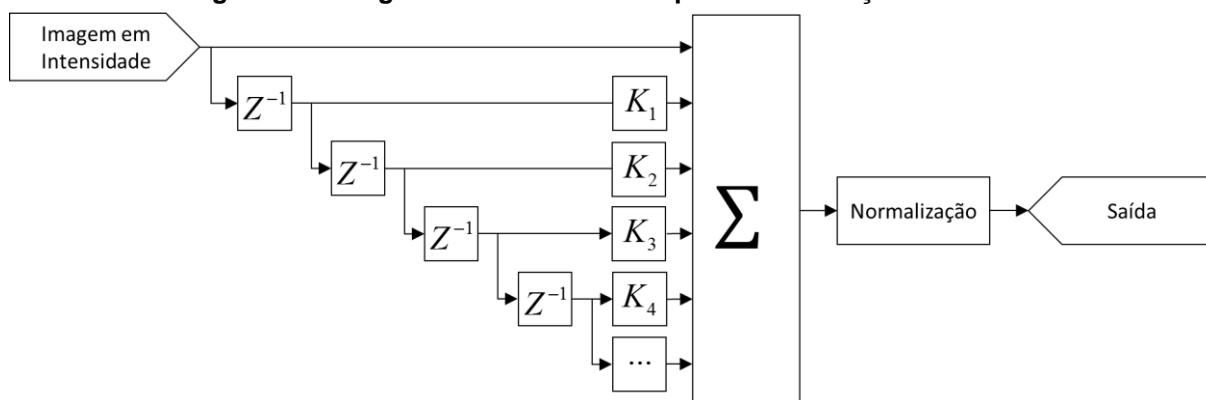
$$Y' = 0,2989R + 0,5870G + 0,1140B. \quad (3.1)$$

Onde  $Y'$  é a imagem de saída em escala de cinza,  $R$ ,  $G$  e  $B$  são as camadas de cores da imagem de entrada. Os ganhos associados a cada camada resultam na correção Gamma, que é processo de obtenção de uma escala de intensidade percebida linearmente pelo olho humano, uma vez que naturalmente a resposta do olho a variação da intensidade de cinza é não linear (SCURI, 1999).

Na etapa de acumulação recursiva de quadros do vídeo (bufferização) aplica-se a estratégia ilustrada no diagrama de blocos da Figura 32. Onde é realizado o somatório de  $n$  frames da imagem ponderados pelos ganhos  $K_n$ , o resultado obtido é normalizado para manter os valores da matriz dentro da faixa de valores desejado. O símbolo  $Z^{-1}$  representa um atraso unitário em relação ao frame atual.

A adoção dessa estratégia realça o contraste entre faixa e pista, pois a sobreposição dos frames reforça a intensidade dos pixels na região das faixas e enfraquece a região mais escura da imagem. Os frames recursivos também contribuem na eliminação de ruídos transitórios e na identificação de faixas fracas e/ou segmentadas.

**Figura 32 – Diagrama de blocos da etapa de acumulação recursiva.**



Fonte: Autoria Própria.

A região de interesse delimita a porção da imagem que será submetida aos algoritmos de extração de características e rastreamento das faixas. Pelo método mais simples, define-se uma região fixa na parte inferior da imagem (parte inferior da matriz de saída de dados da câmera), no entanto a definição adaptativa da ROI é abordada em alguns trabalhos (HILLEL *et al.*, 2014).

O Código de Trânsito Brasileiro (CTB) estabelece que o condutor deve manter uma distância de segurança lateral e frontal entre o seu e os demais veículos sob pena de infração, contudo não há determinação exata de qual distância deve ser mantida (BRASIL, 2013). Em um estudo de 2003, realizado em uma população de 22 pessoas com idade entre 18 e 27 anos, levantou-se o tempo médio de reação para frenagem e o respectivo desvio padrão (CONSIGLIO *et al.*, 2003), na Tabela 2 esses dados são apresentados juntamente com a distância percorrida considerando o caso extremo ( $t+2\sigma$  a 110 km/h, em conformidade com o CTB). Onde  $t$  representa o tempo em segundos e  $\sigma$  o desvio padrão.

**Tabela 2 – Distância percorrida até o tempo médio de reação para frenagem.**


Condição	Tempo de reação [ms]	Desvio padrão [ms]	Distância percorrida [m]
Normal	392	33	12,99
Rádio	408	31	13,41
Conversa com o passageiro	453	47	15,28
Conversa usando o telefone	464	41	15,43
Conversa usando o telefone com as mãos livres	465	51	15,77

Fonte: Adaptado de Consiglio et al. (2003).



A região de interesse proposta se localiza na parte inferior da imagem e possui altura fixa das 150 últimas linhas da matriz da imagem. A verificação do alcance, em metros, foi efetuada com auxílio do algoritmo de mapeamento em perspectiva inversa aplicado por Silva *et al.* (2017) e Johnson e Hamburger (2007). A Figura 33 ilustra o alcance obtido com a ROI proposta em uma região plana, observa-se que com 150 linhas de altura é possível cobrir cerca de 35 metros adiante, que seria a distância percorrida em 1,15 segundos caso o veículo trafegue no limite de velocidade (110 km/h).

**Figura 33 – Visão em perspectiva inversa com ROI de 150 linhas.**



**Fonte: Autoria própria.**

A Tabela 3 foi obtida a partir dos testes realizados e correlaciona o alcance, em metros, com a altura da ROI, em número de linhas. A partir dos resultados, constata-se a influência do efeito de perspectiva na imagem capturada, pois quanto maior a ROI, maior a relação alcance/altura. Por conseguinte, no campo distante da imagem (ou seja, na região mais distante do veículo), os pixels representam uma área maior no plano real em relação a um pixel situado no campo próximo.

**Tabela 3 – Relação alcance/altura da ROI.**

Altura [número de linhas]	Alcance [m]	Alcance/Altura [m/linha]	$\Delta$ Alcance/ $\Delta$ Altura [m/linha]
100	10,38	0,1037	-
110	12,05	0,1095	0,1669
120	14,37	0,1198	0,2320
130	17,82	0,1372	0,3448
140	23,49	0,1678	0,5682
150	34,54	0,2304	1,1111

**Fonte: Autoria própria.**

O desentrelaçamento é uma técnica de minimização dos efeitos dos artefatos de movimento da entrada de vídeo, o método de interpolação linear, aplicado neste trabalho é ilustrado a Figura 34. Nesta técnica as linhas intermediárias da matriz de entrada recebem o resultado da interpolação linear entre os pontos das linhas imediatamente acima e abaixo (HAAN; BELLERS, 1998).

**Figura 34 – Desentrelaçamento por interpolação linear.**

	Quadro de Entrada				Quadro de Saída		
<b>Linha 1</b>	A	B	C	<b>Linha 1</b>	A	B	C
<b>Linha 2</b>	D	E	F	<b>Linha 2</b>	$(A+G)/2$	$(B+H)/2$	$(C+I)/2$
<b>Linha 3</b>	G	H	I	<b>Linha 3</b>	G	H	I
<b>Linha 4</b>	J	K	L	<b>Linha 4</b>	$(G+M)/2$	$(H+N)/2$	$(I+O)/2$
<b>Linha 5</b>	M	N	O	<b>Linha 5</b>	M	N	O
<b>Linha 6</b>	P	Q	R	<b>Linha 6</b>	$(M+S)/2$	$(N+T)/2$	$(O+U)/2$
<b>Linha 7</b>	S	T	U	<b>Linha 7</b>	S	T	U

Fonte: Adaptado de MathWorks (2016).

Após todas as etapas supracitadas, um exemplo de imagem obtida ao fim do processamento de baixo nível é apresentada na Figura 35.

**Figura 35 – Saída da etapa de processamento de baixo nível.**

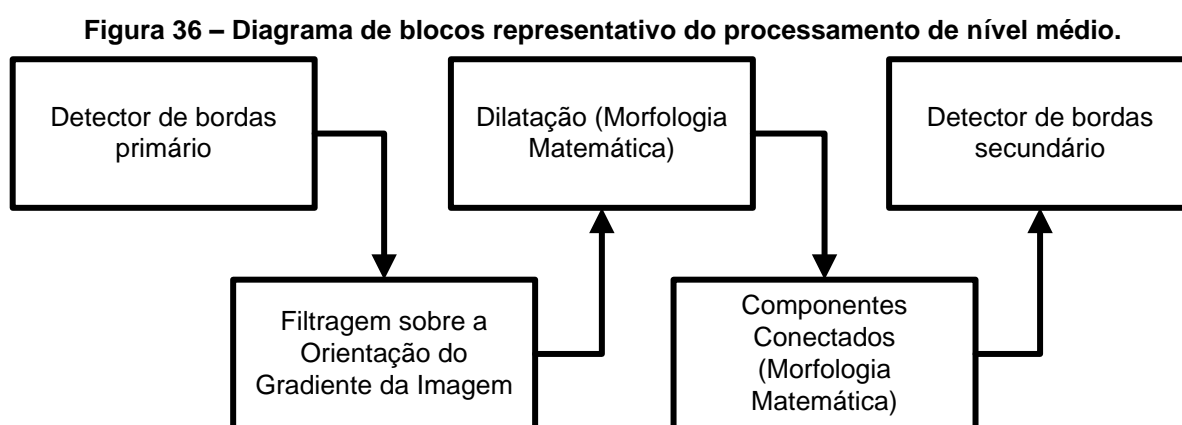


Fonte: Autoria própria.

A saída representada em escala de cinza e com as dimensões reduzidas da Figura 35 é então propagada para etapa de processamento de nível médio descrita em sequência.

### 3.2 PROCESSAMENTO DE NÍVEL MÉDIO

No processamento de nível médio, são obtidas as características das faixas mais próximas do veículo com a maior relação sinal/ruído, para tanto aplicou-se a sequência definida na Figura 36. Nesse processo ocorre a conversão do espaço de cores da imagem, de escala de cinza para binária, na qual o pixel recebe a cor branca (1) ou preta (0).



Fonte: Autoria própria.

O algoritmo detector de bordas primário é aplicado no estágio de processamento de nível médio para extração de características na ROI, optou-se pelo uso do filtro Canny devido as suas características de boa detecção, boa localização e a singularidade da resposta para cada borda. Todavia não há restrição angular no algoritmo, conseqüentemente a extração de características é realizada independentemente de o objeto ter o formato de interesse, neste caso, o formato das faixas da rodovia.

A Figura 37 ilustra o resultado da extração de características sobre a saída do processamento de baixo nível apresentado na Figura 35. Observa-se que, apesar da detecção das bordas pertencentes às faixas mais próximas ao veículo, há um excesso na quantidade de informações extraídas pelo algoritmo. Tal excesso pode desencadear o aparecimento de eventos indesejados ao funcionamento do

algoritmo, como a marcação de falso positivo, ou seja, o rastreamento de uma borda não pertencente à faixa da rodovia.


**Figura 37 – Detector de bordas Canny.**



**Fonte: Autoria própria.**

Assumindo que na perspectiva de uma câmera fixada na região central do para-brisa do veículo as orientações das faixas se enquadram em um intervalo previsível de ângulos, conforme ilustra o cenário da Figura 38, onde as setas indicam a magnitude e a orientação do gradiente obtida a partir de uma entrada em escala de cinza. Considerou-se coerente a proposta de uma filtragem baseada na orientação do gradiente das bordas da imagem, reduzindo assim os efeitos da extração excessiva de características.

**Figura 38 – Orientação do gradiente na região de uma faixa.**



**Fonte: Autoria própria.**

Contudo, durante as curvas, a orientação das faixas sofre mudanças consideráveis. A variação do módulo do ângulo interno das duas faixas mais próximas ao veículo é demonstrada na Figura 39 em três cenários, retas, curva a esquerda e curva a direita. De modo geral, nota-se o seguinte comportamento:

- Nas retas os ângulos internos são semelhantes;

- Na curva a esquerda, o ângulo interno da faixa esquerda se torna mais aberto e o ângulo interno da faixa direita se torna mais fechado;
- Na curva a direita, o ângulo interno da faixa esquerda se torna mais fechado e o ângulo interno da faixa a direita se torna mais aberto.

Tal observação é relevante, pois trabalhos como o de Jung e Kelber (2004) utilizam uma medida de simetria, definida experimentalmente, entre esses ângulos para determinação do aviso de saída de faixa.

**Figura 39 – Mudanças na orientação angular das faixas em diferentes cenários.**



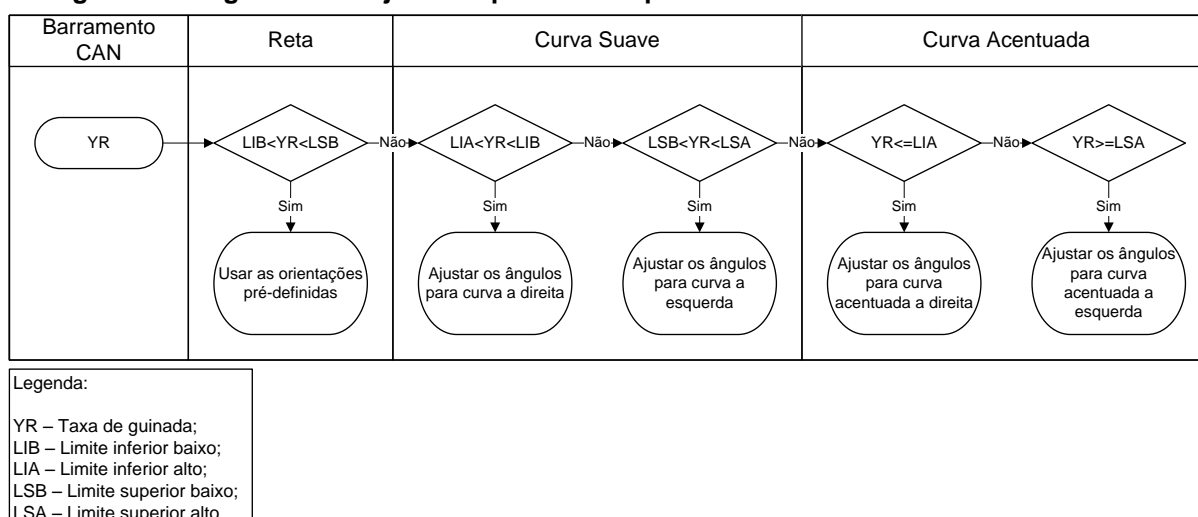
**Fonte: Autoria própria.**

A integração dos sinais da unidade de medição inercial (IMU – *Inertial Measurement Unit*), disponíveis no barramento CAN de comunicação serial do veículo, foi realizada para adequar, de forma adaptativa, os parâmetros do algoritmo de filtragem baseado na orientação do gradiente. Tipicamente, uma IMU é composta de um conjunto de sensores, sendo de importância fundamental, três giroscópios ortogonais e três acelerômetros ortogonais, medindo a velocidade angular e a aceleração linear respectivamente. Com o processamento dos sinais desses sensores é possível rastrear a posição e orientação de um dispositivo (WOODMAN, 2007).

A taxa de guinada (*yaw rate*) é um dos sinais disponibilizados pela IMU e indica a velocidade angular lateral do veículo em graus por segundo, a amplitude

deste sinal está diretamente relacionada com a direção de movimento do veículo. Portanto, a partir da análise experimental do comportamento desse sinal foram definidos os limites utilizados no algoritmo apresentado na Figura 40. Na definição da estratégia, não foram consideradas as alterações causadas pelas ultrapassagens e pela derrapagem do veículo. No caso das ultrapassagens o DAS deve ser desativado por caracterizar um ato intencional do motorista, a derrapagem é uma situação crítica, no entanto pode ser resolvida com a aplicação de outros sistemas, como o ESC.

**Figura 40 – Algoritmo de ajuste de parâmetros por meio da velocidade lateral do veículo.**



**Fonte: Autoria própria.**

A Figura 41 ilustra o resultado da implementação da filtragem sobre a orientação do gradiente aplicada a imagem da Figura 37. Constata-se que a saída apresenta menor quantidade de pixels brancos em relação à saída do filtro Canny mantendo a característica das bordas na região das faixas mais próximas. O ruído remanescente pode ser atribuído a dois fatores principais. O primeiro deve-se ao fato de que, localmente, alguns pixels formam bordas com a mesma orientação das faixas da rodovia e são, portanto, insensíveis a filtragem. O segundo consiste na utilização de uma faixa de segurança para os ângulos de interesse, a fim de evitar a filtragem excessiva da imagem, mantendo a extração de características robusta e funcional independentemente da posição do veículo na pista.

**Figura 41 – Filtragem sobre a orientação do gradiente da imagem.**



**Fonte: Autoria própria.**

As técnicas de morfologia matemática foram aplicadas neste trabalho em um processo de pós-filtragem da imagem, a estratégia proposta consiste da aplicação da dilatação seguido pela análise dos componentes conectados. A dilatação é utilizada para expandir e conectar as bordas mais próximas o que, por sua vez, reduz o número de pontos isolados na imagem e torna a análise dos componentes conectados menos laboriosa.

Na etapa de seleção do elemento estruturante para o processo de dilatação deve-se atentar quanto a forma e dimensão, as consequências de uma escolha inadequada são a descaracterização da entrada ou a expansão insuficiente para conectar os pontos de interesse. Foi definido um elemento estruturante no formato de uma matriz quadrada com dimensão 3x3 preenchida com a constante “1”, na sondagem da imagem da Figura 41 que resultou na saída apresentada na Figura 42. Nota-se a tendência de conexão entre a borda interna e externa da faixa na região do campo distante, assim como maior probabilidade de conexão entre ruído e faixa devido ao efeito de perspectiva.

**Figura 42 – Aplicação da dilatação para conexão dos pontos de interesse.**

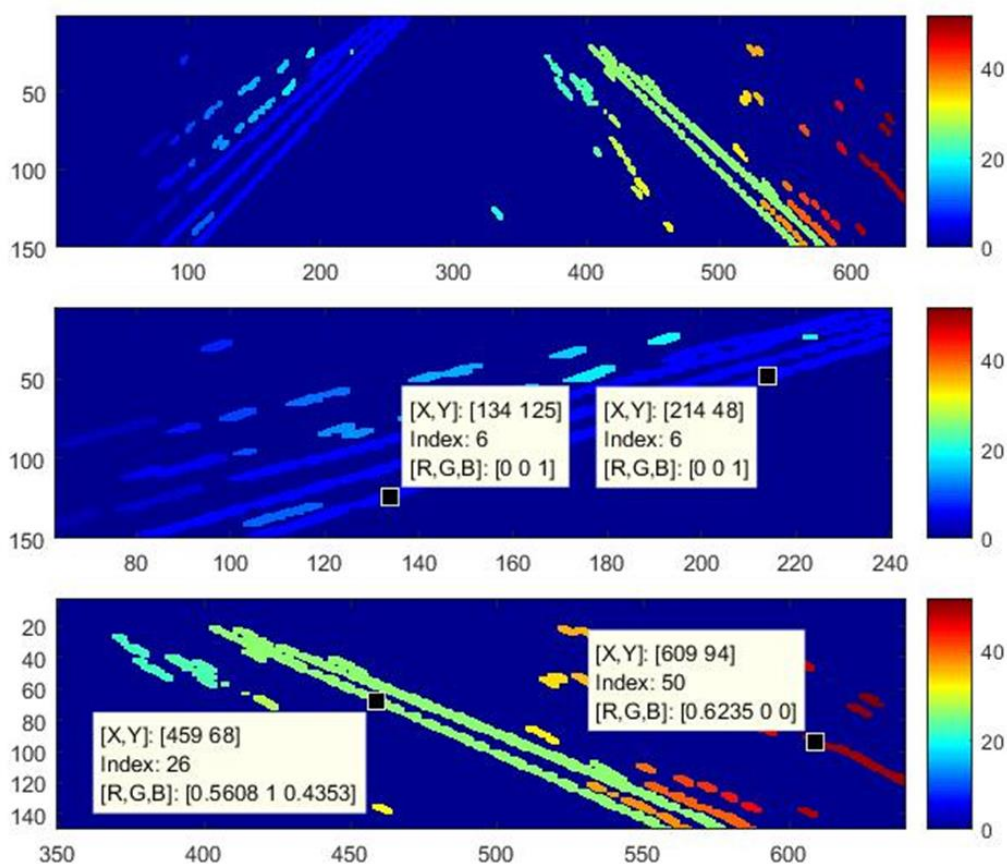


**Fonte: Autoria própria.**

A análise dos componentes conectados consiste em um processo de rotulação das ilhas de pixels interconectados da imagem. Foi adotado um elemento estruturante de conectividade 4, em formato de cruz no processo de sondagem.

Para possibilitar a ilustração da análise, os rótulos foram adequados no espaço de cores apresentado no lado direito da Figura 43, onde os pixels com a mesma tonalidade são conexos entre si. A imagem central ilustra que pixels conectados, mesmo em diferentes posições na imagem recebem o mesmo rótulo, no caso o índice 6. Dois pixels desconexos foram analisados na parte inferior da imagem, o pixel da região com tonalidade verde recebe o rótulo 26 e o pixel com tonalidade vermelha recebe o rótulo 50.

**Figura 43 – Rotulação da saída da imagem dilatada.**

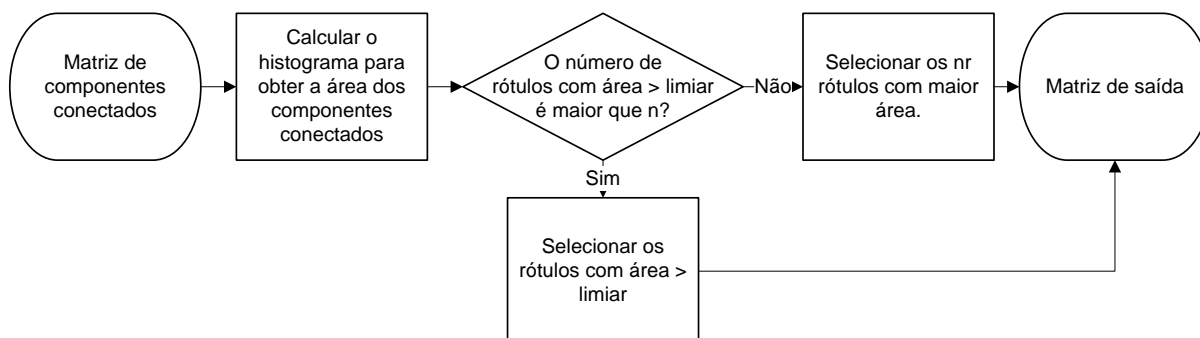


Fonte: Autoria própria.

Além da conectividade, é possível obter a área das regiões rotuladas, a análise dessas informações é a base da estratégia de redução dos ruídos da imagem de entrada. O algoritmo proposto baseia-se na propagação dos rótulos com área superior a um limiar para a saída, caso a quantidade de rótulos com área superior ao limiar seja menor que  $n$  propagam-se para a saída os  $nr$  rótulos com maior área, em conformidade com o processo ilustrado na Figura 44.




**Figura 44 – Algoritmo para filtragem da imagem baseado na análise dos componentes conectados.**



**Fonte: Autoria própria.**

A seleção dos rótulos relativos às faixas da pista é ilustrada na Figura 45 (a). Finalmente, aplica-se a etapa de afinamento das bordas prevista no algoritmo do filtro de Canny para obtenção do resultado da Figura 45 (b). A aplicação da dilatação aumenta a probabilidade da ocorrência de conexões entre a região das faixas e os ruídos próximos, como pode ser observado em algumas regiões da Figura 43, contudo permite a conexão entre segmentos da mesma faixa e reduz o esforço computacional na etapa de análise dos componentes conectados.

**Figura 45 – Saída do processamento de nível médio.**



**Fonte: Autoria própria.**

A saída é propagada para a etapa de processamento de alto nível, que no presente trabalho, consiste no rastreamento da faixa a partir das técnicas relatadas na seção seguinte.

### 3.3 PROCESSAMENTO DE ALTO NÍVEL

As bordas detectadas na etapa de processamento de nível médio são utilizadas na determinação das possíveis linhas no espaço de parâmetros da transformada de Hough. Optou-se pela partição da ROI em várias seções para acomodar as mudanças na orientação da imagem embasado no trabalho de Wang, Teoh e Shen (2004). A altura de cada seção é reduzida gradativamente da parte inferior para a parte superior da imagem, pois, analisando apenas a parte inferior da imagem, assume-se que a faixa pode ser aproximada por uma reta, já no campo distante essa definição só é aceitável caso a área analisada tenha dimensões reduzidas (JUNG; KELBER, 2004).

Como consequência, foi proposto a divisão da ROI em quatro seções com altura de 50, 40, 30 e 30 linhas, respectivamente, além da divisão entre esquerda e direita. Os espaços de parâmetros das mesmas são independentes, desse modo os segmentos de reta identificados pela transformada de Hough em uma seção não sofrem influência das seções vizinhas. Dentro do espaço de parâmetros de cada seção, são selecionados os parâmetros das retas mais relevantes, ou seja, aquelas com os maiores números de votos.

A Figura 46 ilustra a interpolação linear entre os pontos dos quatro pares de coordenadas mais relevantes.

**Figura 46 – Divisão das seções da ROI e coordenadas detectadas.**



**Fonte: Autoria própria.**

Optou-se pela análise dos quatro pares, pois a manutenção de apenas um par de coordenadas diminui a robustez do algoritmo nos seguintes cenários:

- Caso o par de coordenadas mais relevante seja inadequado em consequência da extração de características inapropriada;
- Caso os pares de coordenadas mais relevantes em duas seções, sejam relacionados a parte interna da faixa à esquerda e a parte externa da faixa à direita, e vice-versa.

Portanto, a análise sobre diferentes retas possibilita a implementação de uma etapa de seleção de coordenadas mais apropriada, na qual são consideradas a orientação da reta e sua evolução em relação os pontos das seções vizinhas.

O processo de seleção das coordenadas pode ser dividido em quatro etapas, uma para cada divisão da imagem na ROI. Primeiro, seleciona-se as coordenadas da parte inferior, as quais são a base para a análise das seções subsequentes. Tal escolha justifica-se pelo fato da seção inferior possuir a maior área e é menos afetada pelo efeito de perspectiva, consequentemente é a região com maior integridade das faixas.


A seleção das coordenadas da seção inferior (item 1 da Figura 46) é baseada nos seguintes passos:

1. Calcular o ângulo formado pelos pontos inferior e superior da seção em relação à parte interna da faixa;
2. Verificar se os ângulos obtidos se ajustam dentro dos limites mínimo e máximo de orientação;
3. Verificar se a distância horizontal, em pixels, do ponto inferior da reta se ajusta dentro da faixa especificada;
4. Selecionar os pontos válidos referentes à reta com maior ângulo interno, caso não existam pontos válidos, manter os da iteração anterior por até  $n$  iterações.

O processo descrito é válido para detecção tanto da faixa à direita do veículo quanto da faixa à esquerda. Em resumo, além de descartar coordenadas inválidas o processo favorece a seleção da reta com maior ângulo interno, que representa a

borda mais interna da faixa, conforme ilustrado na Figura 47. Tal efeito pode ser associado ao efeito de perspectiva inversa da imagem capturada pela câmera. Desse modo, o sistema prioriza o rastreamento das bordas mais próximas ao veículo.

**Figura 47 – Comparação entre os ângulos formados pela borda interna e externa da faixa.**



**Fonte: Autoria própria.**

Se, através da aplicação da transformada de Hough, não for possível extrair pontos válidos por  $n$  iterações o sistema deixa de exibir o rastreamento das faixas em todas as seções até a ocorrência de  $n$  iterações consecutivas com coordenadas válidas. Tal histerese é necessária para evitar períodos de funcionamento intermitente do sistema. O funcionamento do sistema também é interrompido quando o motorista muda de faixa intencionalmente, portanto o status da sinalização do veículo é monitorado a partir do barramento CAN (MOTOYAMA *et al.*, 2000).


Para as seções 2, 3 e 4 da imagem, o processo de seleção de coordenadas é semelhante, no entanto a etapa 3 é substituída por uma etapa de verificação da variação na orientação da reta em relação as coordenadas selecionadas na seção anterior. Caso a diferença entre o ângulo da mesma faixa na seção analisada e na seção antecedente seja superior ao limiar proposto, a coordenada em análise é invalidada.

No processo de verificação das coordenadas da seção 4 (superior) adiciona-se uma 5ª etapa, responsável pela ativação de um indicador quando nenhuma das coordenadas analisadas apresenta pontos válidos na iteração. A função do indicador é desativar a representação visual da faixa rastreada nesta seção da imagem, pois, pelo efeito de perspectiva da câmera, trata-se de uma região onde cada pixel

representa uma área maior na imagem em relação ao campo próximo, portanto um pequeno desvio da faixa rastreada em relação à faixa real na unidade de representação da imagem (número de pixels) pode representar um desvio considerável na unidade de medida do plano real (metros). Assim, torna-se preferível a desativação do rastreamento nessa região em detrimento da manutenção dos pontos da iteração anterior caso tais coordenadas não sejam válidas na iteração corrente.

O formato da resposta obtida nesse processo é exemplificado na Figura 48. As marcações representam as coordenadas  $(x, y)$  extraídas pelo algoritmo, para cada iteração são obtidos cinco pares de coordenadas  $(x, y)$  para cada faixa rastreada, os quais são armazenados em dois vetores linha no seguinte formato  $[x_1 \ y_1 \ x_2 \ y_2 \ \dots \ x_{10} \ y_{10}]$ .

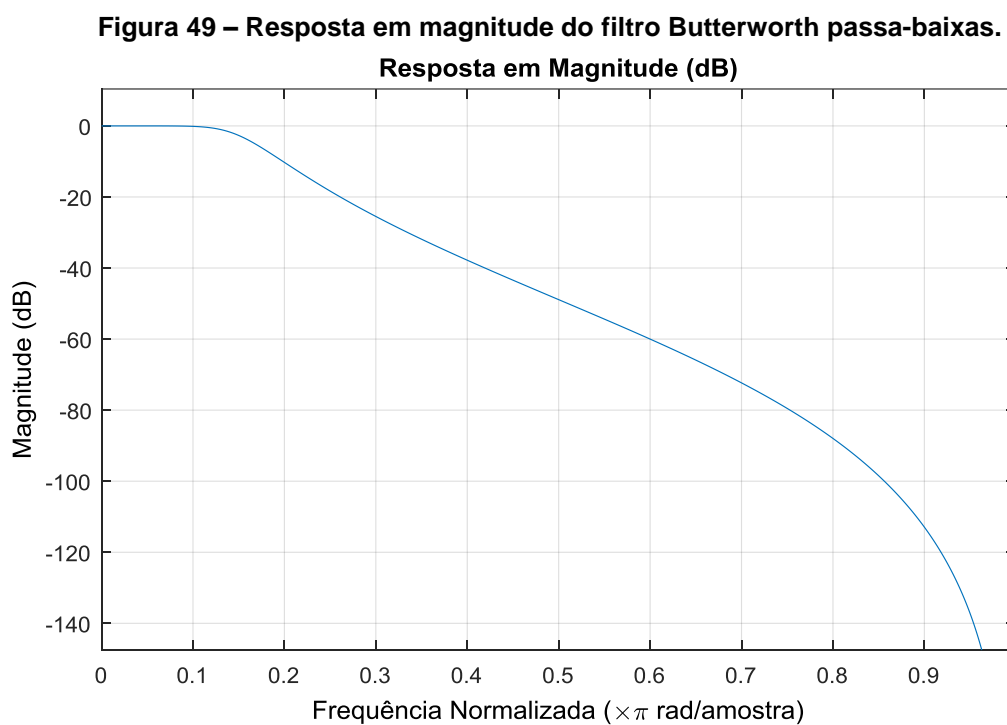
**Figura 48 – Exemplo da saída do processo de seleção de coordenadas.**



**Fonte: Autoria própria.**

De modo a suavizar a transição das coordenadas de rastreamento entre as iterações do algoritmo minimizando assim o efeito de ruídos ou falsas detecções de caráter transitório, implementou-se um filtro passa-baixas com auxílio da ferramenta *Digital Filter Design* do *Simulink*. O filtro digital de 4ª ordem foi projetado sobre o método IIR (*Infinite Impulse Response*) com frequência de corte normalizada em  $0.15 \pi$  rad/amostras.

A resposta em magnitude do filtro projetado pode ser analisada a partir do gráfico apresentado na Figura 49. Observa-se que o ganho na frequência de corte é de -3dB.



**Fonte: Autoria própria.**

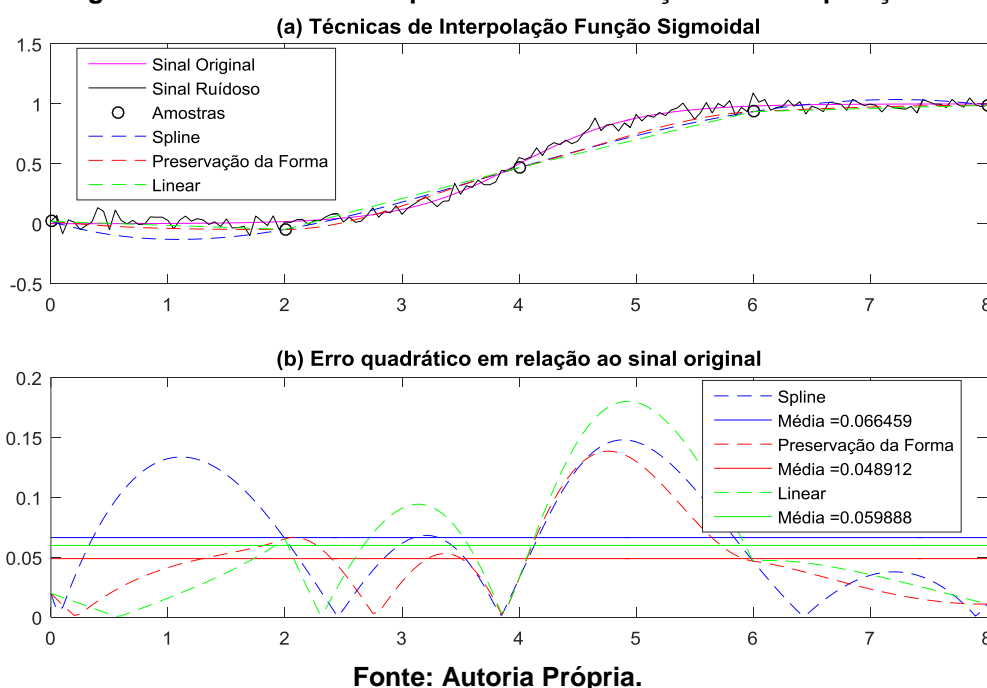
Logo após a filtragem, foi necessária a aplicação de uma função de interpolação entre os pontos selecionados (Figura 48) para o fornecimento da saída visual do resultado do algoritmo.

Pode-se definir interpolação como um método de ajuste de curvas que possibilita sua sobreposição a um conjunto de “pontos de controle”, que nesse trabalho são os pontos extraídos do processo de seleção de coordenadas. A interpolação é diferente da aproximação, pois na aproximação a curva não sobrepõe seus pontos de controle em todas as ocasiões (FLEET; HERTZMANN, 2005).

Para definir a técnica de interpolação adotada, foi realizada a análise das funções de interpolação linear, *spline* cúbica e a *spline* cúbica com preservação da forma, por meio da função *interp1* da ferramenta Matlab. A função sigmoideal foi utilizada como base durante as avaliações, pois apresenta comportamento similar ao observado nas faixas rodoviárias. Para simular as interferências que o processo está sujeito no ambiente de aplicação foi adicionado, sobre o sinal de amostra original,

um ruído branco gaussiano com relação sinal ruído de 25. Os resultados obtidos são ilustrados na Figura 50.

**Figura 50 – Análise do comportamento das funções de interpolação.**



Um conjunto de sinais é sobreposto em (a), o sinal sigmoide original, o sinal sigmoide ruído, cinco amostras coletadas sobre o sinal ruído e os resultados das funções de interpolação. As interpolações foram efetuadas a partir das cinco amostras utilizadas como pontos de controle, em (b) os valores instantâneos e as médias do erro quadrático médio do resultado da interpolação, em relação ao sinal original são ilustrados. O menor índice de erro e, portanto, o resultado mais satisfatório para esta análise foi obtido com a interpolação *spline* cúbica com preservação da forma.

Por consequência, a aplicação da técnica de interpolação por *spline* cúbica com preservação da forma resulta na saída apresentada na Figura 51 e completa o processo de rastreamento das faixas, proposta na etapa de processamento de alto-nível. Como esperado é possível notar que devido à etapa de seleção dos pontos, para esta amostra, o rastreamento ocorre sobre a borda interna das faixas. Assim, com a conclusão das etapas de processamento de nível baixo, médio e alto completa-se o desenvolvimento da estratégia de detecção e rastreamento de faixas proposta neste trabalho.

**Figura 51 – Saída do algoritmo em uma reta.**



**Fonte: Autoria própria.**

Os resultados obtidos a partir da aplicação da técnica proposta em diferentes cenários, assim como as discussões sobre o comportamento e os índices estatísticos de avaliação da estratégia são apresentados no próximo capítulo.



## 4 RESULTADOS E DISCUSSÕES

Esta seção do trabalho se inicia com a apresentação dos resultados e sua discussão de forma qualitativa a partir da análise dos quadros de vídeo apresentados. Tal análise contribui para a crítica e o entendimento dos motivos que levaram o algoritmo a apresentar o comportamento observado, a fim de expor as decisões acertadas e os pontos falhos da estratégia proposta.

### 4.1 ANÁLISE QUALITATIVA DOS RESULTADOS

O algoritmo foi desenvolvido para funcionar nos períodos diurno e noturno, como ilustra a Figura 52. Contudo, algumas situações podem comprometer a captura da imagem pela câmera, tais como, o ofuscamento causado pela incidência direta do sol, a reflexividade do asfalto, a visibilidade da marcação das faixas e a presença de obstáculos ou sujeira na pista.

**Figura 52 – Resposta do algoritmo nos períodos (a) diurno e (b) noturno.**



Fonte: Autoria própria.

Em condições ordinárias, o algoritmo apresenta resposta equivalente nos dois períodos, sendo que no período noturno e em pistas não duplicadas, a câmera

está sujeita a incidência direta da luminosidade emitida pelos faróis dos veículos que trafegam no sentido oposto. O cenário descrito pode ser observado na Figura 53.

**Figura 53 – Ofuscamento causado pelo farol do veículo em sentido oposto.**



**Fonte: Autoria própria.**

A captura da imagem (a) é afetada pelo ofuscamento e pela reflexão da luz no asfalto, como efeito o rastreamento da faixa apresenta um desvio de posição em relação a faixa real. O efeito sobre a captura é mais evidente em (b), pois a região destacada possui uma relação sinal-ruído muito menor que a faixa à direita. O desvio de posição é observado em razão da característica da etapa de verificação do algoritmo, que favorece a seleção das bordas mais internas.

Este caso destaca uma das limitações da estratégia proposta, que devido à instrumentação do veículo com apenas uma câmera, não possui redundância e, pelo mesmo motivo, não possui outras perspectivas de visão da pista. Uma possível solução para o problema seria a adição de câmeras adicionais no veículo, apontadas para as faixas, de modo que, mesmo com um alcance menor em profundidade, seja possível reduzir as interferências externas durante o rastreamento.

Na etapa de processamento de alto nível do capítulo anterior foi previsto uma etapa de verificação das coordenadas da quarta seção (seção superior) da ROI da imagem, onde a representação visual da faixa rastreada é desativada caso não sejam encontradas coordenadas válidas para os pontos. Observou-se essa

característica do algoritmo em funcionamento principalmente quando o pré-processamento não foi capaz de extrair as bordas na parte superior da ROI, que é o caso ilustrado pela Figura 54.

**Figura 54 – Desativação visual da seção superior da faixa rastreada.**



Fonte: Autoria própria.

Em (a), observa-se que a correta não detecção da parte superior das faixas é devida a segmentação na marcação da faixa à esquerda. Na faixa à direita, mesmo com a extração de bordas relativas a faixas antigas (devido às obras no trecho) manteve o rastreamento adequado, pois seguiu a borda mais interna. Em (b), a não detecção pode ser associada a redução do contraste entre a faixa amarela e o asfalto causada pela sombra. Em ambos os casos a faixa à direita do veículo foi rastreada em toda a extensão da região de interesse.


Outra característica implementada na seção de verificação foi a repetição das últimas coordenadas válidas na seção inferior por  $n$  iterações nos casos de não detecção de pontos nessa região. Isso possibilita o funcionamento adequado do algoritmo mesmo na presença de faixas simples segmentadas, pois, com a escolha adequada de  $n$ , a repetição das últimas coordenadas válidas entre as lacunas da faixa apresenta resultados satisfatórios.

Essa situação é representada no detalhe 1 da Figura 55, onde o rastreamento foi mantido mesmo com a presença de uma lacuna localizada na


primeira seção (seção inferior) da faixa esquerda. O detalhe 2 evidencia a filtragem baseada na orientação do gradiente da imagem, nesse cenário somente a faixa de delimitação é extraída pelo detector de bordas, pois a sinalização lateral é composta de faixas com direção diferente da faixa de delimitação.

**Figura 55 – Repetição das últimas coordenadas válidas.**

(a) Resposta do algoritmo



(b) Saída da etapa de detecção de bordas




**Fonte: Autoria própria.**

No algoritmo,  $n$  é uma variável de calibração que teve seu valor determinado experimentalmente. Deve-se cuidar a respeito da determinação inadequada de  $n$ , pois ela pode ocasionar no mau funcionamento do algoritmo. Quando o parâmetro é subdimensionado o rastreamento é prejudicado na ocorrência de pequenas perturbações. Se o parâmetro é sobre dimensionado, a confiabilidade do rastreamento das faixas pelo sistema diminui, pois existem variáveis que rapidamente podem mudar o cenário da rodovia, tornando inadequada a manutenção de uma coordenada definida em uma iteração muito atrasada.

Quanto à filtragem de ruídos, de modo geral, o detector de bordas apresenta um índice considerado satisfatório para a aplicação. Contudo, em amostras onde os ruídos e/ou imperfeições na imagem possuem direção semelhante às faixas, suas bordas podem ser extraídas na etapa de processamento de nível médio, e, por consequência, podem causar o rastreamento inadequado na etapa de processamento de alto nível.

A Figura 56 expõe um caso onde o rastreamento das faixas foi prejudicado pela detecção indevida das bordas relacionadas ao contraste no asfalto. Todavia, o desvio só foi notado porque o ruído afeta a parte interna das faixas, nos casos contrários, a etapa de verificação das coordenadas, por selecionar a borda mais interna, manteve o sistema em funcionamento de forma adequada.

**Figura 56 – Detecção de bordas relacionadas ao contraste do asfalto.**



**Fonte: Autoria própria.**

O problema da detecção das bordas referentes ao contraste do asfalto pode ser reduzido com o ajuste da limiarização no detector de bordas Canny. No entanto, esse ajuste pode prejudicar a detecção das bordas relativas às faixas fracas. As duas situações levantadas são causadas por problemas estruturais da rodovia, a detecção de faixas fracas foi priorizada, pois na maioria das vezes, o contraste é observado próximo a região da marcação das faixas (como nos casos de reforma de apenas uma via da pista).

Pela análise da Figura 57 pode-se realizar o levantamento dos efeitos causados pelo reflexo na resposta do algoritmo. Neste caso o fato da pista estar molhada propiciou a reflexão da luminosidade do sol, tornando mais difícil a identificação visual dos limites da via de condução.

**Figura 57 – Reflexo na pista causado pela chuva.**



Fonte: Autoria própria.

Em (a) e (b) observa-se que a reflexão prejudicou parcialmente a resposta do algoritmo para a faixa à esquerda, por este motivo a representação visual da seção superior esquerda foi desativada. Quanto à saída da etapa de detecção de bordas, pode-se notar que em (a) foram detectadas as bordas relativas às duas faixas, no entanto, somente a faixa direita é representada completamente e em (b) somente detectou-se bordas referentes a faixa à direita.

Continuando a análise sobre a Figura 57, percebe-se também que a exposição da câmera é um fator que deve ser considerado. Neste trabalho a câmera foi protegida contra a aspensão de partículas sólidas e líquidas por ser instalada na parte interna do veículo, ainda assim a captura pode ser prejudicada caso o volume da chuva seja muito alto ou caso surja uma sujeira no para-brisa que o limpador não seja capaz de remover.


Com a integração dos sinais do barramento do veículo foi possível identificar o sinal representativo do estado das lanternas de direção (setas). Assim, seguindo as recomendações para desenvolvimento de sistemas de auxílio ao condutor, é possível desativar o rastreamento das faixas quando detectada a intenção do motorista de deixar a faixa. Na Figura 58 identifica-se a situação descrita, quando a sinalização é ativada seu status é exibido a partir da 300ª linha da matriz da imagem, como mostra o detalhe 1.

**Figura 58 – Desativação do rastreamento devido a sinalização do motorista.**

(a) Resposta do algoritmo



(b) Saída da etapa de detecção de bordas



**Fonte: Autoria própria.**

A próxima seção trata da análise do desempenho do algoritmo de forma quantitativa, as métricas de avaliação se baseiam no desvio entre a faixa rastreada pela estratégia proposta e posição real da faixa.

## 4.2 ANÁLISE QUANTITATIVA DOS RESULTADOS

Os índices quantitativos para avaliação do desempenho da estratégia foram obtidos a partir da utilização de um *software* desenvolvido no GSA (Grupo de Sistemas Automotivos) da UTFPR-PG. A aplicação possui duas interfaces, uma interface de operação e uma de comparação.

Na interface de operação, o usuário importa a amostra de vídeo, realiza a marcação quadro a quadro da posição das faixas (*ground truth*) e realiza a classificação das faixas, quanto à cor (branca/amarela) e o tipo (contínua/segmentada e simples/dupla). A partir da utilização do *software* é possível a comparação de diferentes estratégias de identificação de faixas, as quais são avaliadas nos trechos onde o indicador de avaliação (botão *Evaluation Indicator*) está ativo. Os dados informados pelo usuário são armazenados em um arquivo XML (*eXtensive Markup Language*) para utilização posterior na interface de comparação.

A Figura 59 ilustra o processo de marcação de *ground truth*. Apesar da marcação das faixas e as classificações serem realizadas de quadro a quadro, é possível reutilizar as marcações/classificações do quadro atual no quadro posterior.

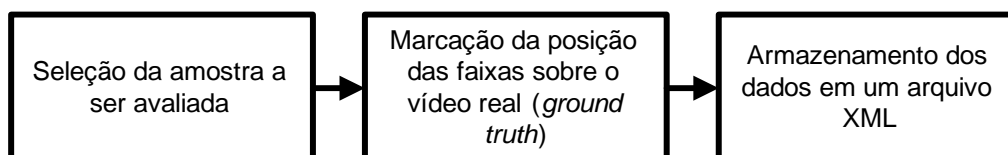
**Figura 59 – Processo de marcação de *ground truth*.**



**Fonte: Autoria própria.**

A sequência adotada, para este trabalho, na etapa de operação do *software* é apresentada na Figura 60. Nota-se que as etapas de classificação de cor e tipo da faixa e a indicação do trecho de falha não são utilizadas, pois a estratégia avaliada é limitada a tarefa de rastreamento das faixas da rodovia mais próximas ao veículo.

**Figura 60 – Etapa de operação do *software* de avaliação de desempenho.**



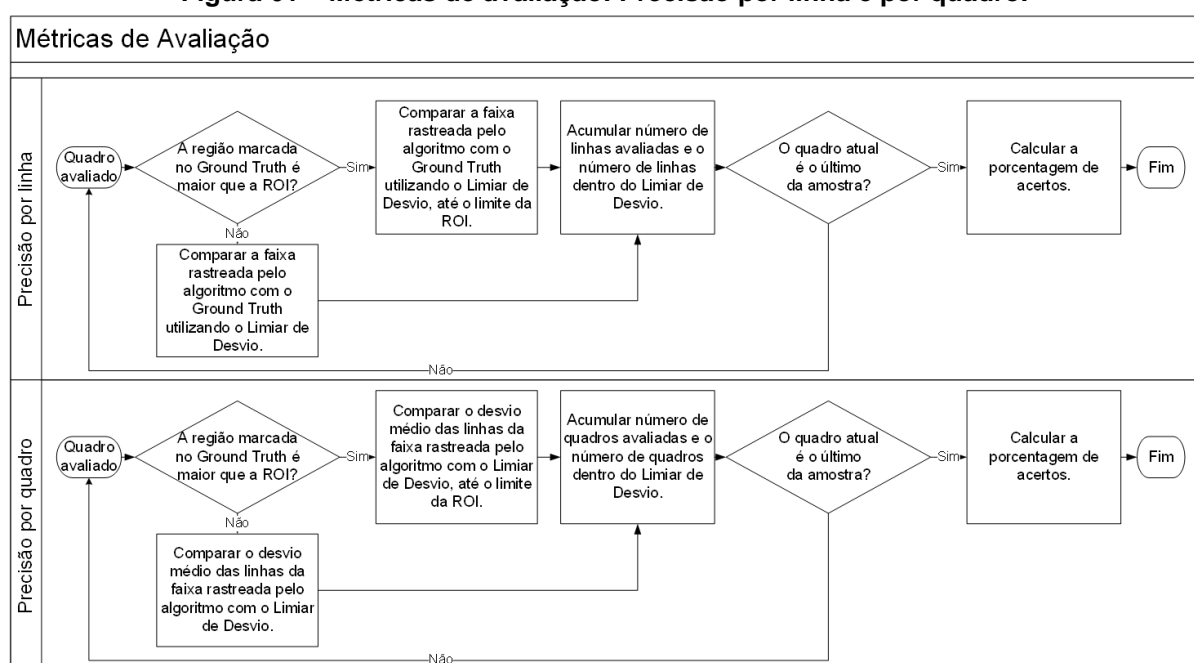
**Fonte: Autoria própria.**

Como o próprio nome indica, na interface de comparação, realiza-se a avaliação dos resultados a partir da comparação entre a marcação da posição exata das faixas e o resultado da saída da estratégia desenvolvida. Esta interface conta com dois parâmetros de calibração, o número de linhas da ROI e limiar de desvio, em número de pixels. O número de linhas da ROI delimita a região avaliada pelo software e o limiar de desvio é utilizado nas métricas de avaliação dos resultados.



Sobre as métricas para avaliação, são disponibilizados o desvio absoluto médio (DAM) em número de pixels, o desvio padrão (DP), a precisão por linha (PPL) e a precisão por quadro (PPQ). A precisão por linha representa a taxa de assertividade considerando a comparação individual do *ground truth* com o resultado do algoritmo em todas as linhas na região de interesse da amostra, conforme Figura 61, onde o número total de linhas é dado pela multiplicação do tamanho da ROI (em pixels) com o número de quadros. A precisão por quadro representa a taxa de assertividade obtida a partir da comparação do desvio absoluto médio da faixa com o limiar quadro a quadro.


**Figura 61 – Métricas de avaliação: Precisão por linha e por quadro.**



Fonte: Autoria própria.

Por conseguinte, o *software* foi utilizado para avaliar a eficiência da estratégia proposta e o efeito da variação da região de interesse e do limiar de desvio sobre a qualidade do rastreamento das faixas. O procedimento adotado pelo usuário na interface de comparação pode ser analisado na Figura 62.

**Figura 62 – Etapa de comparação do *software*.**



Fonte: Autoria própria.

A análise foi realizada sobre seis amostras segmentadas a partir da base de dados local do GSA, sobre os trechos do vídeo onde o indicador de avaliação estava acionado. O critério para seleção foi a diversidade dos cenários, que inclui o tipo de faixa, o período do dia e a presença de contraste, sombra ou ofuscamento na amostra. Os índices de assertividade foram obtidos com base na combinação dos parâmetros de ROI (100, 120, 140 e 150), para verificação do alcance do algoritmo, e limiar de desvio (10, 15 e 20), para verificação da exatidão do mesmo.

Na primeira amostra, observou-se, durante a maior parte dos 524 quadros do vídeo, a presença de faixas brancas, simples e contínuas, sendo que no final a faixa a direita torna-se segmentada. O trecho apresenta diferenças entre o contraste da pista onde o veículo trafega com a pista à sua direita, o efeito é observado devido às obras de restauração da pista.

Os índices de avaliação dos resultados obtidos, para a faixa à esquerda da primeira amostra, são apresentados na Tabela 4.

**Tabela 4 – Índices de avaliação da faixa à esquerda (Amostra 1).**

Parâmetros		Faixa à esquerda			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	3,7924	2,1779	98,55%	99,62%
100	15	3,7924	2,1779	99,98%	100,00%
100	20	3,7924	2,1779	100,00%	100,00%
120	10	3,6203	2,0478	98,76%	100,00%
120	15	3,6203	2,0478	99,93%	100,00%
120	20	3,6203	2,0478	99,95%	100,00%
140	10	3,4634	1,9242	98,88%	100,00%
140	15	3,4634	1,9242	99,89%	100,00%
140	20	3,4634	1,9242	99,90%	100,00%
150	10	3,3922	1,8515	98,93%	100,00%
150	15	3,3922	1,8515	99,87%	100,00%
150	20	3,3922	1,8515	99,89%	100,00%

**Fonte: Autoria própria.**

A taxa de precisão por quadro (PPQ) atingiu o índice máximo em todas as combinações de parâmetros, exceto com a ROI de 100 pixels e o limiar de desvio de 10 pixels. O menor desvio absoluto médio (DAM) em número de pixels foi registrado para a ROI de 150 pixels. A diferença entre o melhor e o pior índice da taxa de precisão por linha (PPL) foi inferior a 2%, sendo que na parametrização com a menor ROI e o maior limiar de desvio obteve-se 100% de precisão, portanto o valor do desvio permaneceu na faixa considerada aceitável por toda a amostra.

Os índices de avaliação dos resultados obtidos, para a faixa à direita da primeira amostra, são apresentados na Tabela 5.

**Tabela 5 – Índices de avaliação da faixa à direita (Amostra 1).**

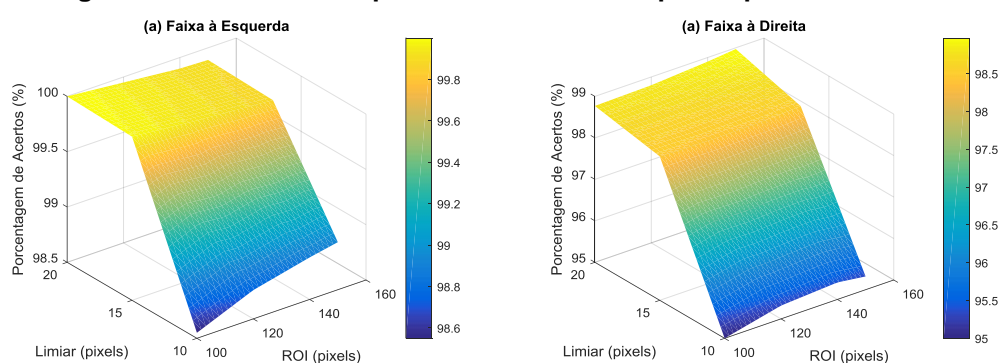
Parâmetros			Faixa à direita		
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	5,7365	3,6495	95,00%	93,87%
100	15	5,7365	3,6495	98,47%	98,47%
100	20	5,7365	3,6495	98,77%	98,85%
120	10	5,7708	3,4529	95,32%	94,64%
120	15	5,7708	3,4529	98,44%	98,47%
120	20	5,7708	3,4529	98,80%	98,85%
140	10	5,8617	3,2678	95,41%	94,25%
140	15	5,8617	3,2678	98,47%	98,47%
140	20	5,8617	3,2678	98,90%	98,85%
150	10	5,9291	3,1839	95,32%	94,25%
150	15	5,9291	3,1839	98,51%	98,47%
150	20	5,9291	3,1839	98,97%	98,85%

Fonte: Autoria própria.

Considerando o limiar de 20 pixels, a taxa de precisão por quadro permaneceu constante para as quatro regiões de interesse avaliadas. O desvio absoluto médio e seu respectivo desvio padrão são maiores em relação aos índices apresentados para a faixa à esquerda, pois foi observado que o contraste afetou o rastreamento da faixa por alguns períodos da amostra. Quanto à precisão por linha, os maiores índices foram obtidos com a região de interesse de 150 pixels, o que indica que as faixas foram rastreadas de forma mais precisa (quanto ao desvio em número de pixels) no campo distante da imagem.

Os índices PPL da primeira amostra são apresentados na forma de gráfico de superfície na Figura 63.

**Figura 63 – Gráfico de superfície do índice PPL para a primeira amostra.**



Fonte: Autoria própria.

A amostra 2 contém 824 quadros, sendo a faixa à esquerda amarela, dupla e segmentada durante a maior parte da amostra, e a faixa à direita, branca, simples e contínua. A região segmentada também possuía aclive e declive, durante o declive se tem visibilidade sobre uma distância maior da rodovia adiante, o aclive acentuado tem efeito contrário, pois diminui o alcance da área visível.

Os índices para avaliação da faixa à esquerda do veículo são apresentados na Tabela 6.

**Tabela 6 – Índices de avaliação da faixa à esquerda (Amostra 2).**

Parâmetros		Faixa à esquerda			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	11,2616	9,784	60,22%	58,62%
100	15	11,2616	9,784	69,57%	66,62%
100	20	11,2616	9,784	79,76%	76,53%
120	10	11,2345	9,7557	60,31%	58,75%
120	15	11,2345	9,7557	69,72%	66,76%
120	20	11,2345	9,7557	79,90%	76,53%
140	10	11,2345	9,7557	60,31%	58,75%
140	15	11,2345	9,7557	69,72%	66,76%
140	20	11,2345	9,7557	79,90%	76,53%
150	10	11,2359	9,7586	60,31%	58,75%
150	15	11,2359	9,7586	69,72%	66,76%
150	20	11,2359	9,7586	79,90%	76,53%

Fonte: Autoria própria.

Observa-se que as taxas de assertividade dadas pelos índices PPL e PPQ, são semelhantes para a análise com diferentes tamanhos da ROI. O desvio absoluto médio e seu desvio padrão são muito superiores aos apresentados na análise dos resultados da primeira amostra, tal comportamento foi atribuído ao tipo da faixa. Por se tratar de uma faixa dupla, com uma marcação contínua e uma segmentada, o rastreamento oscila entre as duas faixas. A oscilação para a faixa mais externa aumenta o desvio em relação a marcação do *ground truth*, o que, como consequência, ocasiona a redução dos índices PPL e PPQ.

De modo semelhante, analisa-se os índices de assertividade para a faixa à direita da segunda amostra por meio da Tabela 7. Neste caso, o rastreamento foi eficiente em todas as combinações de parâmetros testadas, obteve-se pelo menos 99% de precisão em ambos os índices, PPL e PPQ. O desvio absoluto médio entre a faixa verdadeira e a posição rastreada foi de cerca de 4 pixels, com desvio padrão de 1,9.

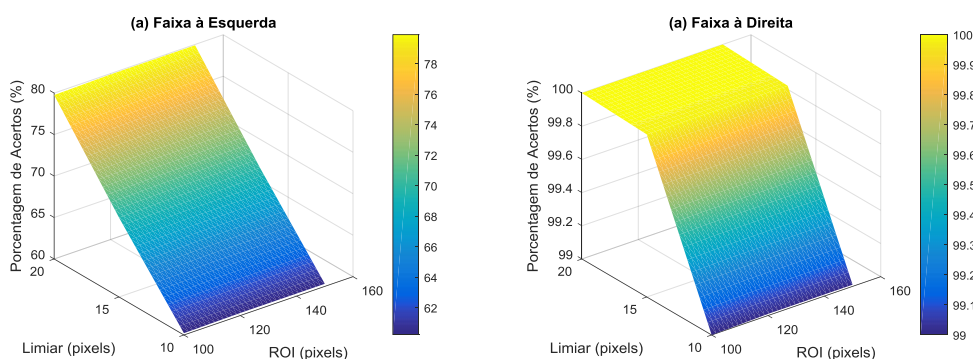
Tabela 7 – Índices de avaliação da faixa à direita (Amostra 2).

Parâmetros		Faixa à direita			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	4,2876	1,8759	99,00%	99,05%
100	15	4,2876	1,8759	99,98%	100,00%
100	20	4,2876	1,8759	100,00%	100,00%
120	10	4,2932	1,8717	99,01%	99,05%
120	15	4,2932	1,8717	99,98%	100,00%
120	20	4,2932	1,8717	100,00%	100,00%
140	10	4,2932	1,8717	99,01%	99,05%
140	15	4,2932	1,8717	99,98%	100,00%
140	20	4,2932	1,8717	100,00%	100,00%
150	10	4,2932	1,8717	99,01%	99,05%
150	15	4,2932	1,8717	99,98%	100,00%
150	20	4,2932	1,8717	100,00%	100,00%

Fonte: Autoria própria.

Os índices PPL da segunda amostra são apresentados na forma de gráfico de superfície na Figura 64. Nota-se que para a faixa à esquerda a assertividade apresenta uma relação de proporcionalidade com o limiar, isto pode representar uma limitação do algoritmo quanto à exatidão do rastreamento das faixas, pois é desejável que a estabilidade do indicador seja mantida com a diminuição do limiar de erro. Para a faixa à direita obteve-se precisão máxima com os limiares de 15 e 20 pixels (ou linhas da matriz da imagem).

Figura 64 – Gráfico de superfície do índice PPL para a segunda amostra.



Fonte: Autoria própria.

Cerca de 40% dos 688 frames da terceira amostra representam a passagem do veículo por uma curva à direita na rodovia. A faixa à esquerda é amarela, dupla e contínua e a faixa à direita é branca, simples e contínua. Identificou-se a presença de sombras, provenientes da vegetação local, que contribuem para a redução do contraste entre a marcação da pista e o asfalto.

A avaliação da faixa à esquerda é exposta na Tabela 8.

**Tabela 8 – Índices de avaliação da faixa à esquerda (Amostra 3).**

Parâmetros		Faixa à esquerda			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	3,8972	1,9669	98,73%	100,00%
100	15	3,8972	1,9669	100,00%	100,00%
100	20	3,8972	1,9669	100,00%	100,00%
120	10	3,9066	1,9574	98,74%	100,00%
120	15	3,9066	1,9574	100,00%	100,00%
120	20	3,9066	1,9574	100,00%	100,00%
140	10	3,9066	1,9574	98,74%	100,00%
140	15	3,9066	1,9574	100,00%	100,00%
140	20	3,9066	1,9574	100,00%	100,00%
150	10	3,9066	1,9574	98,74%	100,00%
150	15	3,9066	1,9574	100,00%	100,00%
150	20	3,9066	1,9574	100,00%	100,00%

Fonte: Autoria própria.

Para a faixa à esquerda, obteve-se o nível máximo de assertividade para o PPQ. O nível máximo de precisão para o índice PPL foi obtido com os limiares de 15 e 20 pixels, com o limiar de 10 pixels obteve-se precisão de cerca de 98,7%. Calculou-se um desvio absoluto médio de cerca de 4 pixels com desvio padrão 2.

A Tabela 9 apresenta os resultados obtidos para a faixa à direita.

**Tabela 9 – Índices de avaliação da faixa à direita (Amostra 3).**


Parâmetros		Faixa à direita			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	4,517	3,5915	92,91%	91,91%
100	15	4,517	3,5915	97,41%	97,06%
100	20	4,517	3,5915	99,56%	100,00%
120	10	4,5277	3,5861	92,90%	91,91%
120	15	4,5277	3,5861	97,43%	97,06%
120	20	4,5277	3,5861	99,56%	100,00%
140	10	4,5277	3,5861	92,90%	91,91%
140	15	4,5277	3,5861	97,43%	97,06%
140	20	4,5277	3,5861	99,56%	100,00%
150	10	4,5277	3,5861	92,90%	91,91%
150	15	4,5277	3,5861	97,43%	97,06%
150	20	4,5277	3,5861	99,56%	100,00%

Fonte: Autoria própria.

A repetição dos índices de assertividade para as duas faixas pode ser atribuída a limitação na marcação do *ground truth* quando a pista é sombreada. Fato que é acentuado pelo aumento da distância de cobertura devido ao declive da pista. Nesse caso o nível de representatividade de um pixel é muito maior em relação as linhas do campo próximo da imagem, o que pode causar distorção na imagem.

Os gráficos de superfície do índice PPL para as faixas à esquerda e à direita são exibidos na Figura 65. Nesse caso a modificação do parâmetro de delimitação da região de interesse não impactou a análise do desempenho do algoritmo. Para a faixa à direita, há uma variação do indicador em cerca de 7%, considerando a mudança do limiar de desvio de 20 para 10, contudo o rastreamento das faixas manteve acima de 90% de acerto.

**Figura 65 – Gráfico de superfície do índice PPL para a terceira amostra.**



**Fonte: Autoria própria.**

Na quarta amostra, a faixa à esquerda é branca, simples e contínua e a faixa à direita é branca, simples e segmentada. O trecho apresenta diferença de contraste entre a área de maior circulação de veículos e o restante da faixa. No total foram avaliados 420 quadros.

Os índices de avaliação da faixa à esquerda são apresentados na Tabela 10. Neste caso, os índices PPL e PPQ são os mesmos em todos os limites de região de interesse avaliados. Este tipo de ocorrência pode ser associado à característica do algoritmo de desativar o rastreamento no campo distante caso os pontos identificados não sejam validados na etapa de verificação ou a limitação da marcação do *ground truth* por algum fator externo. O desvio absoluto médio ficou em torno de 3,6 píxels com desvio padrão de 2,4.

**Tabela 10 – Índices de avaliação da faixa à esquerda (Amostra 4).**

Parâmetros		Faixa à esquerda			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	3,6338	2,4176	98,16%	97,44%
100	15	3,6338	2,4176	99,70%	100,00%
100	20	3,6338	2,4176	100,00%	100,00%
120	10	3,6311	2,4052	98,18%	97,44%
120	15	3,6311	2,4052	99,71%	100,00%
120	20	3,6311	2,4052	100,00%	100,00%
140	10	3,6311	2,4052	98,18%	97,44%
140	15	3,6311	2,4052	99,71%	100,00%
140	20	3,6311	2,4052	100,00%	100,00%
150	10	3,6311	2,4052	98,18%	97,44%
150	15	3,6311	2,4052	99,71%	100,00%
150	20	3,6311	2,4052	100,00%	100,00%

Fonte: Autoria própria.

Em complemento, os índices de avaliação da faixa a direita são apresentados na Tabela 11.

**Tabela 11 – Índices de avaliação da faixa à direita (Amostra 4).**

Parâmetros		Faixa à direita			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	6,7968	4,5431	83,24%	82,11%
100	15	6,7968	4,5431	93,78%	92,65%
100	20	6,7968	4,5431	98,10%	98,08%
120	10	6,7968	4,534	83,25%	82,11%
120	15	6,7968	4,534	93,79%	92,97%
120	20	6,7968	4,534	98,10%	98,08%
140	10	6,7968	4,534	83,25%	82,11%
140	15	6,7968	4,534	93,79%	92,97%
140	20	6,7968	4,534	98,10%	98,08%
150	10	6,7968	4,534	83,25%	82,11%
150	15	6,7968	4,534	93,79%	92,97%
150	20	6,7968	4,534	98,10%	98,08%

Fonte: Autoria própria.

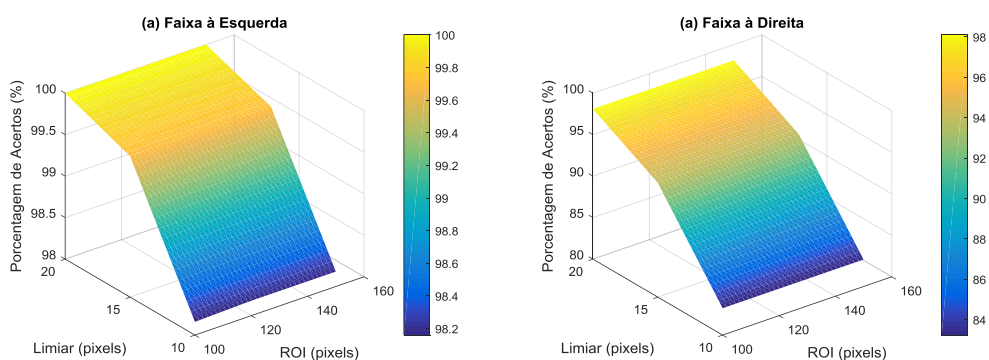
Pela análise dos índices PPQ e PPL, constata-se que o rastreamento é menos preciso em trechos com a marcação de faixa segmentada. Embora atinja taxa de 98% para o limiar de desvio de 20 pixels, essa taxa perde em torno de 15



pontos percentuais considerando o limiar de 10 pixels. Como consequência, o desvio absoluto médio é maior em relação a faixa à direita.

O gráfico de superfície do índice PPL para as faixas à esquerda e à direita da quarta amostra é apresentado na Figura 66. Para cada combinação de parâmetros, a taxa de acertos da faixa à esquerda foi superior à da faixa à direita.

**Figura 66 – Gráfico de superfície do índice PPL para a quarta amostra.**



**Fonte: Autoria própria.**

A quinta amostra foi segmentada no período noturno, com 709 quadros. A faixa à esquerda é branca, simples e segmentada e a faixa à direita é branca, simples e contínua. Nessa amostra, de forma particular, observou-se que o alcance da iluminação do farol baixo do veículo delimita a área marcação do *ground truth*.

Na Tabela 12 são disponibilizados os dados referentes à avaliação da faixa à esquerda do veículo.

**Tabela 12 – Índices de avaliação da faixa à esquerda (Amostra 5).**

Parâmetros		Faixa à esquerda			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	3,9556	2,3077	90,76%	97,01%
100	15	3,9556	2,3077	93,12%	100,00%
100	20	3,9556	2,3077	93,19%	100,00%
120	10	3,9549	2,301	90,77%	97,34%
120	15	3,9549	2,301	93,12%	100,00%
120	20	3,9549	2,301	93,19%	100,00%
140	10	3,9549	2,301	90,77%	97,34%
140	15	3,9549	2,301	93,12%	100,00%
140	20	3,9549	2,301	93,19%	100,00%
150	10	3,9549	2,301	90,77%	97,34%
150	15	3,9549	2,301	93,12%	100,00%
150	20	3,9549	2,301	93,19%	100,00%

**Fonte: Autoria própria,**

Para o limiar de 10 pixels a precisão por linha foi próxima a 91% e a precisão por quadro 97%, considerando os limiares de 15 e 20 pixels a precisão por linha sobe para 93% e a precisão por quadro atinge 100%. Em todos os casos o desvio absoluto médio foi de 3,9 pixels com desvio padrão de 2,3. Associou-se o aumento nos índices de precisão em relação a faixa direita da amostra 4 com as distâncias entre os segmentos da faixa, que são menores na amostra 5.

Os índices de avaliação para a faixa à direita são apresentados na Tabela 13.

**Tabela 13 – Índices de avaliação da faixa à direita (Amostra 5),**


Parâmetros		Faixa à direita			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	5,7603	2,3171	88,66%	93,69%
100	15	5,7603	2,3171	93,13%	100,00%
100	20	5,7603	2,3171	93,19%	100,00%
120	10	5,7636	2,3102	88,67%	93,69%
120	15	5,7636	2,3102	93,13%	100,00%
120	20	5,7636	2,3102	93,19%	100,00%
140	10	5,7636	2,3102	88,67%	93,69%
140	15	5,7636	2,3102	93,13%	100,00%
140	20	5,7636	2,3102	93,19%	100,00%
150	10	5,7636	2,3102	88,67%	93,69%
150	15	5,7636	2,3102	93,13%	100,00%
150	20	5,7636	2,3102	93,19%	100,00%

**Fonte: Autoria própria,**

Para o limiar de 10 pixels a precisão por linha foi próxima a 89% e a precisão por quadro 94%, considerando os limiares de 15 e 20 pixels a precisão por linha sobe para 93% e a precisão por quadro atinge 100%. Em todos os casos o desvio absoluto médio foi de 5,8 pixels com desvio padrão de 2,3.

Pela análise do gráfico de superfície da Figura 67 percebe-se a semelhança entre os índices de precisão do rastreamento das faixas à esquerda e à direita. Notou-se que a curta distância entre os segmentos da faixa não compromete o funcionamento do algoritmo, tanto quanto nos casos onde os segmentos são mais distantes.

**Figura 67 – Gráfico de superfície do índice PPL para a quinta amostra,**



**Fonte: Autoria própria,**

Na sexta amostra, a faixa à esquerda é amarela, dupla e contínua e a faixa à direita é branca, simples e segmentada. Na parte inicial do vídeo o veículo contorna uma curva para a esquerda, há partes do vídeo com marcação das faixas enfraquecidas, com ofuscamento da câmera e reflexo na pista causado pela luminosidade do farol dos veículos em sentido contrário. No total foram avaliados 690 quadros.

Os índices de avaliação para a faixa à esquerda são apresentados na Tabela 14. Nessa amostra a marcação do *ground truth*, tanto da faixa à esquerda, quanto da faixa à direita foi limitada pela presença de um veículo que trafegava adiante.

**Tabela 14 – Índices de avaliação da faixa à esquerda (Amostra 6).**

Parâmetros		Faixa à esquerda			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	7,5352	5,2723	78,65%	73,61%
100	15	7,5352	5,2723	91,60%	92,19%
100	20	7,5352	5,2723	96,82%	97,05%
120	10	7,5315	5,2645	78,70%	73,61%
120	15	7,5315	5,2645	91,64%	92,19%
120	20	7,5315	5,2645	96,83%	97,05%
140	10	7,5315	5,2645	78,70%	73,61%
140	15	7,5315	5,2645	91,64%	92,19%
140	20	7,5315	5,2645	96,83%	97,05%
150	10	7,5315	5,2645	78,70%	73,61%
150	15	7,5315	5,2645	91,64%	92,19%
150	20	7,5315	5,2645	96,83%	97,05%

**Fonte: Autoria própria.**

Para o limiar de 10 pixels obteve-se 78,7% de precisão no índice PPL e cerca de 73,6% no índice PPQ. Com o limiar de 15 pixels, obteve-se PPL de 91,6%

e PPQ de 92,2%. Finalmente, para o limiar de 20 pixels, obteve-se PPL de 96,8% e PPQ de 97%. O desvio absoluto médio concentrou-se na faixa de 7,5 pixels com desvio padrão de 5.

Os índices de avaliação da faixa à direita são apresentados na Tabela 15.

**Tabela 15 – Índices de avaliação da faixa à direita (Amostra 6).**

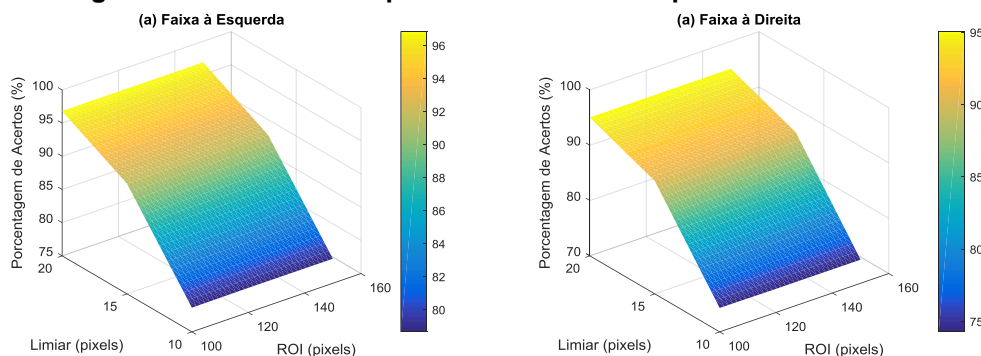
Parâmetros		Faixa à direita			
ROI [pixels]	Limiar [pixels]	DAM [pixels]	DP [pixels]	PPL [%]	PPQ [%]
100	10	9,4085	10,2765	74,33%	71,88%
100	15	9,4085	10,2765	90,42%	88,72%
100	20	9,4085	10,2765	95,02%	94,62%
120	10	9,4232	10,2749	74,27%	71,18%
120	15	9,4232	10,2749	90,43%	88,72%
120	20	9,4232	10,2749	95,04%	94,44%
140	10	9,4232	10,2749	74,27%	71,18%
140	15	9,4232	10,2749	90,43%	88,72%
140	20	9,4232	10,2749	95,04%	94,44%
150	10	9,4232	10,2749	74,27%	71,18%
150	15	9,4232	10,2749	90,43%	88,72%
150	20	9,4232	10,2749	95,04%	94,44%

Fonte: Autoria própria.

Para o limiar de 10 pixels obteve-se 74,3% de precisão no índice PPL e cerca de 71,2% no índice PPQ. Com o limiar de 15 pixels, obteve-se PPL de 90,4% e PPQ de 88,7%. Finalmente, para o limiar de 20 pixels, obteve-se PPL de 95% e PPQ de 94%. O desvio absoluto médio concentrou-se na faixa de 9,4 pixels com desvio padrão de 10,3.

O gráfico de superfície do índice PPL é apresentado na Figura 68.

**Figura 68 – Gráfico de superfície do índice PPL para a sexta amostra.**



Fonte: Autoria própria.

Pela análise dos resultados apresentados, nota-se que a precisão do rastreamento das faixas foi afetada pelas condições do ambiente de coleta da amostra. Houve uma variação em torno de 20 pontos percentuais entre a avaliação considerando o limiar de 20 pixels e a avaliação considerando 10 pixels.

As considerações finais decorrentes do desenvolvimento deste trabalho bem como as propostas para sua continuidade são apresentadas no capítulo seguinte.

## 5 CONCLUSÃO

O desenvolvimento deste trabalho foi dividido em três etapas de processamento, o processamento de baixo nível, médio e alto. As imagens da base de dados foram coletadas a partir de uma câmera monocular instalada na parte central do para-brisa do veículo. Também foram utilizados dados coletados do barramento CAN de comunicação serial do veículo.

Utilizando o algoritmo de mapeamento em perspectiva inversa determinou-se o alcance em metros do rastreamento considerando a alteração da região de interesse. Com a menor ROI (100 linhas) obteve-se alcance de 10,4m, já com a maior (150 linhas) obteve-se cerca de 34,5m de cobertura. Considerando o tempo médio de reação para frenagem apresentado no trabalho de Consiglio *et al.* (2003) e as recomendações previstas no CTB, a ROI mínima para evitar a colisão com um obstáculo estático a frente do veículo antes do tempo de reação do condutor seria de 120 linhas, que tem cobertura de cerca de 14,4m.

A estratégia adotada na etapa de processamento de nível médio delimitou o formato de interesse das características extraídas pelo algoritmo detector de bordas de Canny, aumentando assim a relação sinal ruído da imagem de entrada na etapa de rastreamento das faixas. Como, na perspectiva da câmera, a orientação das faixas se enquadram em um intervalo previsível de ângulos, aplicou-se a etapa de filtragem baseada na orientação do gradiente da imagem. A velocidade lateral do veículo foi utilizada como parâmetro de entrada no algoritmo para efetuar a correção da orientação do filtro. As técnicas de morfologia matemática, dilatação e análise dos componentes conectados, foram aplicadas em cascata para reduzir os ruídos remanescentes.

No processamento de alto nível a ROI foi dividida em 4 seções para melhor ajuste do rastreamento do algoritmo nas curvas. Para cada seção há quatro pares de coordenada para a faixa à esquerda e outros quatro pares para a faixa à direita, que passa por uma etapa de seleção onde a faixa interna da pista é priorizada sobre as demais e as coordenadas inválidas descartadas. A função de interpolação por *spline* cúbica foi escolhida para representar o agrupamento das seções em detrimento da interpolação linear e da *spline*, pois em uma análise da reconstrução de um sinal sigmoidal a partir de 5 amostras apresentou o menor desvio médio

quadrático em relação ao sinal original. O sinal sigmoidal foi escolhido por apresentar comportamento similar ao observado nas rodovias.

A partir da análise quantitativa dos resultados do algoritmo foi possível detectar os cenários onde o rastreamento do algoritmo é mais assertivo, assim como os padrões de rodovia ou condições ambientais onde o rastreamento é mais instável. Observou-se que a visibilidade das faixas pode ser comprometida por vários fatores, tais como, a refletividade da pista, o ofuscamento da câmera, a presença de sombras e a deterioração da pintura das mesmas.

É pertinente tomar nota que além da deterioração da pintura das faixas, há outros problemas estruturais que comprometem o funcionamento da estratégia proposta e também de outros DAS. Tais problemas foram observados a partir da análise das amostras contidas na base de dados do GSA, onde se encontram cenários com a presença de contraste na pista devido ao recapeamento do asfalto, a não conformidade com os padrões para pintura e largura das faixas e a ausência de marcações. O problema pode ser diminuído com o aumento da fiscalização sobre as condições da rodovia e até mesmo pela imposição de normas de conservação, que cumpridas, certamente tornaria a tarefa de rastreamento das faixas menos arduosa.

A análise qualitativa dos resultados foi possibilitada pela utilização de um *software* desenvolvido para comparar a posição real da faixa e posição rastreada pelo algoritmo. Os indicadores da qualidade do rastreamento são o desvio absoluto médio em relação à faixa real, as taxas de precisão por linha e por quadro do algoritmo. Foram avaliadas 6 amostras de vídeo em cenários diversificados, com as regiões de interesse de 100, 120, 140 e 150 pixels e os limiares de desvio de 10, 15 e 20 pixels.

Os maiores índices de assertividade foram observados em pistas com faixas contínuas, sejam elas brancas ou amarelas, onde as taxas de PPL e PPQ foram sempre superiores a 88% e a 93%, com exceção da amostra 6. Nesta amostra as marcações de faixa enfraquecidas e o ofuscamento da câmera causado pela luminosidade do farol dos veículos em sentido contrário prejudicaram o rastreamento, considerando o limiar de 10 pixels obteve-se a taxa de PPL de 78,65% e PPQ de 73,61%, entretanto com o limiar de 20 pixels obteve-se a taxa de PPL de 96,83% e PPQ de 97,05%.

O pior desempenho foi observado na faixa à esquerda da amostra 2, que é dupla com a faixa interna segmentada. Devido à flutuação do rastreamento entre a

parte interna e externa da faixa este cenário apresentou o maior desvio absoluto médio dentre as amostras avaliadas, cerca de 11,3 pixels com desvio padrão de 9,8. A taxa de PPL variou de 60,22% a 79,9% de acordo com o limiar e a ROI avaliados, já a PPQ foi de 58,62% a 76,53%. Esses índices são inferiores aos apresentados pelas amostras com faixa simples e segmentada.

Na amostra 3, a faixa à direita foi afetada pela presença de sombra. Com o limiar de 10 pixels a PPL foi de cerca de 93% e a PPQ cerca de 92%, contudo esses índices chegam a 99,5% e 100% considerando o limiar de 20 pixels. Portanto, a presença de sombras na pista pode influenciar na precisão do rastreamento, contudo a resposta se mantém confiável.

Considerando os resultados obtidos, os trabalhos futuros podem contribuir com a aplicação das seguintes propostas:

- Comparar os resultados deste trabalho com outras estratégias semelhantes;
- Realizar o ajuste-fino dos parâmetros calibráveis do algoritmo baseado no *feedback* dos índices obtidos a partir da aplicação do *software* de avaliação;
- Estender a pesquisa sobre as técnicas de processamento de nível baixo e médio, de modo a minimizar os problemas encontrados devido às condições ambientais (reflexo, ofuscamento, sombra e etc,...);
- Aumentar a robustez do algoritmo em cenários de faixa segmentada, a partir de melhorias na etapa de processamento de alto nível;
- Identificar novas etapas de verificação relevantes para a etapa de processamento de alto nível;
- Verificar o desempenho de técnicas baseadas em aprendizado de máquina para realização do rastreamento das faixas;
- Incrementar a instrumentação do veículo, com a incorporação de novos sensores, tais como lidar, radar (*radio detection and ranging*), câmeras laterais e filtros na lente da câmera para evitar a saturação das imagens e possibilitar o desenvolvimento de novas funções de auxílio ao condutor;
- Implementar as funções de auxílio ao condutor LDW e LKA com base na saída do algoritmo de rastreamento de faixas.



## REFERÊNCIAS

- ANDRADE, A. O. **Sistema de contagem com morfologia matemática fuzzy**. Natal: Universidade Federal do Rio Grande do Norte, 2014.
- BALLABENI, A. *et al.* Advances in image pre-processing to improve automated 3D reconstruction. **The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, 2015. v. 40, n. 5, p. 315.
- BENGLER, K. *et al.* Three decades of driver assistance systems: Review and future perspectives. **IEEE Intelligent Transportation Systems Magazine**, 2014. v. 6, n. 4, p. 6–22.
- BERTOZZI, M. *et al.* Artificial vision in road vehicles. **Proceedings of the IEEE**, 2002. v. 90, n. 7, p. 1258–1271.
- BORKAR, A.; HAYES, M.; SMITH, M. T. A novel lane detection system with efficient ground truth generation. **IEEE Transactions on Intelligent Transportation Systems**, 2012. v. 13, n. 1, p. 365–374.
- BOVIK, A. (Org.). **The essential guide to image processing**. 2. ed ed. Amsterdam: Academic Pr, 2009.
- BRASIL. **Código de Trânsito Brasileiro**. 5. ed. Brasília: Câmara dos Deputados: Edições Câmara, 2013.
- CANNY, J. A computational approach to edge detection. **IEEE Transactions on pattern analysis and machine intelligence**, 1986. n. 6, p. 679–698.
- CONSIGLIO, W. *et al.* Effect of cellular telephone conversations and other potential interference on reaction time in a braking response. **Accident Analysis & Prevention**, 2003. v. 35, n. 4, p. 495–500.
- DOUGHERTY, E. R.; LOTUFO, R. A. **Hands-on morphological image processing**. Bellingham, Wash: SPIE Press, 2003.
- DUDEK, G.; JENKIN, M. **Computational principles of mobile robotics**. 2nd ed ed. New York: Cambridge University Press, 2010.
- ECKERT, A.; HOHM, A.; LUEKE, S. An integrated ADAS solution for pedestrian collision avoidance. *In*: PROCEEDINGS OF THE 23RD INTERNATIONAL CONFERENCE ON THE ENHANCED SAFETY OF VEHICLES, SEOUL, REPUBLIC OF KOREA, 2013, , [s.l.] . **Anais...** [S.l.]: [s.n.], 2013. p. 13-0298.
- EURO NCAP. **Application of Star Rating**. Disponível em: <<http://euroncap.blob.core.windows.net/media/22732/euro-ncap-application-of-star-ratings-v13.pdf>>. Acesso em: 7 nov. 2016.
- FHWA. Roadway Departure Safety. [S.l.], 26 ago. 2016. Disponível em: <[http://safety.fhwa.dot.gov/roadway\\_dept/](http://safety.fhwa.dot.gov/roadway_dept/)>. Acesso em: 7 nov. 2016.

FILHO, O. M.; NETO, H. V. **Processamento digital de imagens**. Rio de Janeiro (RJ): BRASPORT, 1999.

FLEET, D.; HERTZMANN, A. **Computer Graphics Lecture Notes**. Disponível em: <<https://www.dgp.toronto.edu/~hertzman/418notes.pdf>>. Acesso em: 5 jan. 2017.

FOLTZ, M. A. Connected Components in Binary Images. **Massachusetts Institute of Technology**, 1997.

FREEMAN, W. T.; ADELSON, E. H. The design and use of steerable filters. **IEEE Transactions on Pattern analysis and machine intelligence**, 1991. v. 13, n. 9, p. 891–906.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 3. ed ed. Upper Saddle River, NJ: Pearson/Prentice Hall, 2008.

HAAN, G. D.; BELLERS, E. B. Deinterlacing-an overview. **Proceedings of the IEEE**, set. 1998. v. 86, n. 9, p. 1839–1857.

HAN, J. *et al.* Enhanced Road Boundary and Obstacle Detection Using a Downward-Looking LIDAR Sensor. **IEEE Transactions on Vehicular Technology**, mar. 2012. v. 61, n. 3, p. 971–985.

HILLEL, A. B. *et al.* Recent progress in road and lane detection: a survey. **Machine vision and applications**, 2014. v. 25, n. 3, p. 727–745.

HOLDEN, M. E. **Achieving sustainable mobility: everyday and leisure-time travel in the EU**. [S.l.]: Ashgate Publishing, Ltd., 2012.

HOUGH, P. V. Method and means for recognizing complex patterns. U.S. Patent n. 3,069,654, 18 dez. 1962.

HUGHES, C. *et al.* Wide-angle camera technology for automotive applications: a review. **IET Intelligent Transport Systems**, 2009. v. 3, n. 1, p. 19–31.

ILLINGWORTH, J.; KITTLER, J. A survey of the Hough transform. **Computer vision, graphics, and image processing**, 1988. v. 44, n. 1, p. 87–116.

JEONG, J.; KIM, A. Adaptive Inverse Perspective Mapping for lane map generation with SLAM. *In*: UBIQUITOUS ROBOTS AND AMBIENT INTELLIGENCE (URAI), 2016 13TH INTERNATIONAL CONFERENCE ON, 2016, , [s.l.] . **Anais...** [S.l.]: IEEE, 2016. p. 38–41.

JOHNSON, E.; HAMBURGER, R. Computer Vision Class Project. **University of Utah**, [S.l.], 2007. Disponível em: <<http://www.eng.utah.edu/~hamburge/>>. Acesso em: 17 mar. 2017.

JUNG, C. R.; KELBER, C. R. A lane departure warning system based on a linear-parabolic lane model. *In*: 2004 IEEE INTELLIGENT VEHICLES SYMPOSIUM, 2004, , [s.l.] . **Anais...** [S.l.]: [s.n.], 2004. p. 891–895.

JUNG, Claudio Rosito; KELBER, Christian Roberto. A lane departure warning system using lateral offset with uncalibrated camera. *In: PROCEEDINGS. 2005 IEEE INTELLIGENT TRANSPORTATION SYSTEMS, 2005.*, 2005, , [s.l.] . **Anais...** [S.l.]: IEEE, 2005. p. 102–107.

JUNG, S.; YOUN, J.; SULL, S. Efficient Lane Detection Based on Spatiotemporal Images. **IEEE Transactions on Intelligent Transportation Systems**, jan. 2016. v. 17, n. 1, p. 289–295.

LI, Q. *et al.* A sensor-fusion drivable-region and lane-detection system for autonomous vehicle navigation in challenging road scenarios. **IEEE Transactions on Vehicular Technology**, 2014. v. 63, n. 2, p. 540–555.

LI, X. *et al.* Lane detection and tracking using a parallel-snake approach. **Journal of Intelligent & Robotic Systems**, 2015. v. 77, n. 3–4, p. 597–609.

LOGITECH. **The H.264 Advanced Video Coding (AVC) Standard**. Disponível em: <<http://www.logitech.com/assets/45120/logitechh.pdf>>. Acesso em: 25 nov. 2016.

MATHWORKS. Correct Nonuniform Background Illumination and Analyze Foreground Objects. [S.l.], 2016a. Disponível em: <<https://www.mathworks.com/help/images/image-enhancement-and-analysis.html>>. Acesso em: 17 mar. 2017.

MATHWORKS. rgb2gray. [S.l.], 2016b. Disponível em: <<https://www.mathworks.com/help/matlab/ref/rgb2gray.html>>. Acesso em: 17 mar. 2017.

MATHWORKS. Deinterlacing. [S.l.], 2016c. Disponível em: <<https://www.mathworks.com/help/vision/ref/deinterlacing.html?requestedDomain=www.mathworks.com>>. Acesso em: 29 nov. 2016.

MCCALL, J. C.; TRIVEDI, Mohan M. An integrated, robust approach to lane marking detection and lane tracking. *In: INTELLIGENT VEHICLES SYMPOSIUM, 2004 IEEE, 2004*, , [s.l.] . **Anais...** [S.l.]: IEEE, 2004. p. 533–537.

\_\_\_\_\_; \_\_\_\_\_. Video-based lane estimation and tracking for driver assistance: survey, system, and evaluation. **IEEE transactions on intelligent transportation systems**, 2006. v. 7, n. 1, p. 20–37.

MOTOYAMA, S. *et al.* Development of lane departure warning system. *In: 7TH ITS WORLD CONGRESS, 2000*, , [s.l.] . **Anais...** [S.l.]: [s.n.], 2000.

NATIONAL SAFETY COUNCIL. Car Safety Features. **My Car Does What**, [S.l.], 2017. Disponível em: <<https://mycardoeswhat.org/safety-features/>>. Acesso em: 28 fev. 2017.

NAYLOR, N. NHTSA announces final rule requiring rear visibility technology. 2014.

NEDEVSCHI, S. *et al.* High accuracy stereo vision system for far distance obstacle detection. *In: IEEE INTELLIGENT VEHICLES SYMPOSIUM, 2004*, , [s.l.] . **Anais...** [S.l.]: [s.n.], 2004. p. 292–297.

NHTSA. Critical Reasons for Crashes Investigated in National Motor Vehicle Crash Causation Survey. fev. 2015. Traffic Safety Facts. p. 2.

NIXON, M. S.; AGUADO, A. S. **Feature extraction and image processing**. 1. ed., reprinted ed. Oxford: Newnes, 2006.

OTSU, N. A threshold selection method from gray-level histograms. **Automatica**, 1975. v. 11, n. 285–296, p. 23–27.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais princípios, algoritmos e aplicações**. São Paulo: Thomson Learning, 2008.

PREMEBIDA, C.; NUNES, U. Fusing LIDAR, camera and semantic information: A context-based approach for pedestrian detection. **The International Journal of Robotics Research**, 1 mar. 2013. v. 32, n. 3, p. 371–384.

PREWITT, J. M. Object enhancement and extraction. **Picture processing and Psychopictorics**, 1970. v. 10, n. 1, p. 15–19.

PRF. Acidentes agrupados por ocorrência. **Polícia Rodoviária Federal**, [S.l.], 2016. Disponível em: <<https://www.prf.gov.br/portal/dados-abertos/acidentes>>. Acesso em: 25 abr. 2017.

ROBERTS, L. G. **Machine perception of three-dimensional solids**. Massachusetts: MIT, 1963.

SCHRANK, D.; EISELE, B.; LOMAX, T. TTI's 2012 urban mobility report. **Texas A&M Transportation Institute. The Texas A&M University System**, 2012.

SCURI, A. E. Fundamentos da imagem digital. **Pontifícia Universidade Católica do Rio de Janeiro**, 1999.

SHIN, B.-S.; XU, Z.; KLETTE, R. Visual lane analysis and higher-order tasks: a concise review. **Machine Vision and Applications**, ago. 2014. v. 25, n. 6, p. 1519–1547.

SHIN, S.; SHIM, I.; KWEON, I. S. Combinatorial approach for lane detection using image and LIDAR reflectance. *In*: UBIQUITOUS ROBOTS AND AMBIENT INTELLIGENCE (URAI), 2015 12TH INTERNATIONAL CONFERENCE ON, 2015, , [s.l.] . **Anais...** [S.l.]: IEEE, 2015. p. 485–487.

SHUNGUANG WU *et al.* Collision Sensing by Stereo Vision and Radar Sensor Fusion. **IEEE Transactions on Intelligent Transportation Systems**, dez. 2009. v. 10, n. 4, p. 606–614.

SILVA, R. A. *et al.* On the Applicability of Inverse Perspective Mapping for the Forward Distance Estimation Based on the HSV Colormat. **IEEE International Conference on Industrial Technology**, 2017. p. 1036–1041.

SIVARAMAN, S.; TRIVEDI, Mohan Manubhai. Integrated lane and vehicle detection, localization, and tracking: A synergistic approach. **IEEE Transactions on Intelligent Transportation Systems**, 2013. v. 14, n. 2, p. 906–917.

SKODA. Octavia Assistants Phase 2. **skoda-auto.com**, [S.I.], 2017. Disponível em: <<http://www.skoda-auto.com/sites/lv-lv/models/new-octavia/octavia-assistants-phase-2>>. Acesso em: 29 abr. 2017.

SOBEL, I.; FELDMAN, G. A 3x3 isotropic gradient operator for image processing. **a talk at the Stanford Artificial Project in**, 1968. p. 271–272.

SOLOMON, C.; BRECKON, T. **Fundamentals of digital image processing: a practical approach with examples in Matlab**. Chichester, West Sussex; Hoboken, NJ: Wiley-Blackwell, 2011.

SONKA, M.; HLAVAC, V.; BOYLE, R. **Image processing, analysis, and machine vision**. [S.I.]: Cengage Learning, 2014.

STEIN, G. P.; MANO, O.; SHASHUA, A. Vision-based ACC with a single camera: bounds on range and range rate accuracy. *In*: INTELLIGENT VEHICLES SYMPOSIUM, 2003. PROCEEDINGS. IEEE, 2003, , [s.l.] . **Anais...** [S.I.]: IEEE, 2003. p. 120–125.

SUN, Z.; BEBIS, G.; MILLER, R. On-road vehicle detection using optical sensors: a review. [S.I.]: IEEE, 2004. p. 585–590. Disponível em: <<http://ieeexplore.ieee.org/document/1398966/>>. Acesso em: 8 nov. 2016.

UMBAUGH, S. E. **Digital image processing and analysis: human and computer vision applications with CVIPtools**. Boca Raton: Taylor & Francis, 2010.

VOLVO TRUCKS. European Accident Research and Safety Report. [S.I.], 2013. Disponível em: <[http://www.volvotrucks.com/SiteCollectionDocuments/VTC/Corporate/Values/ART%20Report%202013\\_150dpi.pdf](http://www.volvotrucks.com/SiteCollectionDocuments/VTC/Corporate/Values/ART%20Report%202013_150dpi.pdf)>. Acesso em: 6 nov. 2016.

WANG, Y.; TEOH, E. K.; SHEN, D. Lane detection and tracking using B-Snake. **Image and Vision computing**, 2004. v. 22, n. 4, p. 269–280.

WHO. Global status report on road safety. **World Health Organization**, [S.I.], 2015. Disponível em: <[http://www.who.int/violence\\_injury\\_prevention/road\\_traffic/en/](http://www.who.int/violence_injury_prevention/road_traffic/en/)>. Acesso em: 17 mar. 2017.

WOODMAN, O. J. An introduction to inertial navigation. **University of Cambridge, Computer Laboratory, Tech. Rep. UCAMCL-TR-696**, 2007. v. 14, p. 15.

WÜRGES, M. New Electrical Power Steering Systems. *In*: CROLLA, D. *et al.* (Org.). **Encyclopedia of Automotive Engineering**. Chichester, UK: John Wiley & Sons, Ltd, 2013, p. 1–17.

YING, Z.; LI, G. Robust lane marking detection using boundary-based inverse perspective mapping. [S.I.]: IEEE, 2016. p. 1921–1925. Disponível em: <<http://ieeexplore.ieee.org/document/7472011/>>. Acesso em: 15 nov. 2016.

ZHOU, H.; WU, J.; ZHANG, J. **Digital Image Processing: Part II**. [S.I.]: Bookboon, 2010.