

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE ENGENHARIA ELETRÔNICA
BACHARELADO EM ENGENHARIA ELETRÔNICA**

FELIPE REZENDE FRANCO

**ESTRATÉGIA PARA FUNÇÃO DE DETECÇÃO E
RECONHECIMENTO DE FAIXAS EM RODOVIAS COM APLICAÇÃO
A SISTEMAS DE ASSISTÊNCIA AO CONDUTOR**

TRABALHO DE CONCLUSÃO DE CURSO

PONTA GROSSA

2017

FELIPE REZENDE FRANCO

**ESTRATÉGIA PARA FUNÇÃO DE DETECÇÃO E
RECONHECIMENTO DE FAIXAS EM RODOVIAS COM APLICAÇÃO
A SISTEMAS DE ASSISTÊNCIA AO CONDUTOR**

Trabalho de Conclusão de Curso apresentado como requisito parcial à obtenção do título de Bacharel em Engenharia Eletrônica, do Departamento de Engenharia Eletrônica da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Max Mauro Dias Santos – UTFPR - PG

Coorientador: Me. Eng. João Henrique Zander Neme - Multicorpos

PONTA GROSSA

2017



TERMO DE APROVAÇÃO

ESTRATÉGIA PARA FUNÇÃO DE DETECÇÃO E RECONHECIMENTO DE FAIXAS EM RODOVIAS COM APLICAÇÃO A SISTEMAS DE ASSISTÊNCIA AO CONDUTOR

por

FELIPE REZENDE FRANCO

Este Trabalho de Conclusão de Curso (TCC) foi apresentado em 01 de novembro de 2017 como requisito parcial para a obtenção do título de Bacharel em Engenharia Eletrônica. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

MAX MAURO DIAS SANTOS
Prof. Orientador

JOÃO HENRIQUE ZANDER NEME
Coorientador

ANGELO MARCELO TUSSET
Membro titular

FREDERIC CONRAD JANZEN
Membro titular

AGRADECIMENTOS

Aos meus pais, pelo amor, instrução, paciência, e que sempre me apoiaram na realização de meus objetivos.

Ao professor Max Mauro Dias Santos pelo suporte e ensinamentos.

Ao João Henrique Zander Neme pelo suporte, opiniões e companheirismo.

A todos do Grupo de Sistemas Automotivos pelo auxílio e por suportarem minhas boas piadas.

A todos os que por algum motivo contribuíram em minha caminhada acadêmica.

RESUMO

FRANCO, Felipe Rezende. Estratégia para Função de Detecção e Reconhecimento de Faixas em Rodovias com Aplicação a Sistemas de Assistência ao Condutor. 2017. 67 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Eletrônica) - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2017.

As funções automotivas ADAS (*Advanced Driver Assistance Systems*) no âmbito atual são critério de diferenciação tecnológica e comercial, futuramente tais funções serão essenciais nos veículos terrestres. O desenvolvimento destas funções com a metodologia baseada em modelos garante compatibilidade e segurança para com os veículos atuais e futuros, com a possibilidade de diversas verificações e validações alinhadas ao desenvolvimento. Este trabalho é focado no desenvolvimento da estratégia de uma função ADAS para o reconhecimento de faixas, através de método estatístico RANSAC (*Random Sample Consensus*), para a aplicação ao LDW (*Lane Departure Warning*) e resultou em um algoritmo robusto que garantiu segurança e compatibilidade, porém ainda com possibilidades de aprimoramentos. Os testes quantitativos e qualitativos realizados para com o algoritmo demonstram a assertividade no reconhecimento de faixas em diversas situações, e consequentemente a assertividade do LDW.

Palavras-chave: ADAS. RANSAC. LDW. Segurança. Compatibilidade.

ABSTRACT

FRANCO, Felipe Rezende. Strategy for Roads Track Detection and Recognition with Application to Driver Assistance Systems. 2017. 67 p. Work of Conclusion Course (Graduation in Electronic Engineering) - Federal Technology University - Paraná. Ponta Grossa, 2017.

The automotive functions of ADAS (Advanced Driver Assistance Systems) in the current scope are criterion of technological and commercial differentiation, in the future such functions will be essential in the terrestrial vehicles. The development of these functions with the model-based design methodology ensures compatibility and safety for current and future vehicles, with the possibility of several verifications and validations aligned to the development. This work is focused on the development of the strategy of an ADAS function for the lanes recognition, using RANSAC (Random Sample Consensus) statistical method, for the application of LDW (Lane Departure Warning) and resulted in a robust algorithm that guaranteed security and compatibility, but still with possibilities for improvements. The quantitative and qualitative tests performed with the algorithm demonstrate the assertiveness in the lanes recognition in several situations, and consequently the assertiveness of the LDW.

Keywords: ADAS. RANSAC. LDW. Security. Compatibility.

LISTA DE ILUSTRAÇÕES

Figura 1 – Etapas do algoritmo	21
Figura 2 – Posicionamento lateral da câmera	22
Figura 3 – Vista do vidro frontal de um veículo com a câmera digital instalada	22
Figura 4 – Matrizes de intensidades da imagem RGB	23
Figura 5 – Otimização de testes.....	24
Figura 6 – Buferização da imagem em intensidade	25
Figura 7 – Filtro de mediana na imagem de intensidade.....	26
Figura 8 – Filtro 2D.....	27
Figura 9 – Definição de Nb e Nf	28
Figura 10 – Buferização binária.....	30
Figura 11 – Atenuação de ruídos com buferização da imagem em intensidade	31
Figura 12 – Atenuação de ruídos com filtro de mediana aplicado na imagem em intensidade.....	32
Figura 13 – Atenuação e amplificação de faixas de valores pelo filtro 2D	33
Figura 14 – Processo de binarização em situações diurna e noturna.....	34
Figura 15 – Processo de buferização binária em faixa segmentada	35
Figura 16 – Escolha aleatória de amostra pelo RANSAC	36
Figura 17 – Cálculo do erro quadrático para todos os pontos analisados	37
Figura 18 – Aplicação do RANSAC modelo linear nas subdivisões da imagem binarizada.....	39
Figura 19 – Aplicação do RANSAC modelo parabólico.....	40
Figura 20 – Faixas válida e inválida	41
Figura 21 – Fluxograma entre pré-processamento, processamento e pós processamento.....	42
Figura 22 – Processo de filtragem interna e externa.....	43
Figura 23 – Obtenção dos ângulos das faixas para o cálculo do LDW	44
Figura 24 – Saída visual do algoritmo sem a ativação do LDW	45
Figura 25 – Saída visual do algoritmo com a ativação do LDW na faixa esquerda... 46	
Figura 26 – Processos de verificação por precisão por linha e precisão por quadro	48
Figura 27 – Resultado da amostra 1 com chuva, perturbações do para-brisa e água na pista.....	49
Figura 28 – Resultado da amostra 2 sem elementos que dificultaram a extração de bordas da pista apenas possível interferência de ruídos de outros veículos	51
Figura 29 – Resultado da amostra 3 sem elementos que dificultaram a extração de bordas da pista nem interferência de ruídos de outros veículos	54
Figura 30 – Resultado da amostra 4 sem elementos que dificultaram a extração de bordas da pista nem interferência de ruídos de outros veículos	56
Figura 31 – Resultado da amostra 5 sem elementos que dificultaram a extração de bordas da pista nem interferência de ruídos de outros veículos	58
Figura 32 – Resultado da amostra 6 em situação noturna.....	61

Figura 33 – Resultado da amostra 7 em situação noturna, com reflexo de faróis de veículos na faixa contrária e ruído de um veículo na frente63

Gráfico 1 - Taxa de diferentes tipos de acidentes e frequência do comportamento da condução de risco em veículos sem e com sistemas de assistência ao condutor14

LISTA DE TABELAS

Tabela 1 - Dados de performace na identificação da faixa esquerda amostra 1.....	49
Tabela 2 - Dados de performace na identificação da faixa direita amostra 1.....	50
Tabela 3 - Dados de performace na identificação da faixa esquerda amostra 2.....	52
Tabela 4 - Dados de performace na identificação da faixa direita amostra 2.....	52
Tabela 5 - Dados de performace na identificação da faixa esquerda amostra 3.....	54
Tabela 6 - Dados de performace na identificação da faixa direita amostra 3.....	55
Tabela 7 - Dados de performace na identificação da faixa esquerda amostra 4.....	57
Tabela 8 - Dados de performace na identificação da faixa direita amostra 4.....	57
Tabela 9 - Dados de performace na identificação da faixa esquerda amostra 5.....	59
Tabela 10 - Dados de performace na identificação da faixa direita amostra 5.....	59
Tabela 11 - Dados de performace na identificação da faixa esquerda amostra 6.....	61
Tabela 12 - Dados de performace na identificação da faixa direita amostra 6.....	62
Tabela 13 - Dados de performace na identificação da faixa esquerda amostra 7.....	63
Tabela 14 - Dados de performace na identificação da faixa direita amostra 7.....	64

LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

ABS	<i>Anti-lock Brake System</i>
ACC	<i>Adaptive Cruise Control</i>
DAM	Desvio absoluto médio
ADAS	<i>Advanced Driver Assistance Systems</i>
DP	Desvio Padrão
GSA	Grupo de Sistemas Automotivos da UTFPR-PG
LDW	<i>Lane Departure Warning</i>
PPL	Precisão por linha
PPQ	Precisão por quadro
RANSAC	<i>Random Sample Consensus</i>
RGB	<i>Red Green Blue</i>
ROI	<i>Region of Interest</i>
UTFPR	Universidade Tecnológica Federal do Paraná
XML	<i>Extensive Markup Language</i>

SUMÁRIO

1 INTRODUÇÃO	13
1.1 PROBLEMA	15
1.2 OBJETIVOS.....	15
1.2.1 Objetivo Geral.....	15
1.2.2 Objetivos Específicos.....	15
1.3 JUSTIFICATIVA.....	15
1.4 REFERENCIAL TEÓRICO.....	16
2 ADVANCED DRIVER ASSISTANCE SYSTEMS.....	19
2.1 RECONHECIMENTO DE FAIXAS.....	19
2.1.1 Lane Departure Warning.....	20
3 DESENVOLVIMENTO DO ALGORITMO DE RECONHECIMENTO DE FAIXAS E LDW	21
3.1 ENTRADA DE VÍDEO.....	21
3.2 PRÉ-PROCESSAMENTO.....	24
3.2.1 Conversão RGB Para Intensidade.....	24
3.2.2 Buferização Da Imagem Em Intensidade.....	24
3.2.3 Filtro De Mediana.....	25
3.2.4 Filtro 2D	26
3.2.5 Método De Binarização: Otsus's Thresholding	27
3.2.6 Buferização Da Imagem Binarizada.....	30
3.2.7 Desenvolvimento Do Pré-Processamento	30
3.3 PROCESSAMENTO	35
3.3.1 RANSAC.....	35
3.3.2 Desenvolvimento Da Etapa Processamento.....	38
3.4 PÓS-PROCESSAMENTO	40
3.4.1 Etapa De Verificação	41
3.4.2 Filtros Externos E Internos.....	42
3.4.3 Lane Departure Warning.....	43
3.4.4 Visualização Para o Usuário	44
4 RESULTADOS E DISCUSSÕES	46
4.1 AMOSTRA 1	48
4.2 AMOSTRA 2	51
4.3 AMOSTRA 3	53
4.4 AMOSTRA 4	55
4.5 AMOSTRA 5	58
4.6 AMOSTRA 6	60
4.7 AMOSTRA 7	62
5 CONCLUSÃO.....	65
REFERÊNCIAS.....	67

1 INTRODUÇÃO

A logística é parte fundamental de diversos setores de um país, pois está presente em todos os âmbitos da sociedade, tais como econômico, social e ambiental.

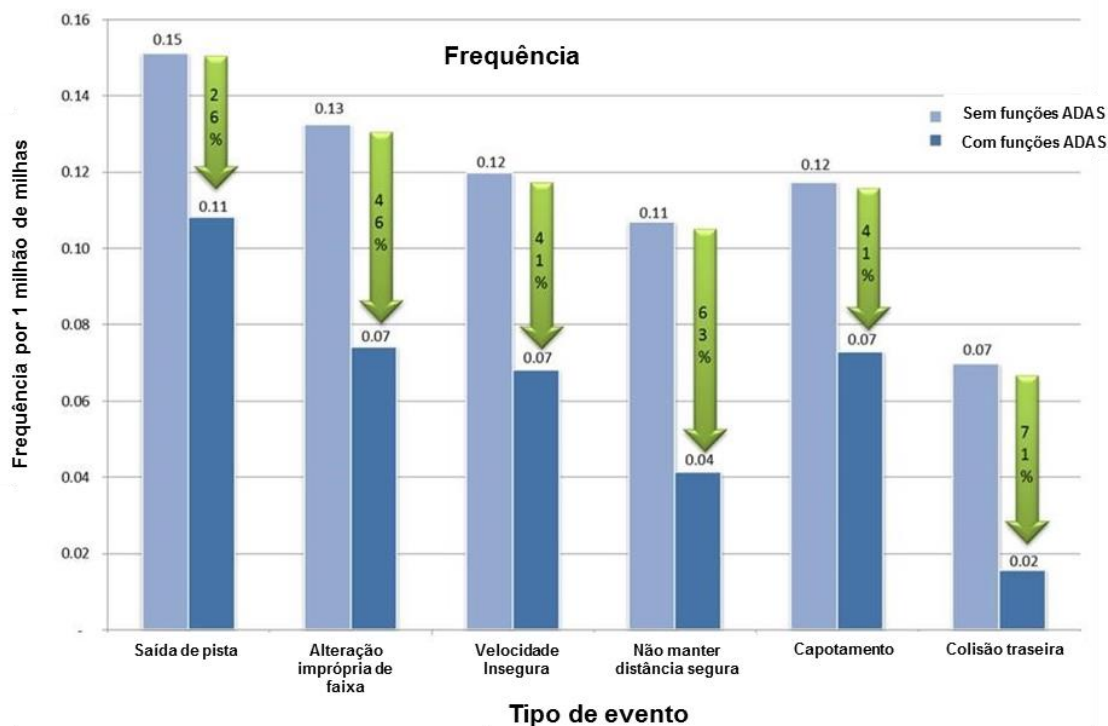
A abrangência da questão logística no gerenciamento de recursos coloca a malha rodoviária como constituinte primário em vários sistemas logísticos. A constituição desses sistemas em parte ou inteiramente rodoviária, privilegia a aplicação de novas tecnologias nesse setor, pela abrangência e impacto delas sobre usuários. A utilização de sistema logísticos terrestres no Brasil para o transporte de cargas chega a 61,1% (IBGE, 2014).

Com a evolução das tecnologias empregadas nos automóveis priorizou-se a conservação da integridade do indivíduo que manipula esses veículos com a inserção não apenas de sistemas e ferramentas que priorizam melhorias nos produtos (conforto, velocidade, autonomia), mas também que visam estabilidade dos indivíduos presentes em situações críticas (*airbag*, cinto de segurança, freios ABS), ou até mesmo evitar e minimizar essas situações com a utilização de sistemas de auxílio ao motorista.

Algumas dessas tecnologias que aprimoram a qualidade dos veículos automotores e que beneficiam a integridade de seus condutores foram novidades e questão de diferenciação tecnológica para a comercialização. Hoje tais tecnologias são componentes obrigatórios em veículos rodoviários em diversos países. Como é o caso do *airbag* e do freio ABS no Brasil que são componentes obrigatórios nos carros produzidos no território brasileiro desde 2014 (CONTRAN, 2009).

A inserção de sistemas ADAS nos automóveis reflete diretamente no envolvimento desses e demais veículos em acidentes. E asseguram a integridade de seus ocupantes com a redução de até 71% na ocorrência de determinado tipo de acidente como demonstrado no Gráfico 1. Com estes índices de redução na ocorrência de acidentes há o fomento para a popularização desses sistemas e posteriormente a inserção destes como itens obrigatórios nos veículos.

Gráfico 1 - Taxa de diferentes tipos de acidentes e frequência do comportamento da condução de risco em veículos sem e com sistemas de assistência ao condutor



Fonte: Adaptado de NTSB (2015)

Deste modo, a comercialização de veículos com ADAS não só é uma questão de diferenciação tecnológica, mas também comercial e precisam de desenvolvimento contínuo que acompanha a evolução de ferramentas e plataformas necessárias para implementação em veículos futuros e já existentes.

Nesta evolução é de suma importância adoção de metodologias de desenvolvimento que garantam ao consumidor final qualidade, confiabilidade, segurança, conforto e satisfação às regulamentações (NEME, 2014). E a todo ciclo de fornecedores e montadoras competitividade dos seus produtos. Assim a adoção de Metodologia de Desenvolvimento Baseado em Modelos (MBD, *Model Based Design*) é algo estratégico que garante vantagem em relação ao método tradicional de desenvolvimento. O desenvolvimento baseado em modelo garante facilidade nas mudanças (avançar ou retroceder etapas do desenvolvimento), facilita a administração da complexidade dos sistemas por mostrar as interações entre os componentes, possibilita a inovação dos sistemas por evitar riscos nas modificações realizadas e possibilita o desenvolvimento mesmo que não se tenha todos os módulos do sistema podendo-se adicioná-los posteriormente (AARENSTRUP, ROGER).

1.1 PROBLEMA

Detectar e realizar o reconhecimento de faixas de modo robusto para a aplicação a um sistema de assistência ao condutor.

1.2 OBJETIVOS

1.2.1 *Objetivo Geral*

Desenvolvimento de uma estratégia de uma função automotiva de detecção e reconhecimento de Faixas aplicado a um sistema de assistência ao condutor.

1.2.2 *Objetivos Específicos*

Desenvolvimento de uma função automotiva de auxílio ao motorista para identificação de faixas rodoviárias através de método estatístico com alerta de saída de pista (LDW – *Lane Departure Warning*) utilizando software Matlab/Simulink com Metodologia Baseada em Modelos.

A aplicação de conceitos matemáticos estatísticos e de visão computacional durante o desenvolvimento da função automotiva.

1.3 JUSTIFICATIVA

A crescente malha rodoviária juntamente com a crescente quantidade de veículos rodoviários, e a necessidade de logística mundial juntamente com a popularização de sistemas ADAS, que evitam a crescente probabilidade de acidentes, estimulam o desenvolvimento desses sistemas em bases modulares e compatíveis com todos os sistemas automotivos já existentes e os futuros.

A Metodologia Baseada em Modelos para o desenvolvimento de softwares garante bases modulares e atende os quesitos de segurança e confiabilidade quando os procedimentos de verificações e validações são realizados adequadamente (NEME, 2014).

Quando aplicada para desenvolvimento de funções ADAS otimiza tempo de desenvolvimento. Garantido ao mesmo tempo sistemas eficientes que proporcionam maiores índices de segurança aos condutores dos veículos e a terceiros.

1.4 REFERENCIAL TEÓRICO

Após a publicação de Fischler e Bolles (1981) sobre a aplicação do código RANSAC na área de cartografia diversas foram as aplicações desse código, inclusive para a área automobilística no âmbito de reconhecimento de padrões. Atualmente esse código ainda é utilizado e possui diversas vertentes com otimizações de gasto computacional, estruturas e técnicas empregadas juntamente com as primícias originais do código. Em muitas aplicações as vertentes desse código foram mescladas com outras técnicas, tais como, de inversão de perspectiva, filtro de Kalman e estratégias especialista para a binarização de imagens.

Em 2004 Jung e Kelber implementaram o reconhecimento de faixas através do método da Transformada Hough utilizando-se do conceito de campo próximo e distante na imagem capturada. O rastreamento no campo próximo segue o modelo linear em consequência de seu comportamento poder ser arredondado à uma função linear, tanto em situações de retas, quanto de curvas. No campo distante há a aplicação de modelo parabólico para melhor adequação às faixas. No campo próximo há aplicação do LDW por meio da análise da diferença da angulação das faixas identificadas, caso essa diferença seja maior que certo limiar o alerta é ativado. Essa técnica para a ativação do LDW pode ser implementada juntamente com o rastreamento de faixas utilizando RANSAC, como foi aplicado neste trabalho.

Borkar, Hayes e Smith (2009) implementaram a identificação de faixas através da projeção de perspectiva inversa juntamente com o RANSAC e a aplicação de filtro Kalman para a realização do rastreamento das faixas. Posteriormente realizaram a análise percentual de assertividade da identificação das faixas que chegou a 89%. O LDW não tinha sido implementado.

Fangfang et al (2012) implementou a identificação de múltiplas faixas encadeando os processos de transformação de perspectiva inversa, transformada Hough, e uma vertente do código RANSAC. Para o melhor ajuste das faixas utilizou o modelo de terceira ordem Bezier Spline, alcançando um percentual de 92% de

assertividade do sistema. As amostras continham um total de 6295 frames. Ressaltou que dentre os 8% faltantes, 3% são respectivos de desalinhamento da faixa identificada e 5% são de erros na identificação.

Kang, Kim e Lee (2014) implementaram um sistema de baixo custo para a realização de duas funções de auxílio ao motorista. A primeira função consiste na aplicação da Transformada de Censo Modificado Estendido e através de requisitos de classificação realizar a identificação de veículos. A segunda função consiste na atenuação de ruídos e aplicação do código RANSAC para a identificação de faixas. Usou-se o conceito de região de interesse (ROI - *Region of Interest*) no campo próximo para o processamento. Com esta estratégia conseguiu-se retirar informações desnecessárias para a identificação das faixas e melhorar o tempo de processamento do algoritmo.

Beyeler, Mirus e Verl (2014) propuseram um sistema de detecção de faixas robusto *ego-lane* baseado nas etapas de segmentação da pista, reconhecimentos das faixas e a estimação das faixas através do código RANSAC, com o objetivo de ser eficiente e simples para a viabilização desse sistema em plataformas computacionais de tempo real. O algoritmo implementado conseguiu bom desempenho em situações rurais, urbanas e interurbanas. Como melhorias futuras do sistema propuseram a adição de filtros (devido ao comportamento das faixas possibilitar tal adição), informações de rotas que o condutor realizará (prevendo cruzamentos e bifurcações) e a fusão de sensores para a detecção de superfícies fracas e estruturas.

Guo, Wei e Miao (2015) propuseram um sistema de detecção de faixas através do código RANSAC modificado mesclado com a técnica de mínimos quadrados. O algoritmo é dividido nas etapas de pré-processamento: ao qual se realiza a secção da imagem na ROI, a conversão para tons de cinza e a aplicação de filtro de mediana para a remoção de possíveis ruídos (preservando as informações da pista); Extração de informações da pista: aplicação de detector de bordas Canny; Modelagem das faixas: usou-se modelos matemáticos para a representação das faixas direita e esquerda; Estimação dos parâmetros dos modelos matemáticos das faixas: utilizou-se para essa tarefa o RANSAC juntamente com a técnica de mínimos quadrados. O algoritmo foi testado em um grupo de vídeos com total de 12637 frames e obteve percentual de assertividade média de 88.82%.

Xu et al (2016) propôs um algoritmo com ênfase em robustez e eficiência. A identificação de faixas é realizada através da utilização de perspectiva inversa (IPM),

define-se a ROI e posteriormente a aplicação do RANSAC com modelo hiperbólico. O algoritmo foi testado em um grupo de amostras nomeado KITTI que é internacionalmente reconhecido para testes de sistemas de auxílio ao motorista. Com as amostras utilizadas (total de 4860 frames) obteve-se percentual médio de 96,05% de assertividade.

Li e Gans (2016) propuseram um método efetivo de rastreamento preditivo de faixas através do código RANSAC juntamente com Kalman Filter. A aplicação do código em hardware foi bem-sucedida com custo computacional de tempo na plataforma Dell M6700 *mobile workstation* de 5 milissegundos por frame analisado. Quando implementado no hardware TDA2x Soc da Texas Instruments® constatou-se o consumo de apenas 2% de capacidade computacional para a faixa de funcionamento de 30 frames por segundo.

Zhu et al (2017) propôs o sistema de detecção de faixas através da secção da imagem de entrada na ROI e posteriormente a aplicação de janelas pequenas de detecção em toda a ROI para a binarização da imagem apenas nas janelas em que se encontravam o comportamento das faixas. Para o processo de binarização foi escolhido o método de limiar de Otsu com valor de limiar pré-estipulado de 50, que garantiu melhor extração de bordas e menor obtenção de ruídos do que o método Canny, que é amplamente utilizado. Após a binarização das janelas com os comportamentos das faixas há divisão de ROI esquerda e direita para a aplicação do RANSAC. Esta técnica foi aplicada em diversas condições climáticas e obtive-se resultados com boa robustez, confiabilidade e adaptabilidade.

2 ADVANCED DRIVER ASSISTANCE SYSTEMS

Os sistemas ADAS englobam os diversos sistemas que têm como objetivo o auxílio ao motorista no ato de dirigir os veículos automotores, tornando esta ação mais segura e fluida com otimização de tempo e intuito de evitar perdas tanto econômicas quanto emocionais.

Os sistemas de Auxílio ao Motorista podem estar em diversas aplicações nos veículos tais como: Controle de Cruzeiro Adaptativo (ACC – *Adaptive Cruise Control*), Reconhecimento de pedestres; Reconhecimentos de obstáculos; sistemas de estacionamento automático; reconhecimento de faixas, sensor de chuva entre diversas outras.

Para aplicações de funções de auxílio ao motorista em veículos é necessário a implementação e modificações de sistemas já existentes. A adição de componentes elétricos e eletrônicos torna-se fundamental, desde sensores, atuadores até os códigos embarcados em hardware.

Para o desenvolvimento de uma função ADAS com a metodologia baseada em modelos escolheu-se a aplicação de reconhecimento de faixas através de método estatístico com LDW.

2.1 RECONHECIMENTO DE FAIXAS

O reconhecimento de faixas nas funções de auxílio ao motorista se faz necessário para evitar os veículos de saírem de suas respectivas pistas e ocasionar possíveis acidentes. Para o desenvolvimento do algoritmo foi empregado a metodologia baseada em modelos, que reflete em ganhos na produção de funções automotivas, visando a eficiência de tempo e confiabilidade do sistema (NEME, 2014) e conseqüentemente otimização de testes.

Através do reconhecimento das faixas é possível a realização de cálculos para a identificação do posicionamento do veículo em relação à pista, e posteriormente saber se este irá ou não evadir a pista contrária e/ou sair da pista atual.

Deste modo com o reconhecimento do posicionamento do veículo é possível a tomada de ações para evitar a evasão do automóvel da pista tal como o LDW que

consiste em avisos sonoros e/ou visuais para alertar o condutor da possível evasão da pista ao qual está.

2.1.1 *Lane Departure Warning*

O LDW consiste em avisos sonoros e/ou visuais para alertar o motorista da possível evasão da pista ao qual está. A ativação desses alertas depende exclusivamente do código implementado para essa função, pois pode ter como referência a posição central do veículo, a distância entre as faixas, angulação de faixas e/ou distância do veículo para com a faixa analisada.

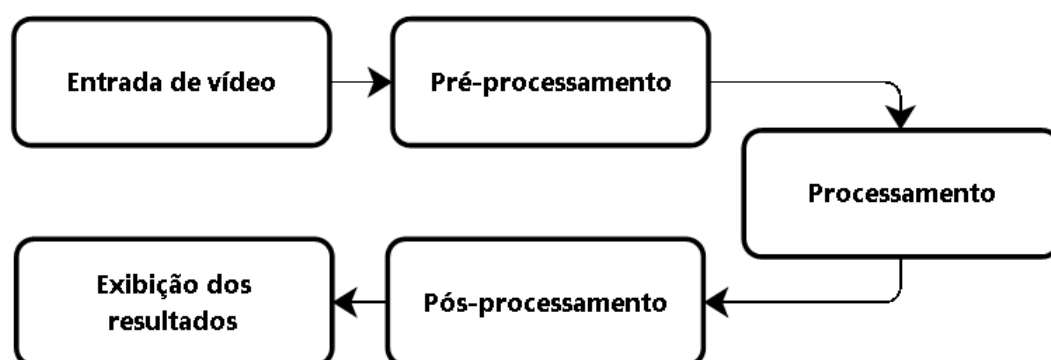
Entretanto todos os métodos têm como objetivo evitar a possível evasão de pista do veículo com alertas para o condutor. A implementação do algoritmo na seção 3.4.3 realiza o alerta através da angulação das faixas reconhecidas posteriormente às etapas de verificações, o que garante robustez e confiabilidade nas ativações do alerta.

3 DESENVOLVIMENTO DO ALGORITMO DE RECONHECIMENTO DE FAIXAS E LDW

Utilizando-se da metodologia de desenvolvimento baseado em modelos na plataforma MATLAB Simulink arquitetou-se o algoritmo de reconhecimento de faixas. Neste algoritmo optou-se por utilizar a segmentação de funcionamento pelas seguintes etapas: entrada de vídeo, pré-processamento, processamento, pós-processamento e exibição dos resultados (Figura 1).

Que consiste na mesma estrutura explanada por Andrade (2017) mudando-se apenas a nomenclatura utilizada. Andrade (2017) se fundamenta na respectiva divisão: processamento de baixo nível (operações primárias como o pré-processamento para redução de ruídos, melhoramento do contraste e nitidez), processamento de nível médio (informações extraídas da imagem, tais como, bordas, contornos e objetos identificados) e processamento de alto nível (interpretação eletrônica de 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))

Figura 1 – Etapas do algoritmo




Fonte: Autoria Própria

3.1 ENTRADA DE VÍDEO

Para o desenvolvimento do algoritmo necessitou-se da captura de imagens de uma câmera (Logitech C920) posicionada no interior do para-brisa de um veículo

(Figura 2). A estrutura e parametrização utilizadas é explanada por Silva (2017), no qual foram extraídas todas as informações da instalação realizada.


Figura 2 – Posicionamento lateral da câmera



Fonte: Silva (2017) adaptado pelo autor (2017)

No para-brisa do veículo a câmera ficou posicionada na porção superior esquerda como demonstrado na Figura 3.

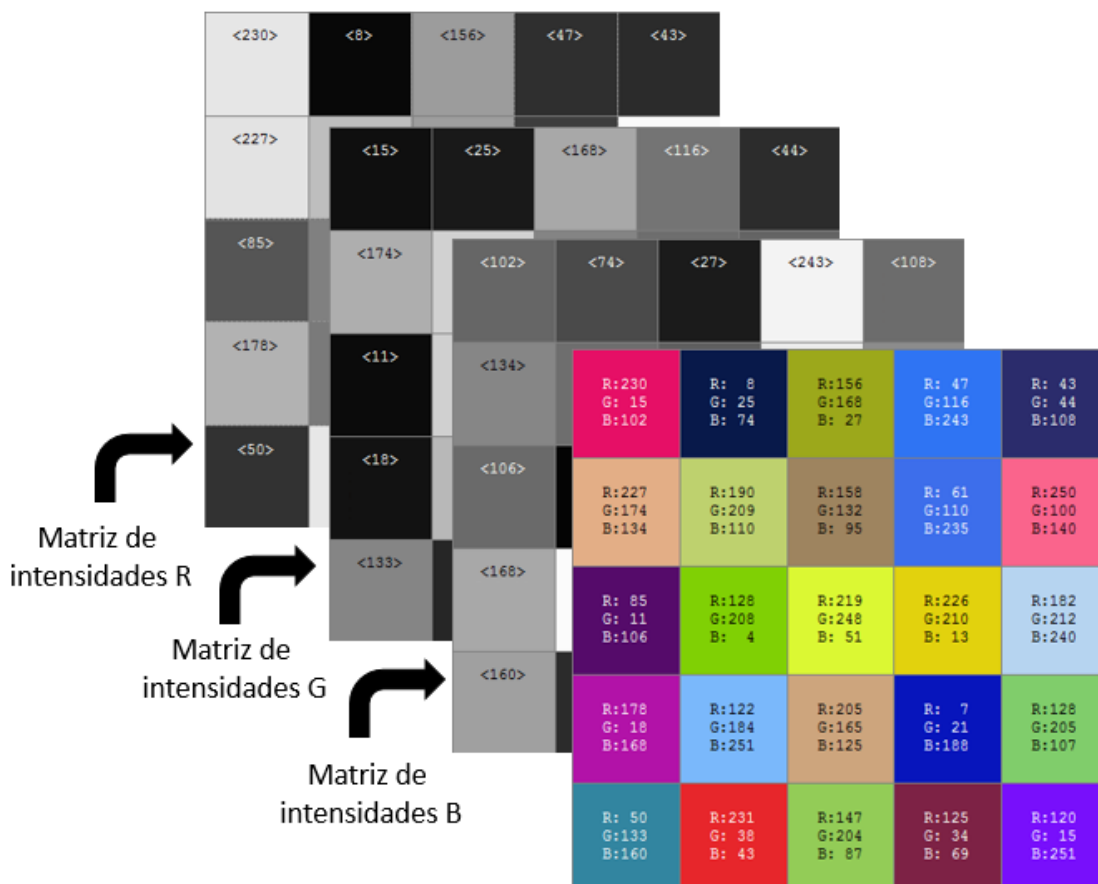
Figura 3 – Vista do vidro frontal de um veículo com a câmera digital instalada



Fonte: Silva (2017) adaptado pelo autor (2017)

Com estas imagens capturadas pode-se começar o processamento da imagem que se comporta como uma matriz de três dimensões constituída por índices das escalas R (*red*), G (*green*) e B (*black*) ilustrada na Figura 4.

Figura 4 – Matrizes de intensidades da imagem RGB



Fonte: Autoria Própria

Através dessas três dimensões há possibilidade de realização de diversas manipulações da imagem para que sejam obtidas as tonalidades para determinada aplicação.

Na plataforma Simulink® há a possibilidade de realização de testes com vídeos e/ou com um hardware de captura de vídeo o que otimiza o processo, pois possibilita a realização de testes com a captura ou reprodução de vídeos juntamente com o desenvolvimento do sistema (Figura 5).

Os resultados são representados por meio de ferramentas da plataforma Simulink® em formatos visuais para o usuário.

Figura 5 – Otimização de testes



Fonte: Autoria Própria

3.2 Pré-Processamento

O pré-processamento consiste na extração de características da imagem sem processamento. No algoritmo desenvolvido realizou-se as etapas de conversão RGB para intensidade, buferização da imagem em intensidade, filtro de mediana, filtro 2D, binarização por método de Otsu e buferização da imagem binarizada.

3.2.1 Conversão RGB Para Intensidade

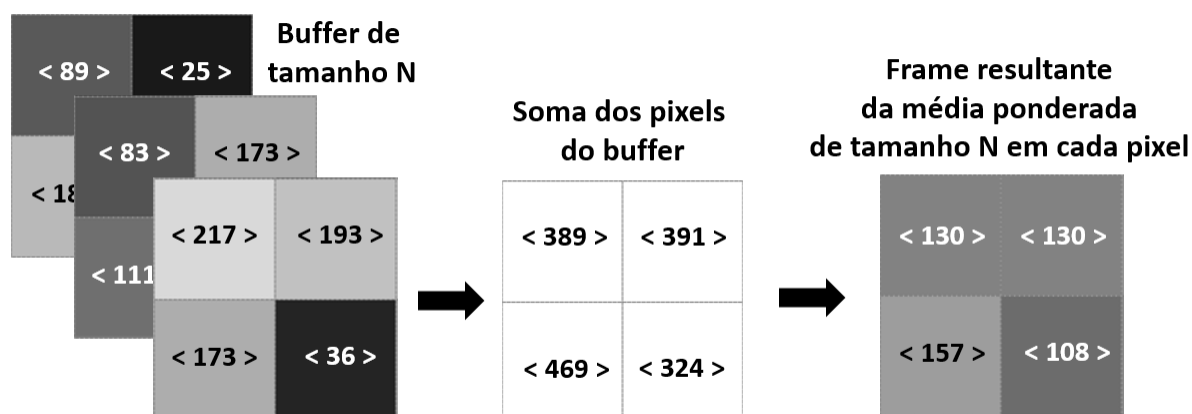
O processo de conversão RGB para intensidade consiste na concatenação dos três pixels das três dimensões multiplicados por fatores e somados em um pixel. Assim mantêm-se as dimensões de linhas e colunas e diminui-se as dimensões de três para uma. Os fatores de multiplicação baseados no padrão NTSC CCIR 601 são demonstrados na Equação (1) de acordo com (BALLABENI *et al.*, 2015).

$$PIXEL_INTENSIDADE = 0.2989 * R + 0.5870 * G + 0.1140 * B \quad (1)$$

3.2.2 Buferização Da Imagem Em Intensidade

A buferização da imagem em intensidade consiste na aquisição de frames de acordo com o tamanho do buffer, e o frame de saída consiste na média ponderada dos pixels de todos os frames armazenados no buffer (Figura 6). A cada interação do algoritmo retira-se o frame mais antigo e acrescenta-se o atual.

Figura 6 – Buferização da imagem em intensidade



Fonte: Autoria Própria

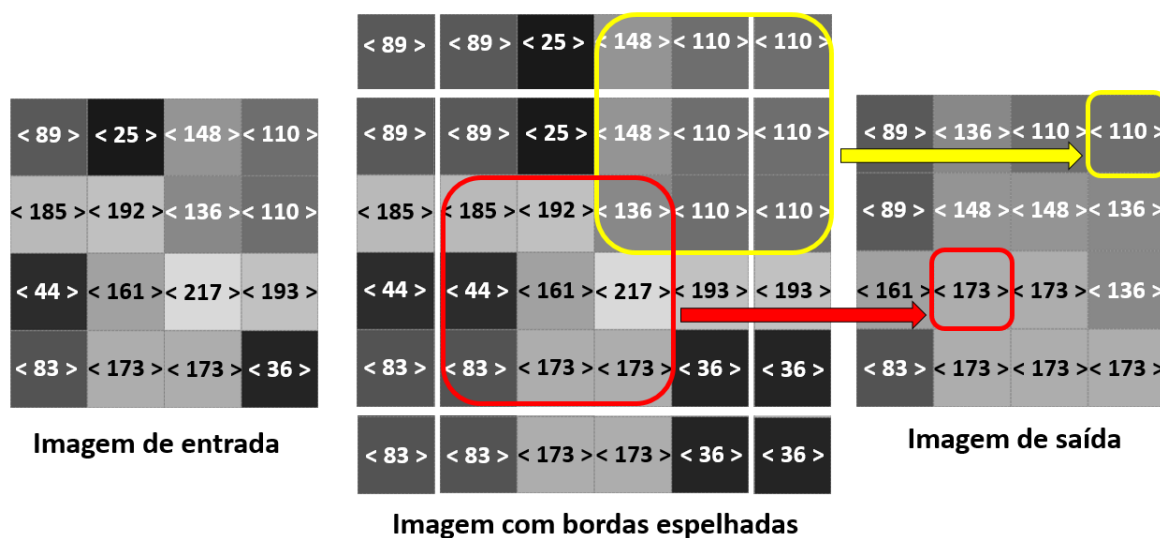
3.2.3 Filtro De Mediana

O filtro de mediana consiste na suavização de dados, com a realização de mediana de um determinado dado central em função dos dados mais próximos de acordo com a vizinhança estipulada. Em processamento de imagem o filtro de mediana consiste na substituição do pixel central pela mediana dos pixels da área de vizinhança como demonstrado na Figura 7.

Este filtro é eficiente para redução de ruídos de picos individuais (SONKA; HLAVAC; BOYLE, 2014). Estes ruídos podem ocasionar grandes contrastes na imagem gerando ruídos na etapa de binarização.

Para os pixels localizados nas bordas realiza-se o processo de espelhamento da imagem e posteriormente aplica-se o filtro de mediana. Especificamente na Figura 7 definiu-se região de vizinhança para a realização das operações de medianas de tamanho 3x3. Caso a região de interesse fosse 4x4 não teria um frame central, neste caso o resultado da mediana na região é alocado no pixel superior esquerdo ao ponto central da região de vizinhança.

Figura 7 – Filtro de mediana na imagem de intensidade



Fonte: Autoria Própria

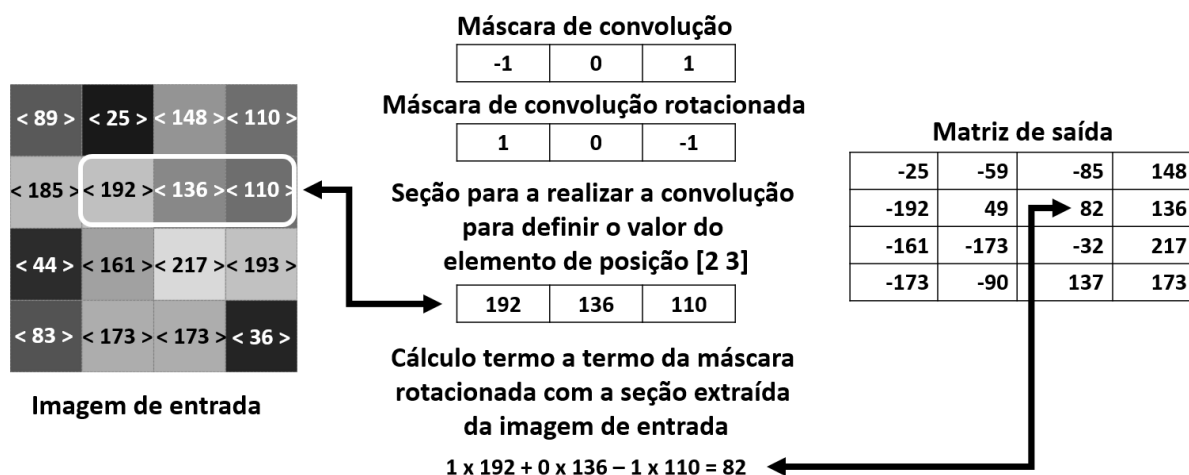
3.2.4 Filtro 2D

O filtro 2D consiste em uma convolução com determinada máscara aplicada nos pixels da imagem e é eficiente na supressão de ruídos gaussianos (SONKA; HLAVAC; BOYLE, 2014) que são originários por situações de iluminação nos processos de transmissão e/ou captura da imagem.

Esta operação é realizada em todos os pixels da imagem como mostrado na Figura 8. Primeiramente inverte-se os elementos da máscara e realiza-se a multiplicação dos termos invertidos para com os termos correspondentes da matriz em tratamento, com o resultado obtido aloca-se este no elemento da matriz de saída que corresponde à localização central do elemento da máscara, após a operação em um elemento o processo se reinicia nos demais termos da matriz em tratamento.

No caso dos elementos na borda da imagem de entrada, os elementos da máscara de convolução que se situarem no exterior das dimensões da imagem são multiplicados por zero sem contribuição no valor de saída do pixel.

Figura 8 – Filtro 2D



Fonte: Autoria Própria

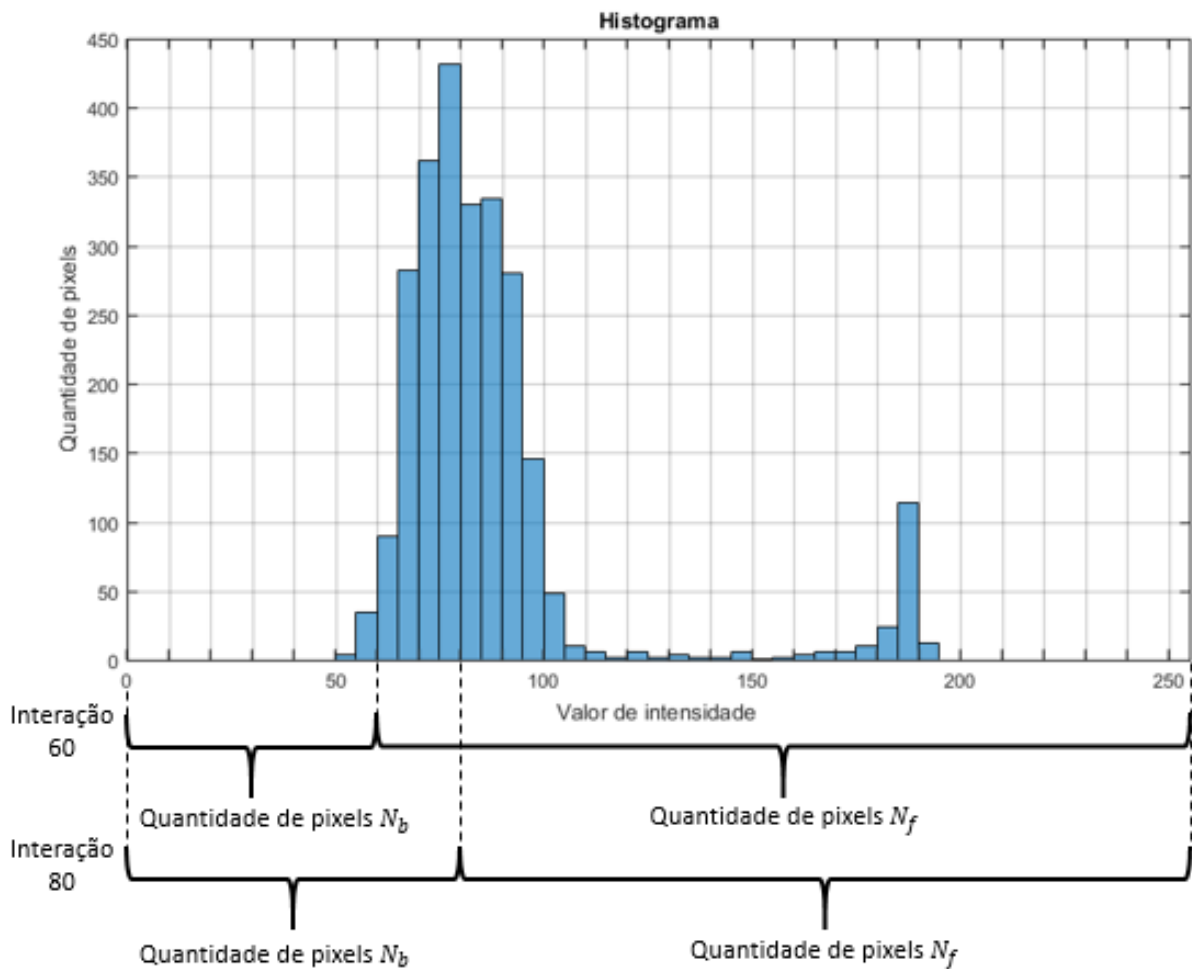
3.2.5 Método De Binarização: Otsus's Thresholding

A binarização da imagem em intensidade é realizada através do método de Otsu que consiste em uma análise do histograma com a extração de pesos, médias e variâncias para a decisão do limiar de intensidade para a realização da binarização.

O processo tem início com a realização do histograma e a divisão deste em dois grupos de pixels, *foreground* e *background*. A cada interação do código os tamanhos dos grupos de pixels *foreground* (N_f) e *background* (N_b) são modificados como mostrado na Figura 9. O valor de intensidade da posição do valor do tamanho do grupo *background* na interação é o limiar de binarização que é analisado.

Deste modo, o tamanho do grupo *background* tem início com o menor valor do histograma e cresce até o máximo valor, e o tamanho do grupo *foreground* é o complementar ao valor do grupo *background* como mostrada na Figura 9.

Figura 9 – Definição de N_b e N_f



Fonte: Autoria Própria

Após a definição da quantidade de pixels e seus respectivos valores em cada grupo (N_f e N_b) é realizado o cálculo para a definição dos pesos W_f e W_b nas Equações (1) e (2).

$$W_f = \frac{N_f}{(N_f + N_b)} \quad (1)$$

$$W_b = \frac{N_b}{(N_f + N_b)} \quad (2)$$

Após a definição dos pesos são realizados os cálculos para a definição das médias de valores dos grupos μ_f e μ_b nas Equações (3) e (4) utilizando-se os valores de intensidade dos pixels (P_{N_f} e P_{N_b}). Sendo que $N_f(k)$ e $N_b(k)$ são as quantidades de pixels com os respectivos valores de intensidade $P_{N_f}(k)$ e $P_{N_b}(k)$.

$$\mu_f = \frac{\sum_{k=1}^{N_f} (P_{N_f}(k) * N_f(k))}{N_f} \quad (3)$$

$$\mu_b = \frac{\sum_{k=1}^{N_b} (P_{N_b}(k) * N_b(k))}{N_b} \quad (4)$$

Após a definição das médias de valores são realizados os cálculos para a definição das variâncias de valores dos grupos σ_f^2 e σ_b^2 nas Equações (5) e (6) utilizando-se os valores de média obtidos nas Equações (3) e (4).

$$\sigma_f^2 = \frac{\sum_{k=1}^{N_f} ((P_{N_f}(k) - \mu_f)^2) * N_f(k)}{N_f} \quad (5)$$

$$\sigma_b^2 = \frac{\sum_{k=1}^{N_b} ((P_{N_b}(k) - \mu_b)^2) * N_b(k)}{N_b} \quad (6)$$

Após a obtenção das variâncias realiza-se o cálculo para a definição da variância conjunta dos grupos na Equação (7) que consiste na soma das variâncias dos grupos multiplicadas pelos seus respectivos pesos.

$$\sigma_w^2 = \sigma_f^2 * W_f + \sigma_b^2 * W_b \quad (7)$$

Após a obtenção da variância conjunta dos grupos para a interação, realiza-se as demais interações para todos os valores do grupo *background*. A interação que obtiver menor valor de variância conjunta é escolhida, e o limiar de binarização é definido como o valor de intensidade para a posição do valor do tamanho do grupo *background*.

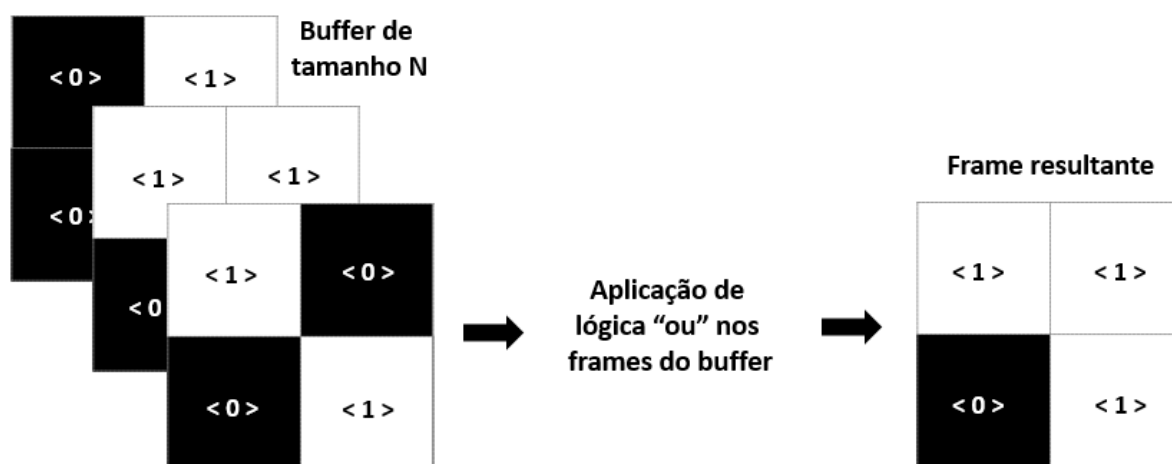
O menor valor de variância conjunta para a imagem do histograma da Figura 9 foi de 333,12 caracterizando o tamanho do grupo *background* de 2368 pixels. Com este tamanho do grupo *background* tem-se o valor 128 de intensidade, logo este é o valor do limiar para a binarização.

Assim, todos os pixels com valores de intensidade maiores do que o limiar definido são binarizados em pixel '1' e os demais em pixel '0'.

3.2.6 Buferização Da Imagem Binarizada

A buferização binária consiste no armazenamento dos frames de acordo com tamanho do buffer definido. O frame de saída é a realização de operações “ou” nos frames do buffer, ou seja, caso um pixel seja ‘1’ em algum dos frames do buffer, o pixel no frame resultante será ‘1’ como demonstrado na Figura 10.

Figura 10 – Buferização binária



Fonte: Autoria Própria

3.2.7 Desenvolvimento Do Pré-Processamento

A imagem oriunda da etapa de aquisição de frames (seção 3.1) é convertida de RGB para intensidade (seção 3.2.1) e encaminhada ao buffer de intensidade (seção 3.2.1).

O filtro de buffers da imagem em intensidade tem eficiência na retirada ou amenização de sinais de alta modificação e/ou com movimentações muito elevadas. Assim o filtro foi aplicado para a retirada do limpador de para-brisa da imagem quando ativado (Figura 11), pois constata-se que o objeto tem deslocamento muito elevado em relação à atualização das informações da pista (faixas). Assim, o valor do tamanho do buffer de intensidade deve satisfazer a necessidade de atenuação de ruídos.

Figura 11 – Atenuação de ruídos com buferização da imagem em intensidade



Fonte: Autoria Própria


Posteriormente à etapa de buferização de intensidade a matriz resultante segue para o processo de filtro de mediana (seção 3.2.3).

O filtro de mediana tem eficiência na atenuação de ruídos que podem gerar pontos aleatórios na etapa de binarização (seção 3.2.5). Na Figura 12 é demonstrado um caso em que um ruído é identificado como pontos binários '1' e quando se aplica


o filtro de mediana na imagem em intensidade evita-se a binarização com valor '1' desse ruído. Assim a definição da vizinhança do filtro deve satisfazer a necessidade de atenuação de possíveis ruídos na imagem.

Figura 12 – Atenuação de ruídos com filtro de mediana aplicado na imagem em intensidade

Frame binário da imagem em intensidade sem o tratamento do filtro de mediana



Frame binário da imagem em intensidade com o tratamento do filtro de mediana



Fonte: Autoria Própria


Posteriormente à etapa de filtro de mediana a matriz resultante segue para o processo de filtro 2D (seção 3.2.4).

O filtro 2D tem eficiência na atenuação de ruídos Gaussianos (SONKA; HLAVAC; BOYLE, 2014) também nomeados como ruídos aleatórios, que podem influenciar diretamente na imagem resultante do processo de binarização, ou pode ser empregado na amplificação e atenuação de valores específicos na imagem em intensidade.

Na Figura 13 é demonstrado o processo de amplificação de *pixels* de alto valor (*pixels* claros) e atenuação de *pixels* de baixo valor (*pixels* escuros) da imagem em intensidade. Assim, a definição da máscara para a realização da convolução, deve satisfazer a robustez do sistema quanto à faixa de valores dos *pixels* a serem atenuados e/ou amplificados.

Figura 13 – Atenuação e amplificação de faixas de valores pelo filtro 2D

Frame em intensidade antes do tratamento do filtro 2D



Frame em intensidade após o tratamento do filtro 2D



Fonte: A autoria Própria

Após a etapa de filtro de filtro 2D a matriz resultante segue para o processo de binarização (seção 3.2.5).

O processo de binarização utilizado foi o de Otsus's Thresholding. Este método garante a binarização robusta à ruídos em diversas situações em consequências de suas análises de variâncias quanto aos grupos que serão ou não binarizados. Na Figura 14 são demonstrados dois casos com iluminações distintas em que este processo de binarização garantiu a extração suficiente de informações da imagem de intensidade.

Figura 14 – Processo de binarização em situações diurna e noturna



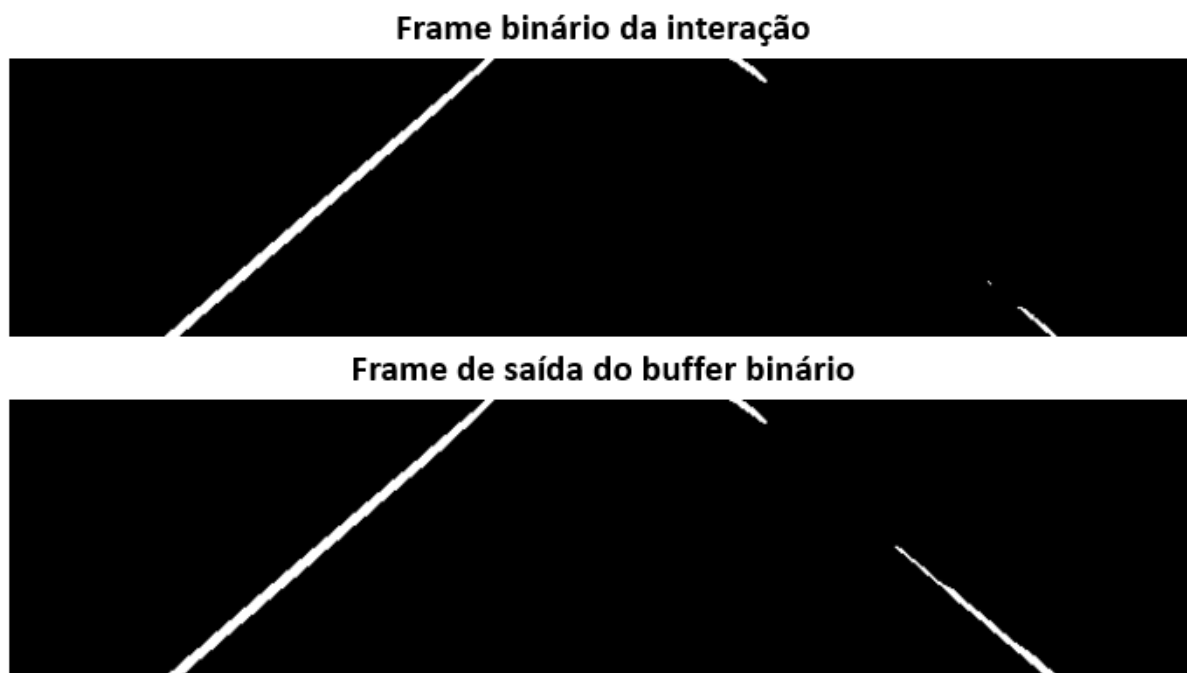
Fonte: Autoria Própria

Após a etapa de binarização a matriz resultante segue para o processo de buferização binária (seção 3.2.6).

Este processo de buferização binária tem eficiência nos possíveis intervalos de falta de informações na pista, ou seja, nos momentos em que o frame tem comportamento binário de faixa, e em um intervalo próximo não há esse comportamento, situação muito comum em faixas tracejadas. Assim, esse buffer foi aplicado para as possíveis perdas de informação nos intervalos de faixas segmentadas para evitar a ocorrência de erros nas próximas etapas do algoritmo

como mostrado na Figura 15. Deste modo, o valor do tamanho do buffer binário deve satisfazer a necessidade de informações nos momentos em que há a perda do comportamento binário em algumas faixas.

Figura 15 – Processo de buferização binária em faixa segmentada



Fonte: Aatoria Própria

3.3 PROCESSAMENTO

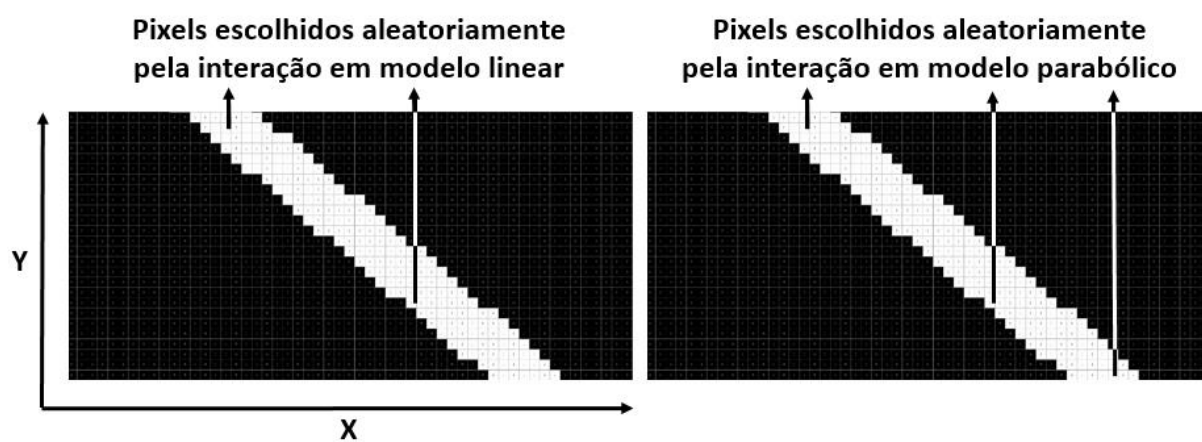
Esta etapa realiza a identificação e localização das faixas utilizando os frames da etapa de pré-processamento. Para o reconhecimento de padrões de faixas utilizou-se vertentes de códigos com o método RANSAC com variados padrões para as diversas etapas do processamento.

3.3.1 RANSAC

O código RANSAC foi definido por Fischler e Bolles em 1981 (FISCHLER, BOLLES, 1981). Após a publicação diversas vertentes foram desenvolvidas, entretanto as primícias iniciais de identificação de modelos matemáticos predefinidos através da amostragem randômica se mantêm as mesmas.

Todos os códigos RANSAC contêm duas bases principais, a de hipótese e de teste. A etapa de hipótese consiste na definição do modelo ao qual se procura com a utilização da quantidade mínima suficiente da amostra de entrada para se obter tal modelo. Na utilização do código RANSAC neste trabalho utilizou-se modelos parabólico e linear, ao qual necessitam de no mínimo três e duas amostras (Figura 16) do grupo de entrada respectivamente.

Figura 16 – Escolha aleatória de amostra pelo RANSAC



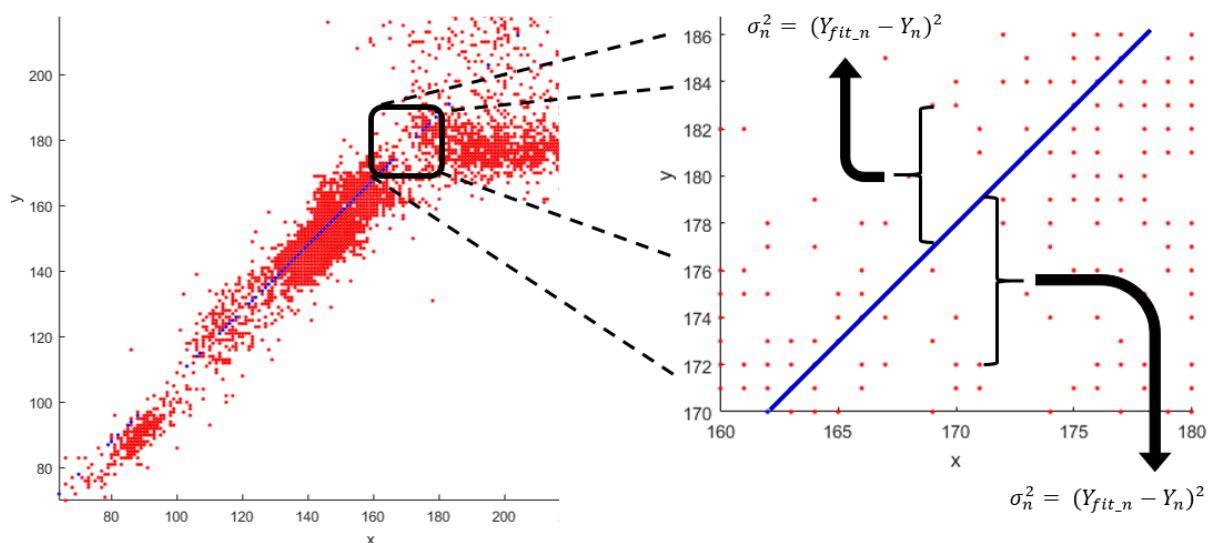
Fonte: Autoria Própria

Após a seleção das amostras se extrai os coeficientes da equação característica através do método da matriz inversa como demonstrado para o modelo parabólico na Equação (9).

$$X * C = Y \rightarrow \begin{bmatrix} x_1^2 & x_1 & 1 \\ x_2^2 & x_2 & 1 \\ x_3^2 & x_3 & 1 \end{bmatrix} \begin{bmatrix} c_1 \\ c_2 \\ c_3 \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix} \rightarrow C = X^{-1} * Y \rightarrow C = \begin{bmatrix} c_1 \\ c_2 \\ c_3 \end{bmatrix} \quad (8)$$

Depois utiliza-se os valores do eixo X de todos os pontos '1' para achar os correspondentes valores Y através dos coeficientes da equação encontrada (Y_{fit_n}) e posteriormente se compara os valores Y reais (Y_n) com os valores encontrados. Na Figura 17 exemplifica a divergência do modelo encontrado na interação com todo o grupo de amostras.

Figura 17 – Cálculo do erro quadrático para todos os pontos analisados



Fonte: Autoria Própria

Posteriormente compara-se os valores de erro quadrático de cada elemento com um limiar para a classificação entre pontos *inliers* (pertencentes ao modelo procurado) ou *outliers* (não pertencentes ao modelo procurado).

Ao final de uma interação do algoritmo se tem valores dos coeficientes do modelo ao qual se procura juntamente com a quantidade de pontos *inliers* e *outliers*. A interação que obtiver com os coeficientes maior número de pontos *inliers* é alocada como resposta (HEKIMOGLU; ERENOGLU; KALINA, 2009).

A quantidade de interações do código é definida pela Equação (9) que leva em consideração a probabilidade que um ponto não está no modelo procurado (e), o número de pontos de uma amostra (s) e a probabilidade desejada em uma interação representativa (p), ou seja, uma interação que represente através dos coeficientes encontrados o modelo procurado. Deste modo, o valor p é definido como 0.99 que estipula que ao menos em uma interação os pontos escolhidos aleatório não estão fora do padrão procurado.

$$Interações = \frac{\log(1 - p)}{\log(1 - (1 - e)^s)} \quad (9)$$

Entretanto para a utilização da Equação (9) é necessário o conhecimento da quantidade de pontos *outliers* o que inviabilizou sua aplicação neste trabalho, pelo fato que essa quantidade de pontos é variável a cada frame analisado. Deste modo,

utilizou-se a Equação (10) que é calculada em toda a interação como limitadora da quantidade de interações totais do algoritmo. Nesta equação utiliza-se o coeficiente ε que representa a probabilidade da não seleção de amostras mínimas que representem o modelo procurado, nomeado como taxa de alarme falso. Também utiliza-se o coeficiente q que representa aproximadamente a probabilidade de seleção por k (grau do modelo procurado) vezes de pontos *inliers* do total de pontos. O coeficiente q pode ser obtido através da Equação (11) que leva em consideração a quantidade de pontos *inliers* da interação (N_I) e a quantidade total de pontos analisados (N).

$$T_{inter} = \frac{\log(\varepsilon)}{\log(1 - q)} \quad (10)$$

$$q = \prod_{i=0}^{k-1} \frac{N_I - i}{N - i} \quad (11)$$

Caso a interação atual seja maior que o coeficiente T_{inter} o código é interrompido e os coeficientes da interação com maior número de pontos *inliers* são encaminhados como resposta final.

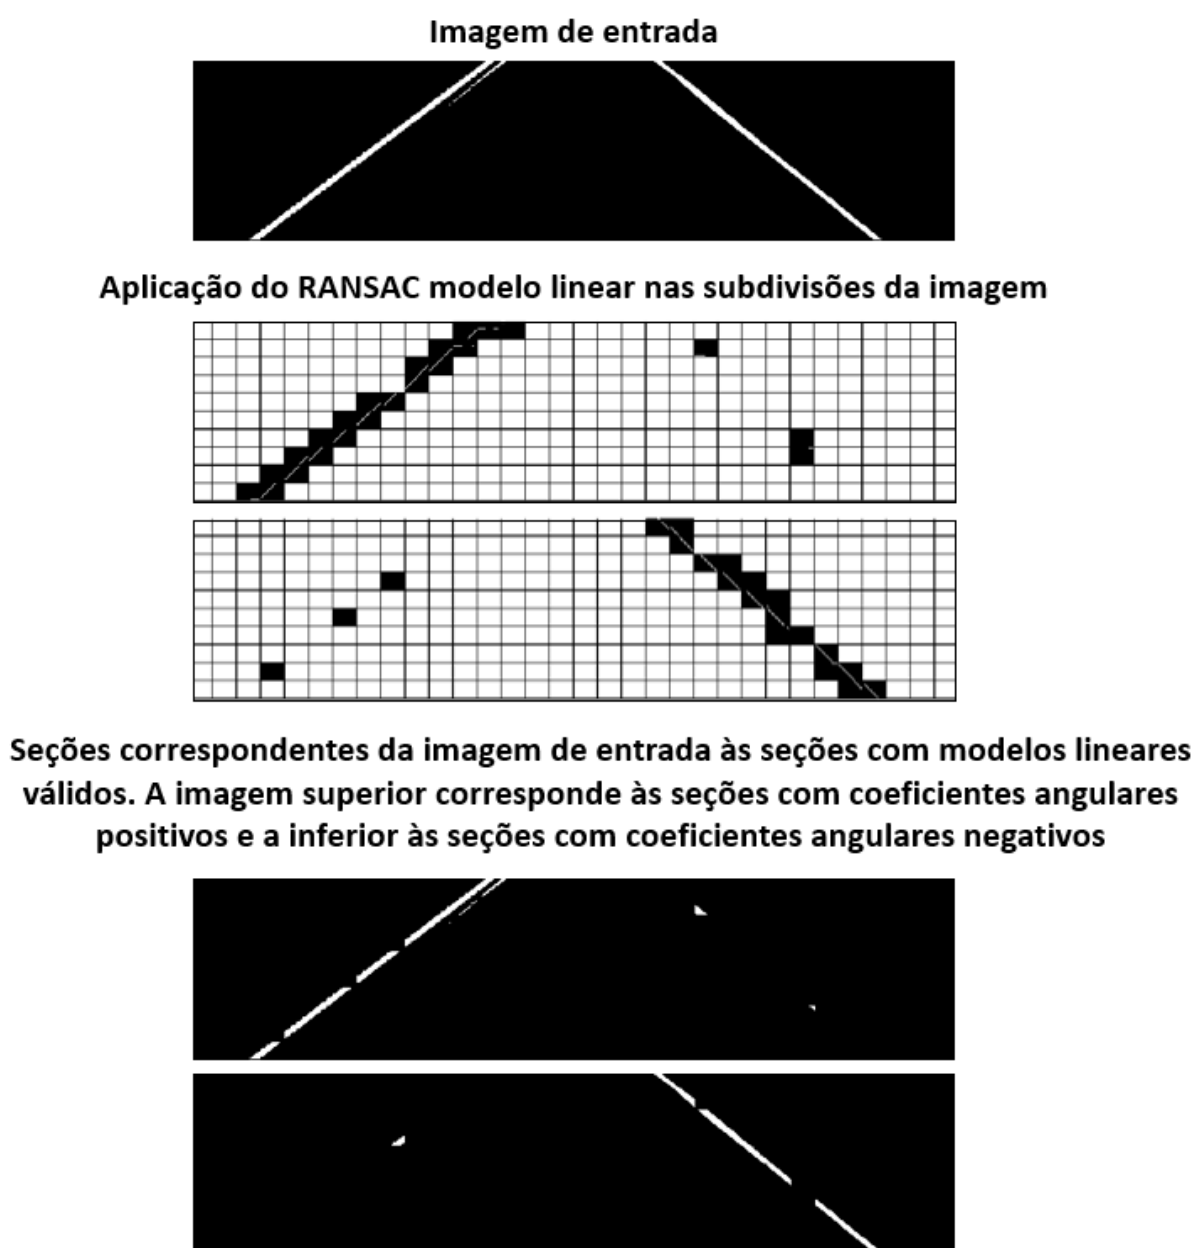
Mas há outros parâmetros controladores de interações que não são dependentes das probabilidades intrínsecas dos pontos analisados, mas que são dependentes do dispêndio de tempo e processamento que o código pode atingir, tais como; o máximo número de interações, máximo número de interações sem o melhoramento do índice de pontos *inliers* e o mínimo de interações que o algoritmo deve realizar. Em ordem hierárquica de variáveis, primeiramente realiza-se o mínimo de interações, e posteriormente o código pode ser interrompido pelos demais parâmetros.

3.3.2 Desenvolvimento Da Etapa Processamento

Essa etapa começa com a subdivisão da imagem binarizada oriunda dos processos anteriores (seção 3.2) em quadrantes menores para o melhor ajuste e identificação. Aplica-se o modelo linear do método RANSAC em cada uma das seções

e com a identificação do padrão identifica-se a disposição espacial das faixas através da análise do coeficiente angular (Figura 18). Caso o coeficiente angular seja positivo trata-se da faixa à esquerda da imagem, caso seja negativo trata-se da faixa à direita da imagem. Para a aplicação do modelo linear em uma seção, esta deve conter um número mínimo de pixels '1', caso não contenha, esta seção é descartada. Caso a seção seja válida, a área da seção correspondente da imagem binarizada de entrada é alocada em imagens separadas de acordo com seus respectivos valores dos coeficientes angulares.

Figura 18 – Aplicação do RANSAC modelo linear nas subdivisões da imagem binarizada



Ao fim desta etapa se tem duas imagens binarizadas que representam padrões à esquerda e direita da imagem. Com essas imagens aplica-se o algoritmo de reconhecimento de padrões em modelo parabólico para a melhor adequação das seções identificadas. Como resultado do modelo parabólico se tem os coeficientes das equações das faixas do modelo procurado, na Figura é mostrado o padrão encontrado pelo algoritmo parabólico.

Figura 19 – Aplicação do RANSAC modelo parabólico

Pontos correspondentes da imagem de entrada às equações encontradas do RANSAC parabólico para as faixas esquerda e direita respectivamente
Modelo de faixa utilizado: $ax^2 + bx + c$



Fonte: Autoria Própria

Após as interações do código RANSAC os coeficientes do modelo de faixa identificados são disponibilizados para as demais etapas.

3.4 PÓS-PROCESSAMENTO

A etapa de pós-processamento tem como objetivo a verificação da integridade das faixas identificadas na etapa de processamento (seção 3.3), extração de pontos para a visualização para o usuário e ativação de alertas em caso de saída de pista.


3.4.1 Etapa De Verificação

A etapa de verificação é realizada através da análise de repetição de pontos ou se esses representam modelos inconsistentes de faixas como mostrado na Figura 20. A identificação desses modelos é de suma importância para se evitar erros nos cálculos de LDW e manter o rastreamento de pontos para a próxima interação do sistema.

Também há a identificação da extrapolação do valor de coeficientes, que pode denotar modelos inconsistentes. Como é o caso do módulo do coeficiente de maior ordem, se esse for muito elevado denota-se um modelo de faixa inconsistente.

Figura 20 – Faixas válida e inválida

Imagem superior: faixa válida, sem repetição de pontos Y e módulo do coeficiente "a" dentro de intervalo calibrado. Imagem inferior: faixa inválida, com repetição de pontos Y e módulo do coeficiente "a" fora de intervalo calibrado



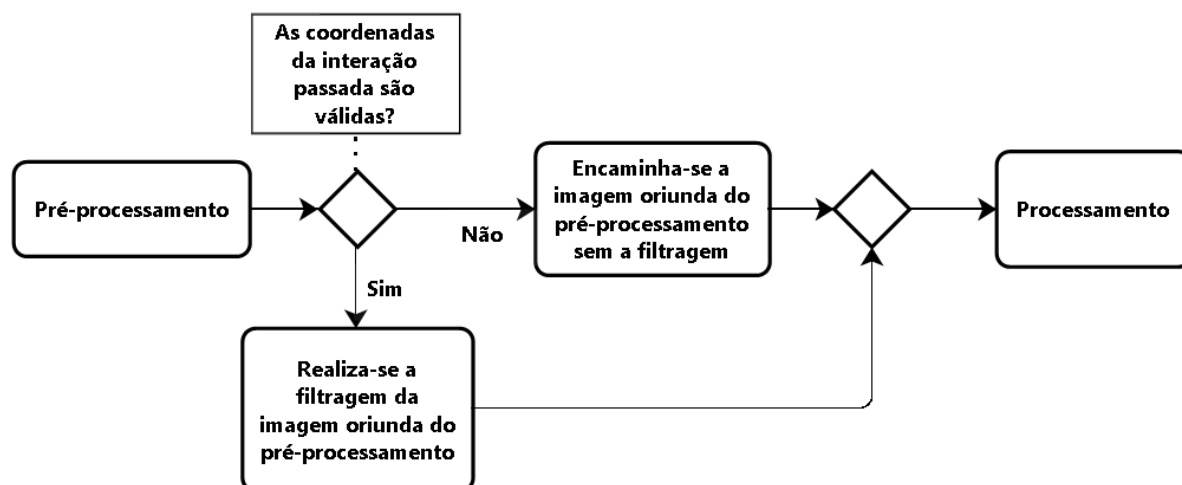
Fonte: Autoria Própria

3.4.2 Filtros Externos E Internos

Os filtros externos e internos consistem no rastreamento da faixa do frame atual em função da região próxima da faixa identificada em interações passadas. Deste modo, só há a ativação desses filtros caso se tenha as coordenadas válidas das faixas em interações passadas.

Quando há coordenadas válidas da interação passada realiza-se a filtragem da imagem oriunda do pré-processamento e posteriormente encaminha-a para a etapa de processamento. Quando não há coordenadas válidas não há a filtragem da etapa oriunda do pré-processamento, esta é encaminhada diretamente para etapa do processamento como mostrado na **Erro! Fonte de referência não encontrada**. Figura 21.

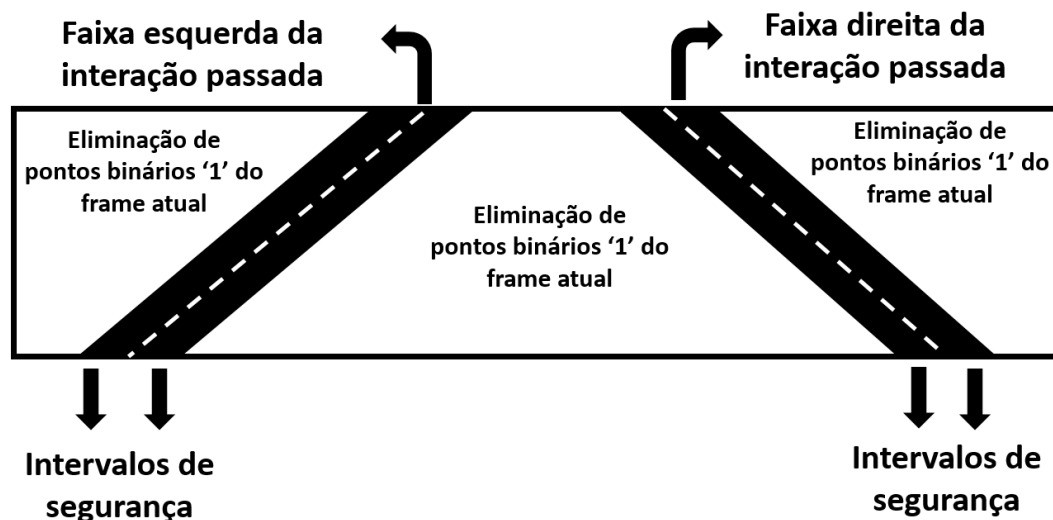
Figura 21 – Fluxograma entre pré-processamento, processamento e pós processamento



Fonte: Autoria Própria

A filtragem consiste na eliminação de pontos binários '1' do frame da interação atual em relação às coordenadas passadas com um intervalo de segurança para que não comprometa a integridade da faixa no frame atual como demonstrado na Figura 22. A área central entre as faixas consiste na filtragem interna e as áreas superiores das bordas consistem na filtragem externa.

Figura 22 – Processo de filtragem interna e externa




Fonte: Autoria Própria

3.4.3 Lane Departure Warning

Após a verificação da integridade das faixas, há o cálculo do LDW para a definição se o veículo está ou não evadindo da faixa ao qual se encontra. Neste cálculo há a consideração do campo próximo da imagem para obtenção de dados como demonstrado na Figura 23.

No campo próximo realiza-se a extração de algumas amostras da localização das faixas com a aproximação linear para a definição do ângulo. Através da definição do ângulo é possível a identificação da saída de faixa com análise da magnitude dos valores com limites preestabelecidos e assim realizar a ativação ou desativação do alerta para o motorista.

Figura 23 – Obtenção dos ângulos das faixas para o cálculo do LDW



Fonte: Autoria Própria

3.4.4 Visualização Para o Usuário

Após a definição do estado do LDW realiza-se a extração das coordenadas do modelo da faixa identificada para a visualização do usuário. Esta etapa é importante pois permite a análise preliminar subjetiva do desenvolvedor, que pode ser útil na identificação de falhas grosseiras ou até mesmo da não funcionalidade do sistema.

Deste modo a visualização do resultado Figura 24 não é somente visual, mas também uma das etapas de verificação antes da etapa de verificação quantitativa. A verificação qualitativa pode poupar tempo de desenvolvimento se a identificação de erros ocorrer, dada que a verificação quantitativa há um maior dispêndio de tempo de desenvolvimento. As funções de identificações de tipo e cor de faixas e de noite ou dia não são analisadas por esse não ser o foco do trabalho que se restringe no rastreamento de faixas e a aplicação da função de LDW.

Figura 24 – Saída visual do algoritmo sem a ativação do LDW



Fonte: Autoria Própria

Assim, a análise subjetiva é viável para a percepção do funcionamento geral do algoritmo e de casos específicos, tais como situações climáticas e de luminosidades que estressam ao máximo o algoritmo.

Na Figura 25 há ativação do LDW e o aviso para a faixa da esquerda. O LDW para a faixa da direita é análogo e apenas a localização do aviso que muda para a outra extremidade da imagem.

Figura 25 – Saída visual do algoritmo com a ativação do LDW na faixa esquerda



Fonte: Autoria Própria

4 RESULTADOS E DISCUSSÕES

Para a realização de testes foram usadas 7 amostras com total de 4261 frames do banco de dados do GSA (Grupo de Sistemas Automotivos) na UTFPR-PG. As amostras selecionadas contemplaram vários cenários climáticos e de situações rodoviárias diferentes. Nos cenários climáticos há amostras que se destacam pela presença de chuva, perturbação visual do para-brisa e perturbação visual da água acumulada na pista e amostras em que não há perturbações visuais, ou seja, com menos stress do algoritmo para a identificação das faixas. As amostras contemplam tanto situações diurnas quanto noturnas, e há diversificação nas situações rodoviárias (pistas duplas, simples, contínuas, segmentadas, amarelas e brancas).

As verificações das marcações da pista foram realizadas usando o método *ground truth* ao qual consiste na marcação manual da localização ideal das faixas (neste caso a borda interna das faixas) que são armazenadas em arquivo com

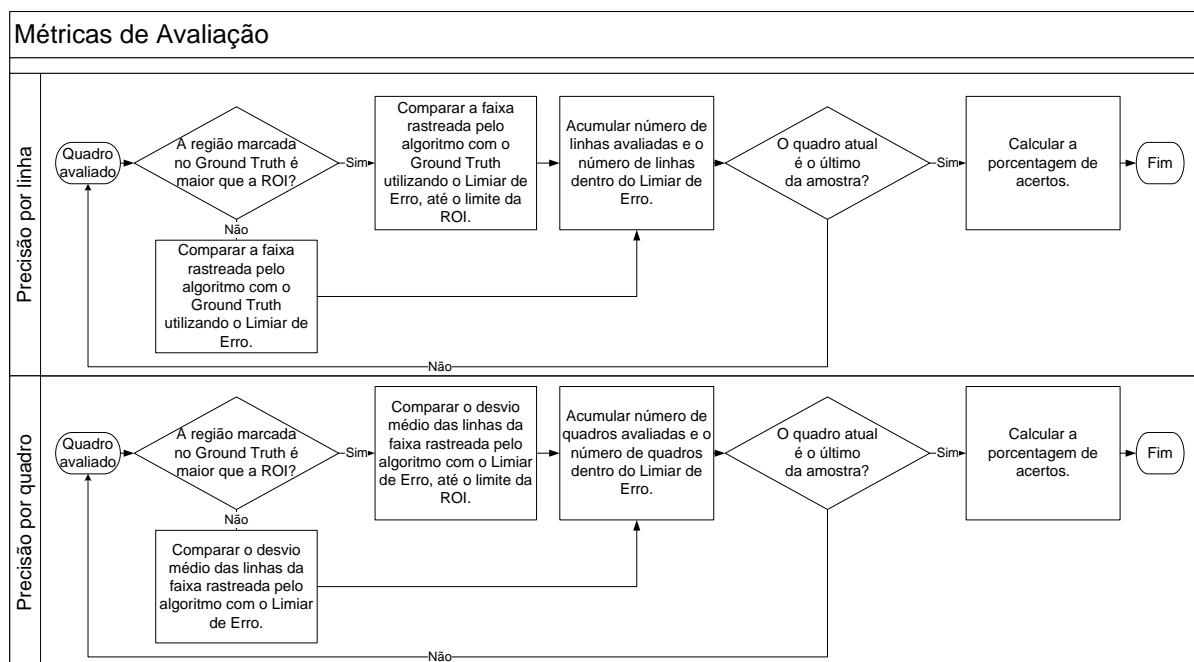
extensão XML e posteriormente se compara essas coordenadas para com as marcações do algoritmo.

O software utilizado nesse processo foi o *RoadMarker* desenvolvido por Felipe Bueno (2016) no GSA que possui duas interfaces, uma é para a marcação do *ground truth* e outra para a comparação de arquivos XML. Para o processo de marcação há as seguintes etapas: seleção da amostra, marcação da posição ideal das faixas através de cliques sobre o vídeo real e armazenamento dessas coordenadas em um arquivo XML. Juntamente com as coordenadas há possibilidade de informar tipo e cor das faixas, ao qual não foram analisadas por não ser o foco deste trabalho.

A alocação dos resultados do algoritmo também é realizada através do armazenamento das coordenadas das faixas identificadas em um arquivo com extensão XML.

Posteriormente realiza-se a comparação dos arquivos XML. O software possui duas principais validações das coordenadas, por PPL (precisão de linha) e PPQ (precisão por quadro), e seus processos são demonstrados na Figura 26. A PPL consiste na verificação linha a linha da marcação ideal para com a saída do algoritmo. A PPQ consiste na verificação de um limiar informado pelo usuário com o desvio absoluto médio (DAM) das coordenadas ideais para com as coordenadas de saída do algoritmo. O software ainda disponibiliza o desvio padrão (DP) das marcações das faixas analisadas.

Figura 26 – Processos de verificação por precisão por linha e precisão por quadro



Fonte: Andrade (2017)

Realizadas as verificações dos arquivos XML são geradas planilhas com extensão csv para a interpretação dos dados. Para com essas planilhas é possível a obtenção das informações de cada amostra e as médias gerais dos dois processos de verificação. Para cada amostra obteve-se os índices para as faixas esquerda e direita com a variação da ROI em 100, 120, 140 e 150 pixels (linhas) e para cada valor da ROI variou-se o limiar de erro nos valores de 10, 15 e 20.

4.1 AMOSTRA 1

Esta amostra foi formada por 638 frames, a faixa da esquerda era contínua branca, e a faixa da direita era segmentada branca com um pequeno trecho sendo contínua em razão da travessia de uma ponte. Conteve elementos que dificultaram a extração de bordas da pista pela presença de ruídos do para-brisa, de chuva e água na pista (Figura 27). Os buffers desempenharam efeito essencial para manter o rastreamento das faixas estável mesmo com o grande estresse do algoritmo e em situação de faixa segmentada. A retirada de ruídos foi ideal para o não comprometimento da identificação das faixas.

Figura 27 – Resultado da amostra 1 com chuva, perturbações do para-brisa e água na pista



Fonte: Autoria Própria

A análise da saída do algoritmo para a faixa esquerda é exposta na Tabela 1. Pode-se perceber que o aumento do limiar de erro influenciou diretamente no resultado da PPL e PPQ sendo que teve grande variação nos índices de limiares para com todas as ROIs. Entretanto a modificação das ROIs teve pouca influência nos índices de PPL e nenhuma nos índices de PPQ. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações.

Tabela 1 - Dados de performace na identificação da faixa esquerda amostra 1

Parâmetros		Faixa à esquerda			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	13,0426	4,1151	34,43	31,58
100	15	13,0428	4,1147	69,16	57,89
100	20	13,0428	4,1147	89,20	100,00
120	10	13,0006	4,1054	34,82	31,58

120	15	13,0006	4,1054	69,46	57,89
120	20	13,0006	4,1054	89,30	100,00
140	10	13,0006	4,1054	34,82	31,58
140	15	13,0006	4,1054	69,46	57,89
140	20	13,0006	4,1054	89,30	100,00
150	10	13,0006	4,1054	34,82	31,58
150	15	13,0006	4,1054	69,46	57,89
150	20	13,0006	4,1054	89,30	100,00

Fonte: Autorial Própria

A análise da saída do algoritmo para a faixa direita é exposta na Tabela 2. Pode-se perceber que o aumento do limiar de erro influenciou apenas no resultado da PPL sendo que o índice de PPQ se manteve em todas as análises. A modificação das ROIs teve pouca influência nos índices. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações.

Tabela 2 - Dados de performace na identificação da faixa direita amostra 1


Parâmetros		Faixa à direita			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	3,0750	1,5517	95,37	100,00
100	15	3,0750	1,5517	95,72	100,00
100	20	3,0750	1,5517	95,72	100,00
120	10	3,0724	1,5433	95,41	100,00
120	15	3,0724	1,5433	95,77	100,00
120	20	3,0724	1,5433	95,77	100,00
140	10	3,0724	1,5433	95,41	100,00
140	15	3,0724	1,5433	95,77	100,00
140	20	3,0724	1,5433	95,77	100,00
150	10	3,0724	1,5433	95,41	100,00
150	15	3,0724	1,5433	95,77	100,00
150	20	3,0724	1,5433	95,77	100,00

Fonte: Autorial Própria

4.2 AMOSTRA 2

Esta amostra foi formada por 493 frames, a faixa da esquerda era contínua branca, e a faixa da direita era contínua branca com um pequeno trecho sendo segmentada (Figura 28). Não conteve elementos que dificultaram a extração de bordas da pista apenas possível interferência de ruídos de outros veículos. A identificação das faixas foi realizada com menos estresse do algoritmo quanto à identificação das faixas na amostra 1.

Figura 28 – Resultado da amostra 2 sem elementos que dificultaram a extração de bordas da pista apenas possível interferência de ruídos de outros veículos



Fonte: Autoria Própria

A análise da saída do algoritmo para a faixa esquerda é exposta na Tabela 3. Pode-se perceber que o aumento do limiar de erro influenciou diretamente no resultado da PPL e PPQ sendo que teve grande variação nesses em todas as ROIs. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações.

Mesmo em situação mais favorável para a identificação das faixas nessa amostra os maiores valores de PPL e PPQ foram de 69,53% e 75,86% respectivamente. Isso é em função da métrica de *ground truth* adotada da marcação das coordenadas ideais das faixas serem as bordas internas, entretanto pela análise qualitativa identificou-se que o algoritmo realizou o reconhecimento e marcação da borda externa da faixa esquerda, comprometendo os índices quantitativos de PPL e PPQ.

Tabela 3 - Dados de performace na identificação da faixa esquerda amostra 2

Parâmetros		Faixa à esquerda			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	17,4955	4,1694	11,68	3,07
100	15	17,4955	4,1694	39,08	32,18
100	20	17,4955	4,1694	69,23	75,86
120	10	17,4405	4,1609	11,99	3,07
120	15	17,4405	4,1609	39,60	32,57
120	20	17,4405	4,1609	69,53	75,86
140	10	17,4405	4,1609	11,99	3,07
140	15	17,4405	4,1609	39,60	32,57
140	20	17,4405	4,1609	69,53	75,86
150	10	17,4405	4,1609	11,99	3,07
150	15	17,4405	4,1609	39,60	32,57
150	20	17,4405	4,1609	69,53	75,86

Fonte: Autoria Própria

A análise da saída do algoritmo para a faixa direita é exposta na Tabela 4. Pode-se perceber que o aumento do limiar de erro influenciou nos índices de PPQ e PPL. A modificação das ROIs teve pouca influência nos índices. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações. Neste caso a identificação e marcação das faixas foram realizados na borda interna sendo explícito tal comportamento do algoritmo pelo índice de PPL ser alto para com todos os valores de limiar de erro e pela saída visual.

Tabela 4 - Dados de performace na identificação da faixa direita amostra 2

Parâmetros		Faixa à direita			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	3,1466	2,2295	96,06	98,47
100	15	3,1466	2,2295	97,07	100,00

100	20	3,1466	2,2295	97,07	100,00
120	10	3,1418	2,2231	96,10	98,47
120	15	3,1418	2,2231	97,09	100,00
120	20	3,1418	2,2231	97,09	100,00
140	10	3,1418	2,2231	96,10	98,47
140	15	3,1418	2,2231	97,09	100,00
140	20	3,1418	2,2231	97,09	100,00
150	10	3,1418	2,2231	96,10	98,47
150	15	3,1418	2,2231	97,09	100,00
150	20	3,1418	2,2231	97,09	100,00


Fonte: Autoria Própria

4.3 AMOSTRA 3

Esta amostra foi formada por 810 frames, a faixa da esquerda era contínua, por um breve trecho contínua dupla e ao final do vídeo dupla segmentada, amarela em toda a amostra, e a faixa da direita era contínua branca (Figura 29). Não conteve elementos que dificultaram a extração de bordas da pista nem interferência de ruídos de outros veículos. A identificação das faixas foi realizada com menos estresse do algoritmo quanto à identificação das faixas na amostra 2.

A análise da saída do algoritmo para a faixa esquerda é exposta na Tabela 5. Pode-se perceber que o aumento do limiar de erro influenciou diretamente no resultado da PPL e PPQ sendo que teve grande variação nesses índices em todas as ROIs. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações. Mesmo em situação mais favorável para a identificação das faixas nessa amostra os maiores valores de PPL e PPQ foram de 31,35% e 32,66% respectivamente. Isso é em função da métrica de *ground truth* adotada da marcação das coordenadas ideais das faixas serem as bordas internas, entretanto pela análise qualitativa identificou-se que o algoritmo realizou o reconhecimento e marcação da borda externa da faixa esquerda, comprometendo os índices quantitativos de PPL e PPQ.

Figura 29 – Resultado da amostra 3 sem elementos que dificultaram a extração de bordas da pista nem interferência de ruídos de outros veículos



Fonte: Autoria Própria

Tabela 5 - Dados de performace na identificação da faixa esquerda amostra 3

Parâmetros		Faixa à esquerda			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	30,4685	13,2014	9,54	5,28
100	15	30,4685	13,2014	24,09	25,75
100	20	30,4685	13,2014	31,29	32,52
120	10	30,3774	13,1638	9,71	5,28
120	15	30,3774	13,1638	24,18	25,75
120	20	30,3774	13,1638	31,35	32,66
140	10	30,3774	13,1638	9,71	5,28
140	15	30,3774	13,1638	24,18	25,75
140	20	30,3774	13,1638	31,35	32,66
150	10	30,3774	13,1638	9,71	5,28
150	15	30,3774	13,1638	24,18	25,75
150	20	30,3774	13,1638	31,35	32,66

Fonte: Autoria Própria

A análise da saída do algoritmo para a faixa direita é exposta na Tabela 6. Percebe-se que o aumento do limiar de erro teve pouca influência nos índices de PPQ e PPL. A modificação das ROIs teve pouca influência nos índices. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações. Neste caso a identificação e marcação das faixas foram realizados na borda interna sendo explícito tal comportamento do algoritmo pelos índices de PPL e PPQ serem altos para com todos os valores de limiar de erro.

Tabela 6 - Dados de performace na identificação da faixa direita amostra 3

Parâmetros		Faixa à direita			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	2,6563	2,1349	94,34	98,64
100	15	2,6563	2,1349	95,56	100,00
100	20	2,6563	2,1349	95,56	100,00
120	10	2,6532	2,1294	94,40	98,64
120	15	2,6532	2,1294	95,60	100,00
120	20	2,6532	2,1294	95,60	100,00
140	10	2,6532	2,1294	94,40	98,64
140	15	2,6532	2,1294	95,60	100,00
140	20	2,6532	2,1294	95,60	100,00
150	10	2,6532	2,1294	94,40	98,64
150	15	2,6532	2,1294	95,60	100,00
150	20	2,6532	2,1294	95,60	100,00

Fonte: Autoria Própria

4.4 AMOSTRA 4

Esta amostra foi formada por 638 frames, a faixa da esquerda era dupla contínua, por um breve trecho com faixa contínua simples, amarela em toda a amostra, e a faixa da direita era contínua branca (Figura 30). Não conteve elementos que dificultaram a extração de bordas da pista nem interferência de ruídos de outros veículos.

Figura 30 – Resultado da amostra 4 sem elementos que dificultaram a extração de bordas da pista nem interferência de ruídos de outros veículos



Fonte: Autoria Própria

A análise da saída do algoritmo para a faixa esquerda é exposta na Tabela 7. Percebe-se que o aumento do limiar de erro influenciou diretamente nos resultados de PPL e PPQ. O índice PPL aumentou conforme aumentava-se o limiar de erro sem muita influência da variação da ROI, atingindo menor e maior valor respectivamente de 87,6% e 96,72%. Em PPQ a maior variação foi com o aumento do limiar de erro de 10 para 15 sem influência das variações da ROI. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações. Mesmo em situação mais favorável para a identificação das faixas nessa amostra os maiores valores de PPL e PPQ foram de 31,35% e 32,66% respectivamente. Nessa amostra a marcação das coordenadas da faixa foram realizadas de acordo com as métricas de *ground truth* elevando principalmente os valores de PPQ com menor e maior valor 91,18% e 100% respectivamente.

Tabela 7 - Dados de performance na identificação da faixa esquerda amostra 4

Parâmetros		Faixa à esquerda			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	6,4080	2,5261	87,67	91,18
100	15	6,4080	2,5261	96,22	100,00
100	20	6,4080	2,5261	96,69	100,00
120	10	6,3882	2,5147	87,79	91,18
120	15	6,3882	2,5147	96,26	100,00
120	20	6,3882	2,5147	96,72	100,00
140	10	6,3882	2,5147	87,79	91,18
140	15	6,3882	2,5147	96,26	100,00
140	20	6,3882	2,5147	96,72	100,00
150	10	6,3882	2,5147	87,79	91,18
150	15	6,3882	2,5147	96,26	100,00
150	20	6,3882	2,5147	96,72	100,00

Fonte: Autoria Própria

A análise da saída do algoritmo para a faixa direita é exposta na Tabela 8. Percebe-se que o aumento do limiar de erro e da ROI não tiveram influência nos índices de PPQ e PPL. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações. Neste caso a identificação e marcação das faixas foram realizados na borda interna sendo explícito tal comportamento do algoritmo pelos índices de PPL e PPQ serem altos para com todos os valores de limiar de erro.

Tabela 8 - Dados de performance na identificação da faixa direita amostra 4

Parâmetros		Faixa à direita			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	2,6665	1,3119	96,09	100,00
100	15	2,6665	1,3119	96,09	100,00
100	20	2,6665	1,3119	96,09	100,00
120	10	2,6626	1,3077	96,13	100,00
120	15	2,6626	1,3077	96,13	100,00
120	20	2,6626	1,3077	96,13	100,00
140	10	2,6626	1,3077	96,13	100,00
140	15	2,6626	1,3077	96,13	100,00
140	20	2,6626	1,3077	96,13	100,00
150	10	2,6626	1,3077	96,13	100,00
150	15	2,6626	1,3077	96,13	100,00

150	20	2,6626	1,3077	96,13	100,00
-----	----	--------	--------	-------	--------

Fonte: Aatoria Própria

4.5 AMOSTRA 5

Esta amostra foi formada por 377 frames, a faixa da esquerda era simples contínua branca, e a faixa da direita era simples segmentada branca (Figura 31). Não conteve elementos que dificultaram a extração de bordas da pista nem interferência de ruídos de outros veículos.

Figura 31 – Resultado da amostra 5 sem elementos que dificultaram a extração de bordas da pista nem interferência de ruídos de outros veículos



Fonte: Aatoria Própria

A análise da saída do algoritmo para a faixa esquerda é exposta na Tabela 9. Percebe-se que o aumento do limiar de erro influenciou diretamente nos resultados

de PPL e PPQ. O índice PPL aumentou conforme aumentava-se o limiar de erro sem muita influência da variação da ROI, atingindo menor e maior valor respectivamente de 38,16% com limiar de erro 10 e 88,44% com limiar de erro de 20. Análogo ao PPL o PPQ obteve valores mínimo de 24,05% para limiar de erro 10 e máximo de 98,53% para limiar de erro 20. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações.

Tabela 9 - Dados de performace na identificação da faixa esquerda amostra 5

Parâmetros		Faixa à esquerda			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	12,0011	3,4840	38,16	24,05
100	15	12,0011	3,4840	75,17	80,94
100	20	12,0011	3,4840	88,37	98,53
120	10	11,9597	3,4741	38,66	24,05
120	15	11,9597	3,4741	75,37	80,94
120	20	11,9597	3,4741	88,44	98,53
140	10	11,9597	3,4741	38,66	24,05
140	15	11,9597	3,4741	75,37	80,94
140	20	11,9597	3,4741	88,44	98,53
150	10	11,9597	3,4741	38,66	24,05
150	15	11,9597	3,4741	75,37	80,94
150	20	11,9597	3,4741	88,44	98,53

Fonte: Autoria Própria

A análise da saída do algoritmo para a faixa direita é exposta na Tabela 10. Percebe-se que o aumento do limiar de erro e da ROI não tiveram influência nos índices de PPQ e PPL. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações. Neste caso a identificação e marcação das faixas foram realizados na borda interna sendo explícito tal comportamento do algoritmo pelos altos índices de PPL e PPQ em todos os valores de limiar de erro.

Tabela 10 - Dados de performace na identificação da faixa direita amostra 5

Parâmetros		Faixa à direita			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	2,5099	1,8766	92,88	100,00
100	15	2,5099	1,8766	93,19	100,00
100	20	2,5099	1,8766	93,19	100,00

120	10	2,5052	1,8696	92,93	100,00
120	15	2,5052	1,8696	93,23	100,00
120	20	2,5052	1,8696	93,23	100,00
140	10	2,5052	1,8696	92,93	100,00
140	15	2,5052	1,8696	93,23	100,00
140	20	2,5052	1,8696	93,23	100,00
150	10	2,5052	1,8696	92,93	100,00
150	15	2,5052	1,8696	93,23	100,00
150	20	2,5052	1,8696	93,23	100,00

Fonte: Autoria Própria

4.6 AMOSTRA 6

Esta amostra foi formada por 667 frames, a faixa da esquerda era simples segmentada branca, e a faixa da direita era simples contínua branca, em situação noturna (Figura 32).

A análise da saída do algoritmo para a faixa esquerda é exposta na Tabela 11. Percebe-se que o aumento do limiar de erro influenciou diretamente nos resultados de PPL e PPQ. Esses índices aumentaram conforme aumentava-se o limiar de erro sem muita influência da variação da ROI. Os valores menor e maior respectivamente foi de 58,95% com limiar de erro 10 e 95,16% com limiar de erro de 20. Análogo ao PPL o PPQ obteve valores mínimo de 51,70% para limiar de erro 10 e máximo de 100,00% para limiar de erro 20. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações. Pelos índices com limiar de erro 10 constata-se que em algumas situações a borda externa da faixa esquerda foi identificada.

Figura 32 – Resultado da amostra 6 em situação noturna



Fonte: Aatoria Própria

Tabela 11 - Dados de performance na identificação da faixa esquerda amostra 6

Parâmetros		Faixa à esquerda			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	9,9818	3,1343	58,95	51,70
100	15	9,9818	3,1343	89,01	91,95
100	20	9,9818	3,1343	95,11	100,00
120	10	9,9529	3,1238	59,30	51,70
120	15	9,9529	3,1238	89,12	91,95
120	20	9,9529	3,1238	95,16	100,00
140	10	9,9529	3,1238	59,30	51,70
140	15	9,9529	3,1238	89,12	91,95
140	20	9,9529	3,1238	95,16	100,00
150	10	9,9529	3,1238	59,30	51,70
150	15	9,9529	3,1238	89,12	91,95
150	20	9,9529	3,1238	95,16	100,00

Fonte: Aatoria Própria

A análise da saída do algoritmo para a faixa direita é exposta na Tabela 12. Percebe-se que o aumento do limiar de erro e da ROI não tiveram influência nos índices de PPQ e PPL. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações. Neste caso a identificação e marcação das faixas foram realizados na borda interna sendo explícito tal comportamento do algoritmo pelos altos índices de PPL e PPQ em todos os valores de limiar de erro.

Tabela 12 - Dados de performace na identificação da faixa direita amostra 6

Parâmetros		Faixa à direita			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	3,2530	2,2659	95,28	98,14
100	15	3,2530	2,2659	96,39	100,00
100	20	3,2530	2,2659	96,39	100,00
120	10	3,2480	2,2609	95,32	98,14
120	15	3,2480	2,2609	96,42	100,00
120	20	3,2480	2,2609	96,42	100,00
140	10	3,2480	2,2609	95,32	98,14
140	15	3,2480	2,2609	96,42	100,00
140	20	3,2480	2,2609	96,42	100,00
150	10	3,2480	2,2609	95,32	98,14
150	15	3,2480	2,2609	96,42	100,00
150	20	3,2480	2,2609	96,42	100,00

Fonte: Aatoria Própria

4.7 AMOSTRA 7

Esta amostra foi formada por 638 frames, a faixa da esquerda era dupla contínua amarela, e a faixa da direita era simples segmentada branca. Em situação noturna, com reflexo de faróis de veículos na faixa contrária e ruído de um veículo na frente (Figura 33).

A análise da saída do algoritmo para a faixa esquerda é exposta na Tabela 13. Percebe-se que o aumento do limiar de erro influenciou diretamente nos resultados de PPL e PPQ. Esses índices aumentaram conforme aumentava-se o limiar de erro sem muita influência da variação da ROI. Os valores de PPL menor e maior foram de 1,04% com limiar de erro 10 e 9,88% com limiar de erro de 20

respectivamente. Análogo ao PPL o PPQ obteve valores mínimo de 0,00% para limiar de erro 10 e máximo de 3,54% para limiar de erro 20. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações. Pelos baixos valores nota-se que o algoritmo não foi efetivo para a identificação da faixa esquerda devido ao ofuscamento dos faróis dos demais carros em sentido contrário.

Figura 33 – Resultado da amostra 7 em situação noturna, com reflexo de faróis de veículos na faixa contrária e ruído de um veículo na frente



Fonte: Autoria Própria

Tabela 13 - Dados de performance na identificação da faixa esquerda amostra 7

Parâmetros		Faixa à esquerda			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	43,3449	39,5670	1,04	0,00
100	15	43,3449	39,5670	3,62	1,53
100	20	43,3449	39,5670	9,63	3,50
120	10	43,1714	39,1869	1,10	0,00
120	15	43,1714	39,1869	3,72	1,53
120	20	43,1714	39,1869	9,88	3,50

140	10	43,1714	39,1869	1,10	0,00
140	15	43,1714	39,1869	3,72	1,53
140	20	43,1714	39,1869	9,88	3,50
150	10	43,1714	39,1869	1,10	0,00
150	15	43,1714	39,1869	3,72	1,53
150	20	43,1714	39,1869	9,88	3,50

Fonte: Aatoria Própria

A análise da saída do algoritmo para a faixa direita é exposta na Tabela 14. Percebe-se que o aumento do limiar de erro aumentou os índices PPL e PPQ. Os valores menor e maior de PPL foram de 23,49% para limiar de erro de 10 e de 26,18% para limiar de erro de 20. Análogo ao PPL o PPQ obteve valores mínimo de 80,61% para limiar de erro 10 e máximo de 94,55% para limiar de erro 20. Para todas as análises o DAM e DP se mantiveram estáveis com poucas variações. Neste caso não houve a influência do ofuscamento dos faróis possibilitando a correta identificação das faixas do lado direito da imagem.

Tabela 14 - Dados de performace na identificação da faixa direita amostra 7

Parâmetros		Faixa à direita			
ROI (pixels)	Limiar (pixels)	DAM (pixels)	DP (pixels)	PPL (%)	PPQ (%)
100	10	5,7709	5,5682	23,50	80,61
100	15	5,7709	5,5682	25,33	91,52
100	20	5,7709	5,5682	26,18	94,55
120	10	5,7745	5,5698	23,49	80,61
120	15	5,7745	5,5698	25,32	91,52
120	20	5,7745	5,5698	26,18	94,55
140	10	5,7745	5,5698	23,49	80,61
140	15	5,7745	5,5698	25,32	91,52
140	20	5,7745	5,5698	26,18	94,55
150	10	5,7745	5,5698	23,49	80,61
150	15	5,7745	5,5698	25,32	91,52
150	20	5,7745	5,5698	26,18	94,55

Fonte: Aatoria Própria

5 CONCLUSÃO

Em um futuro próximo as funções de auxílio ao motorista deixarão de ser questão de diferenciação tecnológica e comercial e serão requisitos básicos em veículos rodoviários. Com o aumento de confiabilidade dos sistemas automotivos, e segurança de condutores e terceiros, é eminente a redução de acidentes e ocorrências rodoviárias, conseqüentemente, a redução de desgastes emocionais e financeiros a todos os indivíduos ligados direta ou indiretamente aos processos de logística rodoviária.

Deste modo necessita-se de uma metodologia de desenvolvimento de funções automotivas de auxílio ao motorista que acompanhe a evolução dos sistemas elétrico e eletrônicos e que seja compatível para com os sistemas atuais, para a realização de possíveis transições tecnológicas. Ao mesmo tempo que essa metodologia seja capaz de assegurar segurança e confiabilidade dos sistemas desenvolvidos.

Assim a metodologia baseada em modelos aplicada para o reconhecimento de faixas com LDW se mostrou eficiente, pois possibilitou a aplicação de conceitos matemáticos estatísticos e de visão computacional juntamente com as bases automobilísticas (protocolos e estruturas veiculares) já firmadas, garantindo integração dos sistemas e fluidez no processo de desenvolvimento. Os testes primários de simulações constantes realizados, foram capazes de alterações no código que possibilitaram a otimização de etapas e correções de anormalidades em seu funcionamento. Tal processo de testes possibilitou a redução do dispêndio de tempo de desenvolvimento e em ambiente industrial resultaria em redução do custo de desenvolvimento.

O desenvolvimento baseado em modelo possibilitou o desenvolvimento da função ADAS para identificação de faixas com LDW com a utilização de técnicas de visão computacional e programação. E através das amostras utilizadas obteve-se resultados satisfatórios mesmo com baixo desempenho em situações de ofuscamento. Os resultados dos testes em 4261 frames obtiveram índices altos na identificação e rastreamento das faixas, em alguns cenários a PPQ chegou a 100% e PPL a 97,09%.

Para trabalhos futuros sugere-se melhorias do algoritmo para o aumento de robustez para com ruídos originados de demais veículos na pista, e adequar o

rastreamento e marcação das faixas apenas nas bordas internas para garantir a compatibilidade para com o método de *ground-truth*. A liberdade desse ajustes e parametrizações é garantida pela metodologia baseada em modelos que segue as primícias de verificações constantes e alterações no código e/ou lógica quando estas forem convenientes e/ou necessárias.

REFERÊNCIAS

AARENSTRUP, ROGER. **Managing Model-Based Design**. Natick: The MathWorks, Inc, 2015.

ANDRADE, DAVID CARVALHO. **Estratégia para Detecção e Rastreamento de Faixas Rodoviárias Utilizando uma Câmera Monocular**. 2017.97f. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2017.

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.

BEYELER, M.; MIRUS, F.; VERL, A. **Vision-Based Robust Road Lane Detection in Urban Environments**. IEEE International Conference on Robotics & Automation (ICRA). 31 mai. a 7 jun. 2014, Hong Kong, China.

BORKAR, A.; HAYES, M.; SMITH, M. T. **Robust Lane Detection and Tracking with Ransac and Kalman Filter**. 16th IEEE International Conference on Image Processing (ICIP), 2009.

CONTRAN. **RESOLUÇÃO Nº 311, DE 03 DE ABRIL DE 2009**. 2009. Disponível em: <http://www.denatran.gov.br/download/Resolucoes/RESOLUCAO_CONTRAN_311_09.pdf>. Acesso em: 08 ago. 2017.

CONTRAN. **RESOLUÇÃO Nº 312, DE 03 DE ABRIL DE 2009**. 2009. Disponível em: <http://www.denatran.gov.br/download/Resolucoes/RESOLUCAO_CONTRAN_312_09.pdf>. Acesso em: 08 ago. 2017.

FANGFANG, X.; WANG, B.; ZHOU, Z; ZHENG, Z. **Real-Time Lane Detection for Intelligent Vehicles Based on Monocular Vision**. Proceedings of the 31st Chinese Control Conference. 25-27 July, 2012, Hefei, China.

FISCHLER, M. A.; BOLLES, R. C. **Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography**. SRI International, v. 24, n. 6, p. 381-395, jun. 1981.

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

GUO, J.; WEI, Z.; MIAO, D. **Lane Detection Method Based on Improved RANSAC Algorithm**. IEEE Twelfth International Symposium on Autonomous Decentralized Systems. 25 mar. a 27mar. 2015, Taichung, Taiwan.

HEKIMOGLU, S.; ERENOGLU, R. C.; KALINA, J. Outlier detection by means of robust regression estimators for use in engineering science. **Journal of Zhejiang University-SCIENCE A**, v. 10, n. 6, p. 909–921, jun. 2009.

IBGE. **Logística dos Transportes no Brasil**. 2014. Disponível em: <<http://www.ibge.gov.br/home/presidencia/noticias/imprensa/ppts/00000019704411122014440525174699.pdf>>. Acesso em: 08 ago. 2017.

JUNG, C. R.; KELBER, C. R. **A Lane Departure Warning System based on a Linear-Parabolic Lane Model**. IEEE Intelligent Vehicles Symposium. University of Panama. Parma, Italy June 14-17, 2004.

KANG, J.; KIM, J.; LEE, M. **Advanced Driver Assistant System Based on Monocular Camera**. IEEE American Control Conference (ACC). Boston, MA, USA. 6-8 Jul, 2016.

LI, Y.; GANS, N. R. **Predictive-RANSAC: An effective data fitting and tracking method with application in curve tracking in video**. IEEE International Conference on Consumer Electronics (ICCE). Las Vegas, NV, USA. 10-13 Jan, 2014.

NEME, J. H. Z. **Aplicação do Método de Desenvolvimento Baseado em Modelos para Função de Software Automotivo: Sistema de Iluminação Externa**. Trabalho de Conclusão de Curso. Engenharia Eletrônica –EE. Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2014.

NTSB. **The Use of Forward Collision Avoidance Systems to Prevent and Mitigate Rear-End Crashes**. Washington, D.C.: 2015. Disponível em: <<https://www.nts.gov/safety/safety-studies/Documents/SIR1501.pdf>>. Acesso em: 30 maio. 2017.

SILVA, RODRIGO ADAMSHUK. **Método de Mapeamento por Perspectiva Inversa Aplicado à Determinação da Distância de Objetos em Sistemas Avançados de Assistência ao Condutor**. 2017.109f. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2017.

STELLA, G. N. D. **Aplicando a Metodologia de Desenvolvimento Baseado em Modelos para Funções de Software Automotivo**. 2015.123f. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2015.

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

XU, S.; YE, P.; HAN, S.; SUN, H.; JIA, Q. **Road Lane Modeling based on RANSAC Algorithm and Hyperbolic Model**. IEEE 3rd International Conference on System and Informatics (ICSAI). 19-21 nov. 2016, Shanghai, China.

ZHU, S.; WANG, J.; YU, T.; WANG, J. **A Method of Lane Detection and Tracking for Expressway Based on RANSAC**. IEEE 2nd International Conference on Image, Vision and Computing (ICIVC). 2-4 jun. 2017. Chengdu, China.