



INSTITUTO TECNOLÓGICO VALE



**Programa de Pós-Graduação em Instrumentação, Controle e  
Automação de Processos de Mineração – PROFICAM  
Universidade Federal De Ouro Preto - Escola de Minas  
Associação Instituto Tecnológico Vale**

**Dissertação**

**IDENTIFICAÇÃO DE ESTRADAS PARA DIREÇÃO ASSISTIDA DE  
CAMINHÕES OPERANDO EM CONDIÇÕES CLIMÁTICAS  
ADVERSAS NO AMBIENTE DA MINERAÇÃO**

**Gilberto Domingues de Resende**

**Ouro Preto  
Minas Gerais, Brasil  
2018**

Mestrado Profissional em Instrumentação, Controle e Automação de Processos de  
Mineração - PROFICAM

IDENTIFICAÇÃO DE ESTRADAS PARA DIREÇÃO ASSISTIDA DE CAMINHÕES  
OPERANDO EM CONDIÇÕES CLIMÁTICAS ADVERSAS NO AMBIENTE DA  
MINERAÇÃO

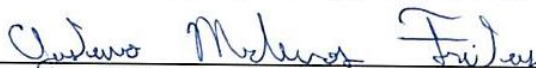
Autor: Gilberto Domingues de Resende

Dissertação defendida e aprovada em 27 de setembro de 2018 pela banca  
examinadora constituída pelos professores:




---

D.Sc. Andrea Gomes Campos Bianchi  
Orientadora – Universidade Federal de Ouro Preto (UFOP)



---

D.Sc. Gustavo Medeiros Freitas  
Coorientador – Universidade Federal de Minas Gerais (UFMG)



---

D.Sc. Gustavo Pessin  
Membro interno – Instituto Tecnológico Vale (ITV)

---

D.Sc. Ana Cláudia da Silva Gomes  
Membro externo – Instituto SENAI de Inovação em Tecnologias Minerais  
(Participação por videoconferência)

**Gilberto Domingues de Resende**

**IDENTIFICAÇÃO DE ESTRADAS PARA DIREÇÃO ASSISTIDA DE  
CAMINHÕES OPERANDO EM CONDIÇÕES CLIMÁTICAS  
ADVERSAS NO AMBIENTE DA MINERAÇÃO**

Dissertação apresentada ao curso de Mestrado Profissional em Instrumentação, Controle e Automação de Processos de Mineração da Universidade Federal de Ouro Preto e do Instituto Tecnológico Vale, como requisito para obtenção do título de Mestre em Engenharia de Controle e Automação.

Orientadora: Prof<sup>a</sup>. Andrea G. C. Bianchi, D. Sc.

Co-orientador: Prof. Gustavo M. Freitas, D. Sc.

Ouro Preto

2018

R433i      Resende, Gilberto Domingues de.  
Identificação de estradas para direção assistida de caminhões operando em condições climáticas adversas no ambiente da mineração [manuscrito] / Gilberto Domingues de Resende. - 2018.  
149f.: il.: color; grafs; tabs.

Orientadora: Profª. Drª. Andrea Campos Bianchi.  
Coorientador: Prof. Dr. Gustavo Medeiros Freitas.

Dissertação (Mestrado) - Universidade Federal de Ouro Preto. Escola de Minas. Departamento de Engenharia de Controle e Automação e Técnicas Fundamentais. Programa de Pós Graduação em Instrumentação, Controle e Automação de Processos de Mineração.  
Área de Concentração: Engenharia de Controle e Automação de Processos Minerais.

1. Condições climáticas adversas. 2. Processamento de imagens. 3. Ponto de fuga. 4. Detecção de limites de estradas. 5. Segmentação de imagens.. I. Bianchi, Andrea Campos . II. Freitas, Gustavo Medeiros. III. Universidade Federal de Ouro Preto. IV. Título.

Catálogo: [www.sisbin.ufop.br](http://www.sisbin.ufop.br)

CDU: 681.5:622.2

## DEDICATÓRIA

À minha esposa, pelo apoio incondicional, aos meus pais pelo incentivo rotineiro, à minha irmã por estar sempre ao meu lado e aos meus avôs e avós, “*in memoriam*”, pelo carinho e ensinamentos.

## **AGRADECIMENTOS**

Início meus agradecimentos a Deus, que através de sua força grandiosa possibilitou a superação de vários desafios para a conclusão dessa dissertação.

Agradeço meus pais, José Geraldo e Maria Auxiliadora, pelo apoio que me deram desde criança, proporcionando-me acesso a um estudo de qualidade e fazendo sacrifícios que colaboraram para a realização desse sonho. Não posso deixar de dizer muito obrigado a minha irmã Marina pela companhia e conselhos.

Igualmente agradeço a minha esposa Marcela que sempre esteve ao meu lado, incentivando-me nas horas difíceis da pesquisa, corrigindo meus erros, cobrando foco e dedicação. O amor demonstrado por ela foi essencial, trazendo-me felicidade pessoal e de alguma forma o término dessa dissertação é uma retribuição a esse apoio.

Agradeço aos professores e funcionários da Universidade Federal de Ouro Preto e Instituto Tecnológico Vale pelos serviços prestados e pelo ensino de alta qualidade ministrado, que contribuíram para minha formação pessoal e profissional. Em especial, agradeço aos meus coordenadores Andrea Bianchi e Gustavo Freitas, pela seleção desse tema desafiador que me possibilitou adquirir conhecimentos em uma área em que eu era praticamente leigo e ao apoio e orientação prestados ao longo da pesquisa.

Externo minha gratidão a FAPEMIG (Fundação de Amparo à Pesquisa de Minas Gerais), por fomentar a pesquisa e inovação no estado de Minas Gerais, o que colaborou para a execução desse trabalho.

Não posso deixar de agradecer imensamente ao meu antigo gerente Paulo Henrique Novais por possibilitar a minha inscrição nesse mestrado, sempre incentivando meu crescimento profissional e consequentemente pessoal. Obrigado Luciano de Biasi, por permitir a continuidade dos meus estudos.

Por fim, agradeço aos colegas de mestrado pela dedicação e companheirismo nos momentos de estudo.

“Quem nunca errou nunca experimentou nada novo.”

Albert Einstein

## RESUMO

Os processos de transporte de minério, realizado por caminhões fora de estrada, estão sujeitos, constantemente, a condições climáticas adversas, como neblina, chuva intensa e poeira, que impedem a operação segura no ambiente da mineração. Nesse sentido, a criação de um sistema de direção assistida, que auxilie os operadores nessas condições, é de grande valia para melhorar a utilização desses equipamentos. Essa pesquisa aplicada visa colaborar na implantação desse sistema, desenvolvendo códigos de processamento de imagens, no software Matlab, que realizam a fusão de imagens RGB e térmica visando criar uma imagem combinada, que contribui na identificação da cena contida em um ambiente de mineração sob condições climáticas adversas. A fusão das imagens é realizada utilizando a técnica *Alpha Compositing*, pela combinação da cor translúcida do primeiro plano com uma cor de fundo, produzindo assim uma nova cor combinada que é armazenada em um novo canal de cores. Além da fusão das imagens, os códigos identificam o ponto de fuga das estradas e seus limites, para posteriormente segmentar a imagem e identificar a área transitável pelos caminhões que operam no ambiente da mineração. O ponto de fuga é identificado através do cálculo do valor esperado da amostra de pontos definidos pelas interseções das bordas retas identificadas nas imagens. A área transitável é identificada por técnica que une, através de uma média ponderada, quatro métodos distintos, sendo eles: segmentação por *superpixel*, limiar de histogramas de cores, triângulo do ponto de fuga e distribuição normal multivariada. Após a definição do algoritmo para segmentação da área transitável da estrada em imagens é possível trabalhar com vídeos processando cada quadro (*frame*) individualmente, o que simula a situação operacional real dos caminhões. Os resultados alcançados demonstram que a fusão de imagens obteve resultados 26% melhores se comparado ao processamento individual de imagens RGB e térmicas e foi possível identificar corretamente a estrada em mais de 65% das imagens e quadros de vídeos. Espera-se, ao final da implantação de um sistema como esse, melhorar a segurança operacional e aumentar a produtividade, indicadores almejados por todas as mineradoras.

**Palavras-chave:** condições climáticas adversas, processamento de imagens, ponto de fuga, detecção de limites de estradas, segmentação de imagens.



## ABSTRACT

The ore transport process, executed by haul trucks, are constantly subject to adverse weather conditions, such as fog, heavy rain and dust, which hamper safety operation of trucks in mining environments. In this sense, the creation of a power assisted steering system that helps the operators in these conditions is of great value to improve the usage of these equipment. This applied research aims to collaborate in the implantation of this system, developing image processing codes in Matlab software, which perform the fusion of RGB and thermal images aiming to create a combined image, which contributes to the identification of the scene contained in a mining environment under adverse weather conditions. The images are merged using the Alpha Compositing method, by combining the translucent foreground color with a background color, thus producing a combined color that is stored in a new color channel. In addition to the images fusion, the codes identify the vanishing point of the roads and their limits, to later segment the image and identify the drivable area that can be used by haul trucks operating in the mining environment. The vanishing point is identified by calculating the mean value of the sample points defined by the intersections of the straight edges identified in the images. The drivable area is identified by a technique that join, through a weighted average, four distinct methods: superpixel segmentation, color histogram threshold, vanishing point triangle and multivariate normal distribution. After defining the algorithm for segmentation of the drivable area of the road into images, it is possible to work with videos processing each frame individually, which simulates the actual operational situation of the trucks. The results show that image fusion achieved results 26% better compared to images RGB and thermals processed apart and it was possible to correctly identify the road in more than 65% of the images and video frames. At the end of the implementation of such a system, an improvement on operational safety and an increase in productivity are expected, which are indicators targeted by all mining companies.

**Keywords:** adverse weather conditions, image-processing, vanishing point, detection of road borders, image segmentation.

## LISTA DE FIGURAS

Figura 1 - Visão do operador de caminhão em condições climáticas adversas .....	17
Figura 2 - Imagem RGB (esquerda) e térmica (direita) de um caminhão .....	19
Figura 3 - Modelo padrão de custos operacionais de uma mina a céu aberto. ....	21
Figura 4 - Representação do Diagrama $L^*a^*b^*$ .....	28
Figura 5 - Exemplo de fusão de imagens utilizando a operação "A over B" .....	30
Figura 6 - Exemplo de divisão de áreas para cálculo de diferença de textura de cores.....	38
Figura 7 - Identificação de regiões para aplicação do algoritmo de Distribuição Normal Multivariada.....	43
Figura 8 – Câmeras e estrutura utilizadas para investigação do ambiente .....	48
Figura 9 - Diagrama de montagem da infraestrutura móvel para testes de câmeras	50
Figura 10 - Teste diurno, filmando dois veículos transitando numa estrada na mina Carajás .....	52
Figura 11 - Teste diurno, filmando pessoas e veículos transitando numa ladeira na cidade de Ouro Preto.....	52
Figura 12 - Teste noturno com iluminação externa, filmando estrada, leira e pontalete na mina de Fábrica .....	53
Figura 13 - Teste noturno sem iluminação externa, filmando estrada, leira e pontalete na mina de Fábrica .....	53
Figura 14 - Teste noturno filmando dois caminhões transitando na mina de Fábrica	54
Figura 15 - Teste noturno filmando dois caminhões transitando na mina Fazendão	54
Figura 16 - Teste noturno filmando três caminhões e uma escavadeira operando na mina do Salobo .....	54
Figura 17 - Teste filmando estrada, leira, pontaletes e um veículo localizado a 200m, se locomovendo em direção às câmeras, na mina de Fábrica .....	55
Figura 18 - Teste noturno filmando estrada, leira e pontaletes na mina de Fábrica ..	55
Figura 19 - Teste noturno filmando leira, pontaletes e uma pessoa na mina de Carajás .....	56
Figura 20 - Teste noturno com presença de poeira, filmando estrada, leiras e pontalete na mina de Fábrica .....	56
Figura 21 - Teste noturno com presença de poeira, filmando um caminhão localizado a 40m, na mina de Carajás.....	56
Figura 22 - Teste noturno com presença de poeira, filmando um caminhão localizado a 29m, na mina Fazendão .....	57
Figura 23 - Teste noturno com presença de neblina, filmando um veículo localizado a 20m, na mina de Brucutu.....	57
Figura 24 - Teste noturno com presença de neblina, filmando uma pessoa localizada a 10m e um veículo localizado a 40m, na mina de Brucutu .....	58
Figura 25 - Teste noturno com presença de neblina, filmando duas pessoas e um veículo localizados a 30m, na mina de Brucutu .....	58
Figura 26 - Teste noturno com presença de jato d'água, filmando uma escavadeira e um caminhão, na mina do Salobo .....	59

Figura 27 - Teste noturno com presença de jato d'água, filmando um caminhão e um veículo batedor, na mina Carajás .....	60
Figura 28 - Etapas do método para processamento de imagens .....	61
Figura 29 - Algoritmo de adequação do tamanho das imagens .....	64
Figura 30 - Imagem original (esq.), imagem filtrada para retirada de ruído (dir.) .....	65
Figura 31 - Fluxo do processo de desenvolvimento do algoritmo de processamento de imagens .....	67
Figura 32 - Algoritmo final utilizado para detecção do ponto de fuga .....	68
Figura 33 - Algoritmo final utilizado para segmentação da região de interesse da estrada .....	69
Figura 34 - Exemplo de aplicação da função <i>bwmorph</i> com o parâmetro <i>skel</i> . .....	72
Figura 35 - Imagens RGB (esq.), Térmica (centro) e após fusão (dir.) .....	77
Figura 36 - Algoritmo de Votação local e flexível baseada no Filtro de Gabor .....	78
Figura 37 - Algoritmo de Detecção de ponto de fuga por método rápido e preciso...80	
Figura 38 - Algoritmo de métodos baseados em identificação de bordas e aplicação de coerência de orientação de métodos baseados em textura .....	82
Figura 39 - Classificador baseado em Gabor Filter utilizando <i>kmeans</i> .....	84
Figura 40 - Regiões de interesse após aplicação do algoritmo SUPP .....	86
Figura 41 - Algoritmo segmentação por <i>superpixel</i> .....	87
Figura 42 - Algoritmo de segmentação por limiar de histograma .....	88
Figura 43 - Algoritmo triângulo do ponto de fuga .....	89
Figura 44 - Algoritmo distribuição normal multivariada .....	89
Figura 45 - Resultado de identificação de área de estrada (base de imagens internet e autores) .....	90
Figura 46 - Resultado de identificação de área de estrada (base de imagens minas Vale) .....	90
Figura 47 - Resultados das técnicas fundamentais .....	98
Figura 48 - Resultados das técnicas fundamentais (continuação). .....	99
Figura 49 - Quadro de vídeo câmera RGB (esquerda.); câmera termográfica (meio); após fusão (direita) .....	103
Figura 50 - Quadro de vídeo câmera RGB (esquerda); câmera termográfica (meio); após fusão (direita) .....	103
Figura 51 - Resultados de quadros aleatórios de vídeos demonstrando a região identificada como área dirigível das estradas. ....	107
Figura 52 - Exemplos de imagem de baixa qualidade da base de imagens Vale ...	109
Figura 53 - Resultados algoritmo MATL .....	116
Figura 54 - Resultados algoritmo MATL (continuação) .....	117
Figura 55 - Resultados algoritmo MATL (continuação) .....	118
Figura 56 - Resultados algoritmo MATL (continuação) .....	119
Figura 57 - Resultados algoritmo MATL (continuação) .....	120
Figura 58 - Resultado localização ponto de fuga algoritmo LASV (A1;B1;C1) .....	121
Figura 59 - Resultado localização ponto de fuga algoritmo LASV (A2;B2;C2) .....	122
Figura 60 - Resultado localização ponto de fuga algoritmo LASV (A3;B3;C3) .....	123
Figura 61 - Resultado localização ponto de fuga algoritmo LASV (A4;B4;C4) .....	124

Figura 62 - Resultado localização ponto de fuga algoritmo LASV (D1;E1;F1) .....	125
Figura 63 - Resultado localização ponto de fuga algoritmo LASV (D2;E2;F2) .....	126
Figura 64 - Resultado localização ponto de fuga algoritmo LASV (D3;E3;F3) .....	127
Figura 65 - Resultado localização ponto de fuga algoritmo LASV (D4;E4;F4) .....	128
Figura 66 - Resultado localização ponto de fuga algoritmo FAVP (A5;B5;C5).....	129
Figura 67 - Resultado localização ponto de fuga algoritmo FAVP (A6;B6;C6).....	130
Figura 68 - Resultado localização ponto de fuga algoritmo FAVP (A7;B7;C7).....	131
Figura 69 - Resultado localização ponto de fuga algoritmo FAVP (A8;B8;C8).....	132
Figura 70 - Resultado localização ponto de fuga algoritmo FAVP (D5;E5;F5) .....	133
Figura 71 - Resultado localização ponto de fuga algoritmo FAVP (D6;E6;F6) .....	134
Figura 72 - Resultado localização ponto de fuga algoritmo FAVP (D7;E7;F7) .....	135
Figura 73 - Resultado localização ponto de fuga algoritmo FAVP (D8;E8;F8) .....	136
Figura 74 - Resultados EBMO (A9;B9;C9) .....	137
Figura 75 - Resultados EBMO (A10;B10;C10) .....	138
Figura 76 - Resultados EBMO (A11;B11;C11) .....	139
Figura 77 - Resultados EBMO (A12;B12;C12) .....	140
Figura 78 - Resultados EBMO (D9;E9;F9) .....	141
Figura 79 - Resultados EBMO (D10;E10;F10) .....	142
Figura 80 - Resultados EBMO (D11;E11;F11) .....	143
Figura 81 - Resultados EBMO (D12;E12;F12) .....	144
Figura 82 - Resultado de identificação de área de estrada (base de imagens internet e autores).....	145
Figura 83 - Resultado de identificação de área de estrada (base de imagens internet e autores).....	146
Figura 84 - Resultado de identificação de área de estrada (base de imagens internet e autores).....	147
Figura 85 - Resultado de identificação de área de estrada (base de imagens internet e autores).....	148
Figura 86 - Resultado de identificação de área de estrada (base de imagens minas Vale) .....	149

## LISTA DE GRÁFICOS

Gráfico 1 - Perfil de perdas médias anuais nos períodos secos e chuvosos nas minas da Vale, por condições adversas de clima .....	20
Gráfico 2 - Número de acidentes e quase acidentes, por severidade, devido a condições climáticas e manobras (período: janeiro de 2017 a abril de 2018) ....	22
Gráfico 3 - Resultados do cálculo da área da estrada.....	92
Gráfico 4 - Resultados da média de resultados entre imagens para distância do ponto de fuga e medição da área da estrada encontrada.....	92
Gráfico 5 - Resultados do cálculo da distância do ponto de fuga calculado em relação ao real para base de imagens da internet.....	94
Gráfico 6 - Resultados do cálculo da distância do ponto de fuga calculado em relação ao real para base de imagens das minas da Vale. ....	95
Gráfico 7 - Resultado de desempenho de identificação de área da estrada de imagens da internet .....	95
Gráfico 8 - Resultado de desempenho de identificação de área da estrada das imagens das minas da Vale.....	96

## LISTA DE TABELAS

Tabela 1 - Algoritmos e etapas para apresentação de resultados .....	76
Tabela 2 - Resultados de localização ponto de fuga.....	94
Tabela 3 - Resultados de desempenho da fusão das imagens.....	103
Tabela 4 - Resultados de desempenho para detecção do ponto de fuga .....	104
Tabela 5 - Resultados de desempenho para identificação da área dirigível da estrada .....	107

## LISTA DE SIGLAS E ABREVIATURAS

**BMP** - Formato de imagem Bitmap (mapa de bits)

**CIE** - *Commission Internationale de l'Eclairage*

**EBMO** - *Edge-based method and the orientation coherence concept* (método baseado em bordas e no conceito de coerência de orientação)

**ELTO** - *Extraction-Locally Texture Orientation* (extração local de orientação de textura)

**FAVP** - *Fast and Accurate Vanishing Point Detection* (rápida e precisa detecção do ponto de fuga)

**GPS** - *Global Positioning System* (sistema de posicionamento global)

**HSV** - *Hue* (matiz), *Saturation* (saturação) e *Value* (valor)

**ITV** - Instituto Tecnológico Vale

**JPG** - *Joint Photographic Group*

**LASV** - *Locally Adaptive Soft-Voting* (votação suave e localmente adaptativa)

**MATL** - Abreviação de Matlab

**OCR** - *Orientation Consistency Ratio* (razão de consistência da orientação)

**PCA** - *Principal Component Analysis* (análise de componente principal)

**PIMS** - *Process Information Management System* (sistema de gerenciamento da informação de processo produtivo)

**PROB** - Abreviação de probabilidade

**PTZ** - *Pan-Tilt-Zoom* (movimentos horizontal, vertical e de aproximação de câmeras)

**RGB** - Vermelho (*Red*), Verde (*Green*) e Azul (*Blue*)

**SAP** - Sistema integrado de gestão empresarial

**SUPP** - Abreviação de *superpixel*

**SVM** - *Support Vector Machines* (vetor de suporte à movimentação de máquinas)

**TIFF** - *Tagged Image File Format* (formato de arquivo para imagens digitais)

**UAV** - *Unmanned Aerial Vehicle* (veículo aéreo não tripulado)

## SUMÁRIO

1.	INTRODUÇÃO.....	17
1.1	Motivação .....	20
1.2	Objetivos.....	23
1.3	Organização da Dissertação.....	23
2.	REFERENCIAL TEÓRICO E FUNDAMENTAÇÃO CIENTÍFICA.....	24
2.1	Sensores utilizados em veículos autônomos .....	24
2.2	Fusão de Imagens .....	29
2.3	Deteção do ponto de fuga.....	31
2.3.1	Votação local e flexível baseada no Filtro de Gabor .....	32
2.3.2	Extração de orientação de textura local, criação de mapa de bordas e definição do ponto de fuga através de uma função de votação customizada.....	35
2.3.3	Deteção do ponto de fuga através de método rápido e preciso .....	36
2.3.4	Métodos utilizando identificação de bordas e aplicação de coerência de orientação baseados em textura.....	37
2.4	Segmentação da área das estradas .....	39
2.4.1	Mapa de texturas e aplicação de padrões na imagem.....	40
2.4.2	Votação local e flexível baseada no Filtro de Gabor .....	41
2.4.3	Utilização da técnica de <i>superpixels</i> .....	42
2.4.4	Utilização de distribuições normal multivariada para os canais de cores ..	43
2.5	Aquisição de vários quadros ( <i>frames</i> ).....	45
3.	MATERIAIS E METODOLOGIA .....	46
3.1	Investigação do ambiente de mineração através de teste com câmeras para geração de base de dados .....	46
3.1.1	Infraestrutura móvel para aquisição de vídeos .....	47
3.1.2	Locais de execução dos testes.....	50

3.1.3 Descrição dos vídeos dos testes e inferências sobre a diferença de percepção das cenas com imagens RGB e térmica .....	51
3.2 Metodologia .....	60
3.2.1 Definição da base de dados ( <i>dataset</i> ) de imagens existentes.....	61
3.2.2 Aquisição de imagens.....	63
3.2.3 Pré-processamento de imagens .....	65
3.2.4 Fusão das imagens.....	66
3.2.5 Processamento das imagens.....	66
3.2.6 Aquisição de vários quadros ( <i>frames</i> ).....	75
4. IMPLEMENTAÇÕES REALIZADAS E RESULTADOS OBTIDOS .....	76
4.1 Fusão de imagens .....	77
4.2 Detecção do ponto de fuga.....	77
4.2.1 Votação local e flexível baseada no Filtro de Gabor ( <i>Gabor-based LASV - Locally Adaptive Soft-Voting</i> ).....	78
4.2.2 Detecção do ponto de fuga através de método rápido e preciso ( <i>Fast and Accurate Vanishing Point Detection - FAVP</i> ) .....	80
4.2.3 Métodos baseados em identificação de bordas e aplicação de coerência de orientação de métodos baseados em textura ( <i>Edge-based methods and the orientation coherence concept - EBMO</i> ) .....	81
4.3 Segmentação da área da estrada.....	83
4.3.1 Classificador baseado em Gabor Filter utilizando <i>kmeans</i> ( <i>Gabor-based classified using kmeans</i> ) .....	84
4.3.2 Segmentação utilizando <i>superpixels</i> .....	85
4.4 Algoritmo final implementado para segmentação da área da estrada .....	86
4.5 Apresentação dos resultados .....	91
4.5.1 Resultados de desempenho da fusão de imagens .....	91



4.5.2 Resultados comparativos entre os métodos selecionados para detecção do ponto de fuga .....	93
4.5.3 Resultados para segmentação da área da estrada.....	95
5. DISCUSSÕES DOS RESULTADOS .....	101
5.1 Fusão de imagens RGB e térmica para facilitar a identificação da área dirigível das estradas .....	102
5.2 Detecção do ponto de fuga das estradas .....	104
5.3 Identificação da área da estrada e segmentação da imagem.....	104
5.3.1 Segmentação por cores utilizando <i>superpixel</i> .....	104
5.3.2 Limiar de histograma de cores.....	105
5.3.3 Triângulo do ponto de fuga .....	105
5.3.4 Distribuição normal multivariada .....	105
5.3.5 Ajustes finais nas imagens processadas .....	106
6. CONCLUSÃO .....	108
6.1. Principais contribuições da dissertação .....	110
6.2 Trabalhos futuros.....	111
7. REFERÊNCIAS BIBLIOGRÁFICAS .....	113
ANEXO A – Resultados algoritmo MATL .....	116
ANEXO B – Resultados algoritmo LASV.....	121
ANEXO C – Resultados algoritmo <i>Fast Vanishing Point Detection</i> .....	129
ANEXO D – Resultados algoritmo EBMO .....	137
ANEXO E – Resultados detecção da área da estrada usando quatro técnicas fundamentais.....	145

## 1. INTRODUÇÃO

No cenário da mineração, durante os últimos anos, vem sendo desenvolvidas soluções para a operação de caminhões em condições climáticas adversas. A maior parte dos acidentes envolvendo direção de veículos ocorre por falha humana (BELLINO; MENESES; JACOT, 2005). Os riscos aumentam consideravelmente em condições climáticas adversas, na presença de chuva, neblina e poeira (PISANO; GOODWIN; ROSSETTI, 2008), correspondendo a um entrave crítico no desenvolvimento de processos e sistemas para o aumento de segurança e produtividade de caminhões que operam em ambientes de mineração.

A neblina é um contratempo na produtividade porque reduz a visibilidade dos operadores e gera uma condição insegura para a operação. A Figura 1 evidencia a condição operacional em um ambiente de mineração. A visibilidade de outros caminhões, veículos e pessoas é muito prejudicada pela neblina.



**Figura 1** - Visão do operador de caminhão em condições climáticas adversas

Fonte: FREITAS; ZANETTI; MIOLA (2015)

O desenvolvimento de um sistema que auxilie a operação de caminhões em condições climáticas, conforme exposto na Figura 1, é de grande valia, pois, normalmente, os equipamentos interrompem suas operações por questões de falta de segurança. Se o sistema possibilitasse a identificação da estrada, mesmo nessas condições climáticas, os equipamentos poderiam continuar a operação, aumentando a produtividade.

Nas últimas décadas, muitos algoritmos surgiram como componentes de sistemas de navegação autônoma de veículos. A grande maioria desses algoritmos, que vêm demonstrando melhores resultados, são baseados em processamento de imagens de câmeras embarcadas nesses veículos. As primeiras abordagens utilizavam veículos autônomos que se moviam em estradas pavimentadas, tentando encontrar os limites da via e cruzamentos (CRISMAN; THORPE, 1993). Recentemente, muitos algoritmos vêm sendo desenvolvidos para lidar com estradas não pavimentadas, características da mineração, sendo esses preconizados por aquele desenvolvido por Rasmussen (2004).

O processamento de imagens vem se mostrando uma ferramenta poderosa e ganhando popularidade na criação de algoritmos de identificação de estradas. Uma técnica muito utilizada, primeiramente, encontra o ponto de fuga da estrada, que determina a direção em que o veículo deve seguir e, posteriormente, encontra os limites da estrada, para finalmente aplicar a segmentação da área trafegável (KONG; AUDIBERT; PONCE, 2010).

Para encontrar os limites da estrada, os algoritmos recentemente desenvolvidos apresentam diversas técnicas. Alguns procuram detectar diferenças de cores relacionadas com a orientação de textura (KONG; AUDIBERT; PONCE, 2010); outros aplicam técnicas de *superpixel* combinadas a modelos gaussianos (WANG, *et al.* 2014). Estudos utilizando detecção de bordas (NGUYEN; PHUNG; BOUZERDOUM, 2016) tiveram sucesso principalmente com estradas pavimentadas. Xia, *et al.* (2016) apresentam um método para estradas não pavimentadas utilizando a transformada Hough<sup>1</sup>.

Essa pesquisa apresenta uma técnica, adaptada para estradas não pavimentadas, que encontra a área da estrada, utilizando uma combinação de algoritmos de detecção de bordas, transformada Hough, *superpixel* e estatística. A detecção de bordas e transformada Hough é utilizada para definir o ponto de fuga através do ponto de encontro das linhas retas obtidas por esse método. A área da estrada é encontrada pela união de métodos como *superpixel* e probabilísticos que avaliam determinadas partes da imagem, definindo-as como regiões que pertencem à estrada ou não.

---


<sup>1</sup> Técnica matemática que realiza a detecção de formas geométricas em imagens digitais.

Antes da identificação da estrada e de seus limites, é proposta a fusão das imagens RGB e térmica, gerando uma sobreposição nas imagens originais.

A imagem RGB se assemelha à visão humana sendo facilmente interpretada pelo operador do caminhão. Entretanto, sob condições climáticas adversas, como neblina e poeira, torna-se difícil a identificação de objetos à frente do caminhão com esse tipo de imagem.

Na imagem térmica, a neblina e poeira afetam menos a cena capturada tornando mais fácil a detecção da estrada nessas condições. A câmera termográfica é capaz de detectar objetos e formas através da temperatura superficial dos mesmos, inclusive na presença de neblina ou poeira. Porém, somente a imagem da câmera termográfica não possibilita a construção de um sistema de direção assistida seguro porque não retrata a visão costumeira do operador e não é sensível à luminosidade existente em placas refletivas, faróis e outras sinalizações, essenciais para a direção segura na mina.

Essa dissertação busca verificar se a fusão das imagens RGB e térmica produz uma imagem combinada capaz de delimitar a área de tráfego à frente do caminhão. A Figura 2 ilustra um quadro de vídeo de um caminhão filmado por uma câmera RGB (à esquerda) e por uma câmera termográfica (à direita).



**Figura 2** - Imagem RGB (esquerda) e térmica (direita) de um caminhão

Fonte: FREITAS; ZANETTI; MIOLA (2015)


Para testes e comprovação dos resultados dos algoritmos desenvolvidos nesse trabalho, foram utilizadas três bases de imagens. A internet foi a primeira fonte porque possui uma extensa base de imagens RGB já testadas por outros algoritmos, o que facilita a comparação de desempenho e serve como validação inicial do algoritmo. A segunda e terceira fontes são provenientes de câmeras RGB e termográfica, respectivamente. Foram gravados vídeos no mesmo instante, lado a lado, em uma

condição desfavorável de visibilidade da estrada, durante a noite, com poeira e neblina no ambiente da mineração. Os vídeos gravados possibilitam o processamento de seus quadros (*frames*), que são imagens, e servem de validação final do método proposto uma vez que permitem realizar a fusão das imagens RGB e térmicas no cenário real de condições climáticas adversas no ambiente da mineração.

## 1.1 Motivação

Essa pesquisa foi estimulada pelos resultados insatisfatórios dos indicadores de segurança e produtividade da mineração. Os indicadores operacionais da empresa Vale mostram que há perda média anual de produção de 5,25% no período seco e de 10,48% no período chuvoso, em função de condições climáticas adversas. Em algumas minas, a perda está acima de 15%. O Gráfico 1 mostra a consolidação de perdas em várias minas da Vale.

**Gráfico 1** - Perfil de perdas médias anuais nos períodos secos e chuvosos nas minas da Vale, por condições adversas de clima



Fonte: relatório de indicadores Vale, dados obtidos do sistema PIMS em janeiro de 2016

Verifica-se que há uma média anual de perdas, com paradas de produção, de aproximadamente 8% devido a condições climáticas adversas. Considerando os dados históricos da Vale de disponibilidade física (79,6%) e utilização física (82,4%) no ano de 2016, as perdas indicadas no Gráfico 1 representam 1,26 horas diárias paradas devido a condições climáticas adversas. Em termos de movimentação de material, significam uma perda de 21 milhões de toneladas de matéria prima anuais. A implantação proposta por esse trabalho auxiliará a operação dos caminhões nessas

condições e conseqüentemente proporcionará aumento de segurança operacional e de produtividade.

A baixa produtividade das frotas de transporte, devido à redução de sua utilização, impacta fortemente os custos operacionais. As perdas são mais significativas nas minas em regiões equatoriais, principalmente nas estações chuvosas, quando o clima quente e úmido favorece a evaporação e geração de neblina.

Considerando uma mina a céu aberto, com produção de 10.000 t/dia de matéria prima para beneficiamento, o modelo de custos apresentado na Figura 3, a seguir, permite inferir que até 63% dos custos operacionais são afetados diretamente com a parada dos caminhões.

A redução ótima do custo é composta pela soma das horas inativas pagas aos operadores (*Hourly Labor*) e do custo operacional dos equipamentos (*Equipment Operation*), conforme apresentados na Figura 3. Os valores estão em função do custo monetário pela produção (\$/mt), portanto,  $2,96\$/\text{mt} + 1,67\$/\text{mt} = 4,63\$/\text{mt}$ , o que representa 63% dos custos totais:  $7,32\$/\text{mt}$ .

Cost Summary		
Operating Costs		
Supplies & Materials	\$/mt ore	\$1.05
Hourly Labor	\$/mt ore	2.96
Equipment Operation	\$/mt ore	1.67
Salaried Labor	\$/mt ore	0.97
Miscellaneous	\$/mt ore	0.67
		-----
Total Operating Costs		\$7.32

**Figura 3** - Modelo padrão de custos operacionais de uma mina a céu aberto.

Fonte: retirado do site: <http://costs.infomine.com/costdatacenter/miningcostmodel.aspx>

Essa pesquisa fornece informações para um sistema de direção assistida que contribui significativamente na redução desses custos, através do aumento da utilização dos caminhões que operam na mineração.


Além da questão de produtividade, outro motivador para a realização desse trabalho é a mitigação de riscos de acidentes no ambiente de mineração. Quando há

condições climáticas adversas como forte neblina e chuvas, normalmente, as movimentações dos caminhões são interrompidas para garantir a segurança. Entretanto, a decisão de parar as operações é subjetiva, ficando sob responsabilidade do gerente, que muitas vezes utiliza das opiniões pessoais dos operadores de caminhões a respeito das condições das estradas e acessos.

Devido a esse fato, há situações em que a operação continua mesmo sem condições ideais havendo alto risco de ocorrer um acidente. Mais uma vez recorrendo aos dados estatísticos da Vale, o Gráfico 2 apresenta a consolidação de acidentes, com caminhões, ocorridos no período de janeiro de 2017 a abril de 2018. Os dados são referentes ao Complexo Industrial Serra Norte (Minas de Carajás, Mina do Azul e Mina de Serra Leste), nos quais as causas foram condições climáticas e má execução de manobras.

Os eventos ocorridos devido a condições climáticas estão relacionados diretamente com essa dissertação no sentido em que o sistema proposto auxilia a visualização das estradas, diminuindo consideravelmente o risco de colisões. O evento ocorrido durante a execução de manobras tem relação indireta com o sistema proposto. Esse trabalho não pretende contribuir nesse aspecto mas poderá haver uma redução desses eventos, pois as câmeras instaladas na cabine poderão auxiliar a visualização de obstáculos durante as manobras.

**Gráfico 2** - Número de acidentes e quase acidentes, por severidade, devido a condições climáticas e manobras (período: janeiro de 2017 a abril de 2018)



Fonte: sistema SAP da Vale

Analisando os dados do Gráfico 2, fica claro a existência de um evento com severidade crítica relacionado com condições climáticas adversas. Nesse evento,

devido a neblina, o operador do caminhão não viu a leira<sup>2</sup> de proteção, subiu na mesma e capotou, segundo relato encontrado no sistema SAP da Vale. De toda forma, os outros acidentes colaboram para demonstrar a importância dessa dissertação devido a existência de sete eventos relacionados com condições climáticas que poderiam ser evitados, porque mesmo um acidente sendo classificado com severidade leve, por um simples detalhe durante o acontecimento, pode-se transformar em crítico e causar fatalidades.

## 1.2 Objetivos

O objetivo geral dessa pesquisa é desenvolver uma prova de conceito através de algoritmos e códigos no Matlab a fim de identificar os limites de uma estrada em ambiente de mina, em condições climáticas adversas.

Os objetivos específicos são:

- Validar o método de fusão de imagens selecionado na pesquisa como facilitador da identificação de limites ao longo das estradas, comparando os resultados obtidos no processamento somente das imagens RGB, das imagens térmicas e após a fusão de ambas;
- Verificar o desempenho de alguns algoritmos já desenvolvidos por outros autores e identificar a melhor técnica em virtude do desempenho esperado para uma aplicação real;
- Testar algoritmos usualmente utilizados para veículos leves em imagens e vídeos do ambiente da mineração.

## 1.3 Organização da Dissertação

Após a introdução realizada no Capítulo 1, a dissertação está dividida de tal forma que no Capítulo 2 é apresentado o referencial teórico com a descrição dos trabalhos relacionados com o tema pesquisado, que compõem a base científica para o desenvolvimento dos algoritmos e códigos.

No Capítulo 3 são apresentados os materiais e a metodologia utilizados na pesquisa. Os materiais e a infraestrutura utilizados para a aquisição de imagens são

---

<sup>2</sup> Estrutura construída nas laterais de estradas de mina, considerada elemento de segurança, que tem a função de evitar que os veículos que operam na estrada saiam da pista.



descritos e vários cenários nas minas da Vale são apresentados. As imagens RGB e térmicas são dispostas lado a lado para averiguação das diferenças na identificação de objetos. Em seguida, a metodologia para desenvolvimento dos algoritmos de fusão de imagens, detecção do ponto de fuga e segmentação da área dirigível é apresentada.

No Capítulo 4 são apresentados detalhes sobre a implementação dos algoritmos utilizados e seus respectivos resultados assim como uma análise de desempenho.

No Capítulo 5 os resultados são avaliados em função do nível de acurácia relacionando-os aos objetivos da pesquisa e à sua utilidade no Projeto de Direção Assistida do ITV (Instituto Tecnológico Vale).

No Capítulo 6 é apresentada a conclusão da pesquisa e a sugestão de trabalhos futuros. O Capítulo 7 contém as referências bibliográficas. Os anexos A, B, C, D e apresentam imagens com os resultados dos códigos desenvolvidos.

## **2. REFERENCIAL TEÓRICO E FUNDAMENTAÇÃO CIENTÍFICA**

Neste capítulo será realizada uma revisão bibliográfica dos conceitos e fundamentações teóricas e práticas que suportam o presente trabalho. Para um melhor entendimento, o capítulo foi dividido em seções. Na Seção 2.1 são descritas as iniciativas relacionadas com a utilização de sensores para auxiliar a condução de veículos. Na Seção 2.2 é justificada a importância da fusão de imagens e são apresentados trabalhos relacionados ao tema. Na Seção 2.3 são apresentadas técnicas para o encontro do ponto de fuga das estradas. Na Seção 2.4 contém técnicas para a segmentação da área da estrada que constituem o resultado final para um único quadro das imagens. Na última Seção 2.5 são descritas técnicas que trabalham com múltiplos quadros de imagens para formar o vídeo que compõe o resultado final.

### **2.1 Sensores utilizados em veículos autônomos**

Devido ao alto índice de acidentes e busca pela produtividade, o estudo de sistemas de direção assistida vem recebendo grande atenção ao longo dos anos. Uma questão inicial consiste em avaliar quais sensores podem ser utilizados para o

mapeamento de ambientes em condições adversas. Em um dos primeiros trabalhos pesquisados, Madhavan, *et al.* (1999) comparam o desempenho de lasers, unidades inerciais, GPS (*Global Positioning System*) e encoder<sup>3</sup> para obter a localização de um veículo em uma mina subterrânea.

Avaliando o funcionamento dos sensores individualmente, o encoder apresenta medição satisfatória somente com movimentação em baixas velocidades, pois em altas velocidades existe um erro sistemático que vai se acumulando, inviabilizando a medição. As unidades inerciais possuem ruídos não lineares inerentes ao sensor, que fazem a trajetória prevista ser válida somente por curtos períodos de tempo. O sistema GPS possui alta exatidão, quando usada a correção diferencial, mas não pode ser utilizado em ambientes fechados sem visada para o céu. O laser possui medição precisa e pode ser instalado de tal forma que cubra toda a região ao redor do veículo, porém ele detecta o ambiente a sua volta, sendo necessário relacionar o ambiente ao movimento do veículo através de cálculos complexos. Uma fusão de sensores (*sensor fusion*<sup>4</sup>) gera uma informação mais confiável e independente dos erros individuais de cada um deles.

Outra análise de sensores e técnicas de instrumentação a serem empregadas em veículos autônomos é apresentada por Hague; Marchant; Tillett (2000), incluindo odometria com encoders, unidades inerciais, compassos geomagnéticos ou sensores Doppler<sup>5</sup> para medição de movimento; detecção de *landmarks*<sup>6</sup> artificiais através de laser ou radar de ondas milimétricas e identificação de objetos através de sonar ou aplicação de técnicas de visão computacional utilizando câmeras de vídeo. Neste trabalho, fica evidente que a utilização de *sensor fusion*, aliado ao filtro de Kalman<sup>7</sup>, melhoraram consideravelmente as estimativas de posicionamento do veículo autônomo. O filtro de Kalman colabora na estimativa de posição do veículo, uma vez

---

<sup>3</sup> Transdutor que converte um movimento mecânico angular ou linear em uma série de pulsos analógicos ou digitais elétricos. Esses pulsos gerados podem ser usados para determinar velocidade, taxa de aceleração, distância, rotação, posição ou direção.

<sup>4</sup> Combinação de dados sensoriais ou dados derivados de fontes diferentes, de modo que a informação resultante tenha menos incerteza do que seria possível quando essas fontes fossem usadas individualmente.

<sup>5</sup> Efeito Doppler é um fenômeno físico observado nas ondas quando emitidas ou refletidas por um objeto que está em movimento em relação ao observador.

<sup>6</sup> Ponto de referência.

<sup>7</sup> Filtro que usa uma série de medidas observadas ao longo do tempo, contendo ruído estatístico e outras imprecisões, para produzir estimativas de variáveis desconhecidas que tendem a ser mais precisas do que aquelas baseadas em apenas uma medida, estimando uma distribuição de probabilidade conjunta sobre as variáveis para cada período de tempo

que elimina a necessidade de reinicializar o algoritmo de localização do veículo ao longo do tempo.

Cada um dos instrumentos de medição mencionados é mais adequado a uma determinada condição de operação, de modo que não existe um sensor ideal, com desempenho ótimo para mapeamento de ambientes com presença de chuva, neblina e poeira. Uma solução mais robusta consiste em combinar vários instrumentos de medição para mapear ambientes naturais.

Após definido o instrumento ou conjunto de instrumentos a serem empregados no mapeamento, é necessário implementar técnicas de processamento dos dados fornecidos pelos sensores a fim de obter uma representação realística do ambiente.

As câmeras fornecem imagens que ilustram o ambiente de forma detalhada e a utilização de mais de um tipo dessas agrega ainda mais informações. O trabalho apresentado por Liao, *et al.* (2015) define uma proposta de fusão de dados de imagens RGB e térmica apresentada em dois estágios. No primeiro estágio é reduzida a resolução da imagem RGB para coincidir com a resolução da imagem térmica e utilizado Filtro Guiado<sup>8</sup> na imagem RGB para transferir os detalhes da imagem, bordas e variância de cores, por exemplo, para a imagem térmica original no domínio PCA<sup>9</sup>. No segundo estágio é feito um processo reverso, aumentando a resolução da imagem resultante do primeiro estágio, retornando a imagem do domínio PCA, gerando então a imagem resultante.

Susperregi, *et al.* (2013) apresentam um trabalho em que construíram um protótipo capaz de seguir pessoas utilizando imagens RGB, sensor laser e sensores térmicos, evidenciando a capacidade de construção de *multi-sensors*<sup>10</sup> para realizar tarefas relativamente complexas.

Sabendo que a neblina prejudica a visualização do operador de caminhão que opera no ambiente de mina, somente com a câmera RGB não é possível identificar corpos à frente do caminhão, pois considera-se que a imagem capturada é semelhante à cena vista pelo operador. A imagem RGB é um modelo aditivo de cores,

---

<sup>8</sup> Derivado de um modelo linear local, o filtro guiado calcula a saída de filtragem considerando o conteúdo de uma imagem de orientação. O filtro guiado pode ser usado como um operador de limpeza de bordas, como o popular filtro bilateral.

<sup>9</sup> *Principal Component Analysis* (PCA) é uma ferramenta matemática que transforma a relação entre um conjunto de variáveis gerando eixos ortogonais onde a primeira principal componente está ao longo da máxima variância, a segunda componente está limitada ao espaço perpendicular da primeira e assim por diante.

<sup>10</sup> Combinação de 2 ou mais sensores que juntos geram informação superior à gerada individualmente.

uma vez que é formada pela interpretação humana da mistura das cores vermelha (*red*), verde (*green*) e azul (*blue*). Os nomes das cores na língua inglesa geram o acrônimo RGB. Em uma foto, tela ou câmera, cada *pixel*<sup>11</sup> recebe uma intensidade independente de cor vermelha, verde e azul, formando a imagem RGB. A retina humana possui três espécies de células sensíveis à luz: os cones. Cada cone é composto por pigmentos sensíveis a três diferentes comprimentos de onda de luz, sendo o cone Protan sensível ao vermelho, o Deutan sensível ao verde e o Tritan sensível ao azul. As cores primárias combinadas originam todos os outros tons cromáticos do espectro visível humano (YOUNG, 1802).

A câmera termográfica possui detectores térmicos, microbolômetros<sup>12</sup>, que identificam a temperatura dos corpos que estão sendo filmados. Assim, neblina e poeira influenciam menos na formação e definição da imagem se comparada com a câmera RGB. A utilização das duas câmeras e a fusão de suas imagens se mostra favorável para a identificação da estrada em um ambiente de mina de forma segura e confiável.

Além do sistema de cores RGB, uma imagem pode ser representada e processada em outros sistemas de cores não menos importantes. No sistema de cor escala de cinza ou nível de cinza, a imagem é definida com o valor de cada *pixel* sendo uma única amostra de um espaço de cores. Imagens desse tipo são tipicamente compostas por tons de cinza, variando entre o preto, com a menor intensidade, e o branco, com a maior intensidade. O valor de cada *pixel* é decimal e varia entre 0 (preto) e 1 (branco). Imagens em nível de cinza são diferentes de imagens binárias em preto e branco, que contém apenas dois valores representados por 0 (preto) e 1 (branco).

HSV é a abreviatura para o sistema de cores formadas pelas componentes *hue* (matiz), *saturation* (saturação) e *value* (valor). Matiz (tonalidade) representa o tipo de cor, abrangendo todas as cores do espectro, desde o vermelho até o violeta, mais o magenta. A matiz atinge valores de 0 a 360, mas para algumas aplicações, esse valor é normalizado de 0 a 100%. Saturação, ou "pureza", é um valor em que quanto menor

---

<sup>11</sup> Menor elemento num dispositivo de exibição (como, por exemplo, um monitor), ao qual é possível atribuir-se uma cor.

<sup>12</sup> Instrumento utilizado na medição de radiação eletromagnética incidente através do aquecimento de um material interno ao instrumento que tem sua resistência elétrica dependente da temperatura.


mais com tom de cinza será representada a imagem. A saturação atinge valores de 0 a 100%. O valor define o brilho da imagem e atinge valores de 0 a 100%.

O sistema de cores Lab, criada pela CIE<sup>13</sup>, define a existência de cores opostas em que duas cores não podem ser verdes e vermelhas ou amarelas e azuis ao mesmo tempo. O “L” indica a luminosidade e o “a” e “b”, são as coordenadas cromáticas.

- $L^*$  = Luminosidade
- $a^*$  = coordenada vermelho / verde (+a indica vermelho e -a indica verde)
- $b^*$  = coordenada amarelo / azul (+b indica amarelo e -b indica azul)

Um instrumento de medição faz facilmente a quantificação desses atributos de cor. Espectrofotômetros e colorímetros medem a luz refletida dos objetos em cada comprimento de onda ou em faixas específicas. Eles então quantificam os dados espectrais para determinar as coordenadas de cor do objeto no espaço de cor  $L^*a^*b^*$  e apresentam a informação em termos numéricos.

Quando se mede a cor de uma maçã, por exemplo, o instrumento de medição, mostra os valores de  $L^*a^*b^*$ , apresentados na Figura 4.



**Figura 4** - Representação do Diagrama  $L^*a^*b^*$

Fonte: retirado do site: <http://sensing.konicaminolta.com.br/2013/11/entendendo-o-espaco-de-cor-lab/>

<sup>13</sup> Commission Internationale de l'Eclairage - é uma organização sem fins lucrativos considerada autoridade na ciência de luz e cor.

## 2.2 Fusão de Imagens

A fusão de imagens utiliza duas ou mais imagens como base para proporcionar uma informação rica do ambiente, mas em contrapartida, sua aquisição e processamento demandam técnicas muitas vezes avançadas. Pode haver também a demanda por técnicas computacionais robustas com alta capacidade de processamento.

Toet, *et al.* (1997) apresentam um teste militar de localização de um alvo em uma cena na qual ficou evidente que a fusão de uma imagem visível (RGB) com uma imagem térmica gera mais precisão na localização dos alvos pelos observadores. Uma analogia pode ser feita evidenciando que a fusão da imagem térmica com a imagem RGB colabora na identificação de formas e obstáculos nas estradas.

Kumar, *et al.* (2011) apresentam uma estratégia de fusão de imagens. A fusão é aplicada em um *Unmanned Aerial Vehicles* (UAV) para possibilitar sua operação autônoma. O veículo possui uma câmera RGB e outra térmica e captura as duas imagens à sua frente, no mesmo instante. O método de fusão utilizado é a decomposição das imagens RGB e térmicas em quatro níveis definindo coeficientes para cada nível. Depois, utilizando a transformada inversa de Haar (KUMAR, *et al. apud* WANG, *et al.*, 2002) as imagens são unidas formando a imagem final.

Uma abordagem, com resultados satisfatórios, é obtida pela técnica *Alpha Compositing*, introduzida por Porter; Duff (1984). Essa técnica combina uma cor translúcida de primeiro plano com uma cor de fundo, produzindo assim uma nova cor combinada. Cada *pixel* recebe dados adicionais que são armazenados no canal alfa com um valor entre 0 e 1. Um valor 0 significa que o *pixel* não tem nenhuma informação de cobertura e é transparente; isto é, não houve contribuição de cor de qualquer geometria porque essa não se sobrepôs a esse *pixel*. Se a cor do primeiro plano for completamente transparente, a cor combinada será a cor de fundo. Por outro lado, se for completamente opaco, a cor combinada será a cor do primeiro plano. A translucidez pode variar entre estes extremos, caso no qual a cor combinada é calculada como uma média ponderada das cores de primeiro plano e do plano de fundo. A imagem RGB se transforma em RGBA onde o “A” é o canal alfa adicionado. Um valor de *pixel* de [0; 0,7; 0; 0,5] implica em um *pixel* que possui 70% da intensidade verde máxima e 50% de opacidade. Se a cor fosse totalmente verde, o RGBA seria [0; 1; 0; 0,5]. Com a existência de um canal alfa, é possível expressar as operações

de imagem de composição algebricamente. Por exemplo, com dois elementos de imagem A e B, pode-se combinar as imagens de modo que A apareça no primeiro plano e B aparece em segundo plano. Isso pode ser expresso como “A over B”. Além dessa operação, outros operadores de composição são definidos: “A in B”, “A out B”, “A as\_top B” e “A xor B”. Essas operações são definidas a partir de considerações de escolhas ao combinar as cores de dois *pixels* quando a cobertura deles, conceitualmente, é superada ortogonalmente. A Equação 1 demonstra a operação “A over B” aplicada a cada *pixel* da imagem:

$$C_o = \frac{C_a \alpha_a + C_b \alpha_b (1 - \alpha_a)}{\alpha_a + \alpha_b (1 - \alpha_a)} \quad (1)$$

sendo  $C_o$  o resultado da operação, ou seja, a cor do *pixel* após a fusão,  $C_a$  a cor do *pixel* da imagem A,  $C_b$  a cor do *pixel* da imagem B, e  $\alpha_a$  e  $\alpha_b$  os valores alpha dos *pixels* das imagens A e B respectivamente.


Multiplicando todas as cores pelos seus respectivos alpha ( $c_i = \alpha_i \cdot C_i$ ), a Equação 1 pode ser simplificada de acordo com a Equação 2:

$$c_o = c_a + c_b(1 - \alpha_a) \quad (2)$$

e o alpha resultante é dado pela Equação 3:

$$\alpha_o = \alpha_a + \alpha_b(1 - \alpha_a) \quad (3)$$

As imagens da Figura 5 abaixo mostram um exemplo da fusão de imagens em que foram aplicadas duas operações “A over B” em sequência.



**Figura 5** - Exemplo de fusão de imagens utilizando a operação "A over B"

Fonte: PORTER; DUFF (1984)

## 2.3 Detecção do ponto de fuga

Para a identificação de estradas, a grande maioria dos autores desenvolveram algoritmos que inicialmente encontram o ponto de fuga. Esse ponto representa, como o próprio nome diz, o local na imagem onde não se consegue mais ver a estrada, pois suas extremidades laterais se unem. Ou seja, é o ponto para o qual o veículo deve se direcionar para manter-se na estrada.

Kong; Audibert; Ponce (2010) esclarecem que para identificação de pontos de fuga de estradas pavimentadas, típicas de cidades, técnicas como Color Cue (KONG, *et al. apud* TSUNG-YING *et al.*, 2006), Hough transform (KONG, *et al. apud* SOUTHHALL; TAYLOR, 2001), filtros direcionáveis (KONG, *et al. apud* FREEMAN; ADELSON, 1991; MACCALL; TRIVEDI, 2006) e Spline model (KONG, *et al. apud* KASKE *et al.* 1995; JUNG; KELBER, 2004; WANG *et al.* 2004) apresentam resultados satisfatórios. Para estradas não pavimentadas, como é o caso da mina, onde não há claramente distinção por cores dos limites, é necessário aplicar outras técnicas.

Uma abordagem que vem sendo usada por muitos pesquisadores é a utilização de métodos que usam as informações de textura para encontrar o ponto de fuga da estrada. De forma geral, as marcas de pneus e bandas de rodagem mudam a textura do solo, criando sulcos que têm a mesma direção do ponto de fuga da estrada. Rasmussen (2004) propõe um algoritmo que inicialmente calcula a orientação de textura dominante de cada *pixel* da imagem, utilizando uma série de convoluções com o Filtro de Gabor<sup>14</sup>, configurado para várias orientações e comprimentos de onda. A orientação da resposta da convolução que obtiver o maior resultado é considerada a orientação de textura dominante para um determinado *pixel* da imagem original. Após o cálculo da orientação máxima de textura de cada *pixel* é realizado um esquema de votação para definir o ponto de fuga da estrada. Kong; Audibert; Ponce (2010) propõem um método adaptativo no qual somente *pixels* com alta confiança de votos definem o ponto de fuga. O nível de confiança é definido pela variação entre o valor das diversas orientações de textura de cada *pixel*.

Kong; Audibert; Ponce (2010) afirmam que o melhor método de identificar o ponto de fuga da estrada, para posteriormente identificar a estrada através do processamento de imagens, passa pelos seguintes passos:

---

<sup>14</sup> Desenvolvido por Dennis Gabor em 1946, é um filtro definido por uma função harmônica multiplicado por uma gaussiana. A função harmônica pode ser seno, cosseno ou ambas na forma de exponencial complexa.



1. Estimar a orientação de textura dominante para cada *pixel* utilizando como base a resposta da convolução de uma série de núcleo de Filtros de Gabor com a imagem original. Os núcleos têm 5 escalas de comprimento de onda e 36 orientações variando de 5° em 5° em um arco de 180°;
2. Realizar um esquema de votação levando em consideração o nível de confiança de cada *pixel* e a distância do *pixel* votante ao *pixel* candidato a ponto de fuga;
3. O *pixel* que recebe maior votação é definido como o ponto de fuga.

Em vários artigos, o método utilizado por Kong; Audibert; Ponce (2010), preconizado por Rasmussen (2004), apresenta bons resultados na detecção do ponto de fuga. Entretanto, como é necessário criar um esquema de votação em que cada *pixel* vota numa série de outros candidatos, é gerada uma grande demanda de processamento. Entendendo isso, muitas pesquisas vêm sendo produzidas no intuito de elaborar um novo método com menor demanda de processamento e resultado mais rápido.

Shi; Wang; Fu (2016) definem um novo método em que o ponto de fuga é encontrado também analisando a orientação de textura dos *pixels* com maior confiança. Porém, eles criaram um novo filtro que demanda menos processamento e une o cálculo de votação de *pixel* representante do ponto de fuga, no processamento do filtro, ao invés de fazer a votação convencional que demandaria mais processamento para encontrar o ponto de fuga.

Yang; Fang; Tang (2016) criaram um método diferente: primeiramente são encontrados os *pixels* com informações de textura relevantes, que são definidos como aqueles que têm uma excitação diferencial (ver Seção 2.3.3) acima de um parâmetro pré-definido e a orientação que interessa ao estudo. Posteriormente é definido um esquema de votação para definir o ponto de fuga.

Após a investigação da melhor técnica para cálculo do ponto de fuga de estradas, quatro algoritmos se mostraram viáveis para o desenvolvimento do código e comparação dos resultados. Os mesmos estão descritos a seguir.

### **2.3.1 Votação local e flexível baseada no Filtro de Gabor**

Como já brevemente esclarecido, Kong; Audibert; Ponce (2010) desenvolveram um algoritmo, denominado LASV (*Locally Adaptive Soft-Voting*) que primeiramente encontra a estimativa de orientação de textura de cada *pixel* da

imagem, aplicando o Filtro de Gabor como descrito por *apud* Lee, (1996) e faz uma votação das orientações dominantes para cada *pixel*. O agrupamento das orientações dominantes poderia definir o ponto de fuga. Entretanto, somente essa técnica não é suficiente para gerar resultados satisfatórios. É possível encontrar um ponto de fuga na parte superior da imagem, onde estaria localizado o céu na imagem. Se torna necessário definir um nível de confiança para orientação de textura de cada *pixel* e medir a distância dos pontos mais votados com o ponto de fuga candidato, evitando a ocorrência de erros de estimativas.

Calcula-se a orientação de textura de cada *pixel* da figura aplicando a convolução de núcleos de filtros de Gabor à imagem original. O filtro de Gabor é definido pela Equação 4:

$$\psi_{(\omega,\phi)}(x,y) = \frac{\omega}{\sqrt{2\pi c}} e^{\frac{-\omega^2(4a^2+b^2)}{8c^2}} (e^{ia\omega} - e^{-\frac{c^2}{2}}) \quad (4)$$

sendo  $a = \cos(\phi) + y\sin(\phi)$ ;  $b = -x\sin(\phi) + y\cos(\phi)$ ;  $c = 2,2$ . O valor de  $c$  é constante. São consideradas cinco escalas ( $\omega$ ) onde  $\omega = \omega_0 2^k$ ;  $\omega_0 = 2,1$ ; sendo  $k = [0, 1, 2, 3, 4]$ . São consideradas também trinta e seis orientações ( $\phi$ ) que variam de  $5^\circ$  a  $175^\circ$ , com intervalo de  $5^\circ$ . A parte imaginária da equação é representada por  $i = \sqrt{-1}$ .

Aplica-se a convolução da imagem original a todos os núcleos do filtro de Gabor de acordo com a Equação 5:

$$G_{\omega,\phi}(z) = I(z) \otimes \psi_{(\omega,\phi)}, \quad z = (x,y) \quad (5)$$

sendo  $I(z)$  é a imagem original em função das suas coordenadas de *pixels*  $x$  e  $y$ , representadas por  $z$ . O símbolo  $\otimes$  indica a operação de convolução entre a imagem original  $I(z)$  e o filtro de Gabor  $\psi_{(\omega,\phi)}$ , calculado pela Equação 4.  $G_{\omega,\phi}(z)$  é um resultado da convolução com determinada orientação  $\phi$  e escala  $\omega$ .

O resultado da convolução tem duas componentes, uma parte real e uma parte imaginária provenientes do filtro de Gabor. A Equação 6 computa o comprimento (norma) para cada vetor de orientação:

$$I_{\omega,\phi}(z) = Re(G_{\omega,\phi}(z))^2 + Im(G_{\omega,\phi}(z))^2 \quad (6)$$

sendo  $I_{\omega,\phi}(z)$  é a norma das partes reais  $Re(G_{\omega,\phi}(z))$  e parte imaginária  $Im(G_{\omega,\phi}(z))$ .

A Equação 7 define as orientações de cada *pixel* considerando as 5 escalas do filtro de Gabor:

$$R_\phi(z) = Media_\omega I_{\omega,\phi}(z) \quad (7)$$

sendo  $R_\phi(z)$  é a imagem resposta contendo a orientação em cada *pixel*  $z$  em uma determinada orientação  $\phi$ . O operador  $Media_\omega$  define o cálculo da média dos comprimentos dos vetores  $I_{\omega,\phi}(z)$  nas 5 escalas do filtro de Gabor também em uma determinada orientação  $\phi$ .

A orientação de textura dominante de um *pixel* é definida pela Equação 8 em que o valor de orientação de um *pixel* é definido tal que se tem o máximo de  $R_\phi(z)$ :

$$\theta(z) = Argmax_\phi R_\phi(z) \quad (8)$$

sendo  $\theta(z)$  é a orientação dominante do *pixel*  $z$ . O operador  $Argmax_\phi$  define o cálculo do máximo valor de  $R_\phi(z)$  variando-se  $\phi$  nas 36 orientações utilizadas pela filtro de Gabor.

Após definidas as orientações dominantes de cada *pixel*, são computados os níveis de confiança da orientação de textura. Esse nível de confiança é normalizado entre 0 e 1. O nível de confiança é dado pela Equação 9:

$$Conf(z) = 1 - \frac{Media(r_5(z), \dots, r_{15}(z))}{r_1(z)} \quad (9)$$

sendo  $r_n(z)$  as respostas ordenadas em ordem decrescente do filtro de Gabor na orientação  $n$ , tal que  $\{n \in \mathbb{N} : 1 \leq n \leq 36\}$ , para um determinado *pixel*  $z$ . O fator  $r_1(z)$ , sendo a maior resposta de orientação, realiza a normalização. O operador  $Media$  define a média aritmética no intervalo do 5º ao 15º maiores valores de orientação.

Após o cálculo do nível de confiança para cada *pixel*, para otimizar a execução do algoritmo, são descartados 10% da parte inferior da imagem, pois nessa região não se espera encontrar o ponto de fuga da estrada. Para evitar falsos pontos de fuga, são criadas na imagem uma zona de votação para cada *pixel* denominada  $R_v$ . A área  $R_v$  é definida como o semicírculo de 180º, abaixo do *pixel* a ser votado, sendo esse o centro do “meio disco”. O raio do semicírculo é definido como  $0,35 \times D$ , onde  $D$  é a diagonal da imagem. Todos os possíveis *pixels* dentro de  $R_v$  votam para o *pixel* do centro do semicírculo como pontos de fuga. A votação segue a Equação 10 a seguir:

$$Vote(P, V) = \begin{cases} \frac{1}{1 + [\gamma d(P, V)^2]} & \text{para } \gamma \leq \frac{5}{1 + 2d(P, V)} \\ 0 & \text{para outro caso} \end{cases} \quad (10)$$

sendo  $P$  o *pixel*, dentro de  $R_v$ , que vota para  $V$ ; define-se  $d(P, V)$  como a razão da distância entre  $P$  e  $V$  e a diagonal da imagem;  $\gamma$  é o ângulo entre o vetor formando com os pontos  $P$  e  $V$  e a orientação de textura dominante de  $P$ . O *pixel* que receber maior votação, definido pela função  $Vote(P, V)$ , é então selecionado como o ponto de fuga.

### 2.3.2 Extração de orientação de textura local, criação de mapa de bordas e definição do ponto de fuga através de uma função de votação customizada

O algoritmo pesquisado foi elaborado por Nguyen; Phung; Bouzerdoum (2016). Nesse algoritmo, denominado ELTO (*Extraction-Locally Texture Orientation*) para futuras referências, primeiramente, é realizada uma extração local da orientação de textura usando método de tensão de cores (*apud* WEIJER *et al.*, 2006) para encontrar as bordas das imagens, onde a tensão das cores é maior, identificando limites de estradas e objetos.

Em um segundo passo, são definidos os pontos de fuga da estrada, candidatos e votantes para os pontos de fuga. Para definir os pontos de fuga candidatos, o algoritmo aplica a *Hough transform* (*apud* SOUTHHALL; TAYLOR, 2001) no mapa de bordas encontrado a partir do mapa de tensão de cores. Nas interseções das bordas principais estarão os candidatos a ponto de fuga. Para definir os *pixels* votantes para os pontos de fuga, são considerados somente os *pixels* localizados abaixo do *pixel* candidato.

Contudo, isso não é suficiente pois *pixels* de bordas, localizados fora da área da estrada, influenciam na votação. Então, é elaborado um histograma de orientação local, baseado nas tensões de cores (*apud* WEIJER; GEVERS; SMEULDERS, 2006). Sabendo-se que *pixels* da borda da estrada terão alta representatividade no histograma porque possuem orientações locais semelhantes, os demais são eliminados e não votam para o ponto de fuga. Para definição da função de votação para encontrar o ponto de fuga, é levado em consideração a distância entre o votante, o ponto de fuga e o vetor de orientação local. Esse método demanda menos

processamento que os outros métodos, de acordo com a literatura. A Equação 11 apresenta a equação de votação:

$$S(c) = \sum_v f(v, c) \quad (11)$$

sendo que a variável  $c$  representa os candidatos a pontos de fuga e  $v$  algum *pixel* votante.  $S(c)$  é a pontuação acumulada de cada candidato  $c$ . Portanto, o candidato com maior pontuação é definido como ponto de fuga.

Para encontrar a função de votação  $f(v, c)$ , deve-se considerar que a mesma deve ter alto valor se a orientação de textura em  $v$  tem uma direção similar a linha que conecta  $c$  e o  $v$  em questão. Também, um ponto  $v$  perto de um candidato  $c$  deve ter um valor alto. Baseado nessas observações, define-se a Equação 12 para o cálculo da função de votação:

$$f(v, c) = \begin{cases} \frac{1}{\exp(k\Delta) \cdot \left[1 + \left(\frac{d}{L}\right)^2\right]}, & \text{para } \Delta < \delta \\ 0, & \text{para } \Delta \geq \delta \end{cases} \quad (12)$$

sendo  $k$  um coeficiente experimental;  $\delta$  é o ângulo limite para que  $v$  possa votar para  $c$ ; a variável simplificada  $d$  é a Distância Euclidiana<sup>15</sup> entre  $c$  e  $v$ ;  $L$  é o tamanho da diagonal da imagem;  $\Delta$  está em função de  $v$  e  $c$ , sendo  $\Delta(v, c) = O(v) - \emptyset(v, c)$ ;  $O(v)$  é a orientação de textura local em  $v$ ;  $\emptyset(v, c)$  é o ângulo de  $d$ .

### 2.3.3 Detecção do ponto de fuga através de método rápido e preciso

O algoritmo pesquisado, denominado FAVP (*Fast and Accurate Vanishing Point Detection*) para futuras referências, foi desenvolvido por Yang; Fang; Tang (2016). Esse algoritmo é composto por duas etapas: 1) obtenção da informação de textura relevante de cada *pixel*; 2) esquema de votação para encontrar o ponto de fuga.

Para executar a primeira etapa é necessário encontrar a excitação diferencial dos *pixels* da imagem ( $\xi$ ) e sua orientação de textura ( $\theta$ ). A excitação diferencial é computada com base na razão entre dois termos:

- a soma da diferença de intensidade relativa do *pixel* atual  $p_c$  contra seus *pixels* vizinhos  $p_i$  ( $i = 1, 2, 3, \dots, n$ , sendo  $n$  o nº de vizinhos);
- a intensidade de  $p_c$  de acordo com a Equação 13:

<sup>15</sup> É a distância entre dois pontos, que pode ser provada pela aplicação repetida do teorema de Pitágoras

$$\xi(p_c) = \begin{cases} \sqrt{\theta(p_c)}, & \text{se } \theta(p_c) \geq 0 \\ 0, & \text{se } \theta(p_c) < 0 \end{cases} \quad (13)$$

sendo  $\theta(p_c)$  definido pela Equação 14:

$$\theta(p_c) = \arctg\left(\frac{p_c - \bar{p}}{p_c}\right) \quad (14)$$

sendo  $\bar{p}$  o valor médio de todos os *pixels*  $p_i$ .

Para a segunda etapa, usa-se o método LASV, executando o esquema de votação proposto pelo método, já detalhado anteriormente. Entretanto, somente os *pixels* com excitação diferencial positiva e acima de um limiar experimental ( $T=0,05$ ) são selecionados para votar para pontos de fuga, o que teoricamente melhora o desempenho do algoritmo se comparado ao método LASV original.

### 2.3.4 Métodos utilizando identificação de bordas e aplicação de coerência de orientação baseados em textura

Nesse algoritmo pesquisado por Lu (2012), denominado EBMO (*Edge-based methods and the orientation coherence concept*) para futuras referências, é proposto um método bem diferente dos três anteriores, que utiliza a geometria natural de estruturas contidas nas imagens e as propriedades de textura. Inicialmente, o algoritmo encontra linhas retas nas imagens que são um ponto de partida para a definição das bordas da estrada. Após aplicar o método “Canny” (*apud*, CANNY, 1986) para encontrar as bordas da imagem, o algoritmo verifica e ajusta o tamanho e orientação das linhas para evitar erros.

O ponto de fuga, normalmente, se encontra em uma interseção de linhas retas que representam as bordas laterais da estrada. Entretanto, é difícil selecionar quais linhas representam as verdadeiras bordas, pois as mesmas normalmente têm tamanhos parecidos e o mesmo número de linhas através das interseções.


Portanto, é necessário verificar a coerência das orientações dos segmentos abaixo de cada interseção. O valor de coerência é definido pela Equação 15:

$$C(I_i^s) = \frac{\text{count}(|\hat{\theta}(p_j) - \theta(I_i)| < T, p_j \in I_i^s)}{\text{length}(I_i^s)} \quad (15)$$

sendo  $I_i^s$  representa a linha  $I_i$  que começa no ponto de interseção  $s$  até a parte inferior da imagem, ou seja,  $I_i^s$  é segmento de reta da linha de  $I_i$ ;  $\theta(I_i)$  representa a orientação da linha  $I_i$ .  $p_j$  denota um ponto da linha  $I_i$  sendo  $j=0$  o ponto inicial da interseção

crescendo para baixo.  $\hat{\theta}(p_j)$  é a orientação estimada de  $p_j$ , calculada pelo filtro derivativo 5-*tap* (*apud* FREEMAN; ADELSON, 1991). *count* é a função para contar quantos pontos em  $I_i^s$  tem as diferenças angulares entre as direções da borda local e a direção da linha  $I_i$  que são menores que o limite  $T$  ( $T = 3^\circ$ ). *length* é a função que retorna o tamanho do segmento  $I_i^s$ .

De forma geral, a área da estrada tem textura de cores uniformes em uma imagem. Utilizando-se desse aspecto, o algoritmo computa a variação média de cor das áreas da imagem limitadas por duas linhas ( $\phi_1$  e  $\phi_2$ ) que têm interseção entre si. Para tal, essa área é dividida, através de um segmento com origem no ponto de interseção, em que seu ângulo será a soma dos ângulos das duas linhas dividido por 2, ou seja:  $[(\phi_1 + \phi_2) / 2]$ . A Figura 6 esclarece essa divisão de áreas.



**Figura 6** - Exemplo de divisão de áreas para cálculo de diferença de textura de cores.

Fonte: (LU; 2012)

As linhas vermelhas representam as linhas que se interceptam no ponto  $s$ . A linha verde representa o segmento que dividiu a área entre as linhas vermelhas criando as subáreas  $\Omega_1$  e  $\Omega_2$ .

O algoritmo propõe então o cálculo da diferença de textura de cores entre as duas áreas utilizando a Equação 16:

$$CT\_diff(I_i^s, I_j^s) = \left| \frac{1}{\#(\Omega_1)} \sum_{p_1 \in \Omega_1} c(p_1) - \frac{1}{\#(\Omega_2)} \sum_{p_2 \in \Omega_2} c(p_2) \right| \quad (16)$$

sendo  $I_i$  e  $I_j$  são os segmentos que se interceptam no ponto  $s$ .  $\Omega_1$  e  $\Omega_2$  são as duas áreas delimitadas pelo segmento criado e as duas linhas ( $I_i$  e  $I_j$ ).  $\#$  é o operador que computa quantos pontos estão dentro de  $\Omega_1$  e  $\Omega_2$ .  $c(p_1)$  e  $c(p_2)$  são os valores de cores dos pontos nas áreas  $\Omega_1$  e  $\Omega_2$  respectivamente.

Para encontrar o ponto de fuga é utilizada pelo algoritmo uma função custo definida pela Equação 17, que é aplicada a cada par de linhas tem têm interseção.

$$PF\_cost(I_i^s, I_j^s) = CT\_diff(I_i^s, I_j^s) - C(I_i^s) - C(I_j^s) \quad (17)$$

O par de linhas que obtiver o menor custo determina o ponto de fuga no seu ponto de interseção  $s$ .

## 2.4 Segmentação da área das estradas

As estradas presentes nas minas não são pavimentadas e possuem leiras de proteção, construídas com o mesmo material da estrada, apresentando uma superfície homogênea, o que dificulta a aplicação de métodos de segmentação da imagem da área trafegável. Entretanto, as estradas costumam ter feixes paralelos no solo, que formam texturas que são indicações para a aplicação de métodos de processamento de imagem.

Os primeiros trabalhos encontrados por essa pesquisa, aplicadas a estradas pavimentadas, baseiam-se no SCARF System<sup>16</sup> (CRISMAN; THORPE, 1993), utilizando um conjunto gaussiano de modelos de cores para diferenciar as áreas da estrada, demarcando os limites e superfícies degradadas.

Uma combinação do algoritmo de Adaboost<sup>17</sup> para segmentação de regiões e projeções geométricas é utilizada por Alon; Ferencz; Shashua (2006), porém demanda grande quantidade de processamento e memória para as etapas de treinamento e classificação. Técnicas baseadas no fluxo ótico, apresentadas por Lookingbill, *et al.* (2007) executam uma segmentação adaptativa da estrada através de sensores instalados em veículos autônomos. Esse algoritmo apresenta sérios problemas quando a condição do fluxo ótico da estrada é caótico.

Outro método proposto por Gao; Luo; Moli (2007) detecta estradas não pavimentadas aprendendo os atributos de partes da imagem, utilizando os canais HSV da imagem. Esse método é falho para imagens que possuem pouca variação de intensidade entre a área da estrada e fora da estrada, como é o caso do ambiente de mina.

<sup>16</sup> Sistema de visão artificial composto por um robô e um sistema de navegação que consegue reconhecer ruas e cruzamentos, mesmo sob condições adversas de clima.

<sup>17</sup> Algoritmo de aprendizado de máquina, inventado por Yoav Freund e Robert Schapire. É um algoritmo meta-heurístico e pode ser utilizado para aumentar a performance de outros algoritmos de aprendizagem



Uma proposta diferente é apresentada por Shengyan, *et al.* (2010) usando SVM (*Support Vector Machines*) que é um algoritmo supervisionado de aprendizagem de máquina, que pode ser empregado para fins de classificação e regressão. O SVM é capaz de reduzir os erros de extração de atributos de segmentação de estrada por cores e textura. Zhen, *et al.* (2013) propõem um método, através de uma imagem única, cuja segmentação é feita utilizando os dados produzidos em uma área estimada do solo do quadro da imagem corrente. Um método não paramétrico é proposto por Wu; Lam; Srikanthan (2015), no qual parâmetros intrínsecos da estrada são utilizados. São empregadas algumas câmeras para detectar a estrada formando uma visão estéreo<sup>18</sup>. A identificação da estrada acontece através da avaliação do mapa de disparidade<sup>19</sup>.

Para estradas não pavimentadas uma abordagem diferente vem sendo pesquisada e aplicada. Os métodos apresentados para estradas pavimentadas não apresentam bons resultados em ambiente de mineração, que possuem desafios com relação a falta de definição dos limites das estradas e presença de neblina e poeira. Da mesma forma que acontece com pesquisas em detecção de estradas pavimentadas, existe material de base científica que propõe métodos e algoritmos para estradas não pavimentadas.

Nesse trabalho foram selecionados quatro algoritmos para serem estudados em profundidade. Os mesmos foram selecionados em virtude do seu baixo nível de complexidade, dos resultados preliminares obtidos e do alinhamento com técnicas de encontro do ponto de fuga, que são ponto de partida para a identificação da área das estradas.

#### **2.4.1 Mapa de texturas e aplicação de padrões na imagem**

Para a execução do primeiro algoritmo, chamado de MATL (abreviação de Matlab) para futuras referências, foi definida uma abordagem inicial simples. O software Matlab possui funções na sua biblioteca de processamento de imagens que podem identificar as estradas. Essas funções não são aplicáveis como resultado definitivo, mas o teste das mesmas é válido para melhor entendimento e utilização

---

<sup>18</sup> Sistema de visão robótica que através de duas ou mais câmeras constrói uma visão tridimensional da cena filmada de forma bidimensional pelas câmeras.

<sup>19</sup> Mapa que identifica a variação de pixels de uma mesma cena gravada de posições diferentes. Essa diferença que permite o sistema computacional identificar profundidade na imagem. Uma analogia pode ser feita com a sensação de profundidade que o ser humano tem, devido à diferença de posição dos olhos.

nos algoritmos seguintes, considerados mais robustos em relação a diferentes situações e imagens utilizadas. No Matlab pode ser criado um mapa de texturas locais de cada *pixel* da imagem para posteriormente ser aplicada a função “*kmeans*”, que define padrões na imagem, os quais podem ser identificados como sendo as bordas da estrada. Os padrões identificados com maior presença na parte inferior da imagem podem ser segmentados como sendo a área trafegável da estrada.

#### 2.4.2 Votação local e flexível baseada no Filtro de Gabor

O segundo algoritmo, que representa a segunda parte do LASV previamente detalhado, é utilizado para encontrar a área da estrada. Kong; Audibert; Ponce (2010) propõem que a partir do ponto de fuga da estrada podem ser traçados segmentos de retas igualmente espaçados até a parte inferior da imagem. A diferença de cores dos dois lados de cada segmento e a variação entre a direção do segmento e da orientação de textura dominante devem ser medidas e o fator entre esses dois determina a localização das bordas da estrada. A partir do ponto de fuga previamente identificado, são traçados segmentos de reta com ângulos entre  $20^\circ$  e  $160^\circ$ , igualmente espaçados em  $5^\circ$ . As orientações de textura de cada *pixel* sob os segmentos são comparadas com o ângulo do próprio segmento. Se a diferença for menor que um limite (não informado no material pesquisado), esses *pixels* contêm orientação consistente. A razão entre o número de *pixels* consistentes e o número total de *pixels* sob o segmento definem o OCR (*Orientation Consistency Ratio*).

A diferença entre as cores dos dois lados de cada segmento é calculada através da Equação 18. As áreas laterais são definidas pelos segmentos do intervalo considerado. A diferença de cada canal de cores é determinada pela Equação 19:

$$dif(A_1, A_2) = \max(dif(A_1, A_2)_c | c = \{R, G, B\}) \quad (18)$$

$$dif(A_1, A_2)_c = \frac{|media(A_1) - media(A_2)|}{\sqrt{var(A_1) + var(A_2)}} \quad (19)$$

sendo  $A_1$  e  $A_2$  as áreas laterais de um determinado segmento;  $media()$  e  $var()$  a média aritmética e o desvio padrão dos *pixels* das áreas no canal de cor  $c$ . Para calcular a diferença de cores em todos canais seleciona-se o maior valor dos canais de cores através da função  $\max()$ .

Para encontrar o segmento do lado esquerdo da estrada (90° a 160°) que define o limite da mesma, basta encontrar o maior fator entre a diferença de cores e o OCR, como definido pela Equação 20:

$$BordaEsq(j) = \max[dif(A_1(j+1), A_2(j-1)) \text{ OCR}(j)] \text{ sendo } j = [90^\circ, 160^\circ] \quad (20)$$

Para encontrar a outra borda da estrada (direita), a mesma técnica deve ser aplicada de acordo com a Equação 21:

$$BordaDir(j) = \max[dif(A_1(j+1), A_2(j-1)) \text{ OCR}(j)] \text{ sendo } j = [20^\circ, 90^\circ[ \quad (21)$$

### 2.4.3 Utilização da técnica de *superpixels*

No terceiro método pesquisado, chamado de SUPP (abreviação de *superpixel*) para futuras referências, Yoon, *et al.* (2016) afirmam que o algoritmo anterior considera que o formato das bordas da estrada é definido pelas linhas retas provenientes do ponto de fuga até a parte inferior da imagem, o que muitas vezes gera uma interpretação grosseira e errônea da área trafegável da estrada. Adicionalmente, o processo de detecção de limites é altamente sensível a distúrbios e objetos na estrada.

A partir da utilização de imagens térmicas-infravermelhas, é proposto um algoritmo para resolver essa questão, através da técnica que, primeiramente, faz uma segmentação grosseira da estrada para então definir sua área utilizando o Gabor Filter. Somente os *pixels* que possuem respostas ao filtro acima de um limite definido por Yoon, *et al.* (2016) não têm seus valores zerados. A região da imagem segmentada que estiver mais próxima da parte central-inferior é mantida e as outras áreas são zeradas. Em um segundo momento do algoritmo são definidos rótulos na imagem que são agrupados e segmentados, utilizando a técnica de *superpixel*<sup>20</sup> (*apud* Achanta *et al.*, 2012). Assim, é calculada a média agrupada de intensidade de cada *pixel*.

A região da estrada a ser identificada precisa atender às condições chamadas de local e global. A condição local é definida pela conectividade entre os *superpixels*. A condição global é definida por uma curva de probabilidade gaussiana com as amostras de intensidade da máscara inicial (considerando a variável  $k=2$  do algoritmo

---

<sup>20</sup> Agrupamento de pixels definido por uma certa relação entre eles que normalmente indica algum tipo de semelhança na sua cor ou intensidade.

do *Gabor Filter* para separar a estrada do resto da imagem). É executado um algoritmo denominado *Expectation and Maximization* no qual são processados os *superpixels* com alta probabilidade. Como os resultados não são satisfatórios, é necessária uma compensação local considerando a conectividade dos *superpixels* uma vez que a diferença de intensidade da imagem calculada em regiões próximas na estrada não varia muito e que há ambiguidade na imagem, à medida em que a câmera se distancia da superfície quente (atenuação da detecção de calor devido à distância).

A medida em que obstáculos, outros veículos e pessoas afetam a textura da imagem térmica-infravermelha, é possível, através desse mesmo algoritmo, identificá-los, já que eles não estarão presentes na área segmentada da estrada; área essa que irá delimitar o caminho permitido a ser trafegado pelo caminhão.

#### 2.4.4 Utilização de distribuições normal multivariada para os canais de cores

A quarta técnica, chamada de PROB (abreviação de probabilidade) para futuras referências, usa a estratégia de Neethu; Anusha; Krishnan (2015) na qual a área da estrada é definida a partir de três passos: a) definir três regiões que demonstram um padrão de cores característico da estrada em questão nos 6 canais de cores (RGB e HSV); b) definir duas regiões que demonstram um padrão de cores característico de região fora da estrada em questão nos 6 canais de cores (RGB e HSV); c) aplicar um modelo probabilístico para verificar de qual região cada *pixel* (abaixo do ponto de fuga) pertence.

Na Figura 7, os quadrados vermelhos identificam as regiões fora da estrada; os quadrados verdes e as linhas amarelas identificam as três regiões com padrões de cores da estrada.



**Figura 7** - Identificação de regiões para aplicação do algoritmo de Distribuição Normal Multivariada.

Fonte: adaptada pelo autor

As três regiões definidas na imagem como padrões de cores da área da estrada são consideradas um “mix” de três distribuições enquanto as regiões com padrões de fora da estrada um “mix” de duas distribuições. É considerado que existem valores esperados e desvios padrões para cada um dos 6 canais de cores da imagem (HSV<sup>21</sup> e CIE Lab Space<sup>22</sup>) de cada distribuição. É calculada a probabilidade de cada *pixel* abaixo do ponto de fuga estar nas regiões padrões da estrada ou fora da estrada de acordo com a Equação 22. O maior valor entre as duas probabilidades define se o *pixel* pertence à estrada ou não:

$$p(x) = \sum_{i=1}^m w_i p(x/\theta_i), \text{ sendo } \sum_{i=1}^m w_i = 1 \quad (22)$$

$$p(x/\theta_i) = N\left(\frac{x}{\mu}, \sigma\right) \quad (23)$$

$$N\left(\frac{x}{\mu}, \sigma\right) = \frac{1}{(2\pi)^{d/2} |\sigma|^{1/2}} e^{\left\{\frac{-1}{2}(x-\mu)^T \sigma^{-1} (x-\mu)\right\}} \quad (24)$$

sendo  $\theta_i$  a distribuição com índice  $i$ ;  $w_i$  o peso da distribuição no mix definido pela razão entre nº de *pixel* da distribuição e o total de *pixel*;  $p(x/\theta_i)$  a probabilidade de um *pixel*  $x$  estar na distribuição  $\theta_i$ ;  $\mu$  e  $\sigma$  são a matriz de média e desvio padrão da distribuição  $\theta_i$  nos seis canais de cores. A variável  $d$  representa a dimensão da distribuição normal multivariada ( $d = 6$ ). A letra  $T$  indica a transposição da matriz formada por  $(x - \mu)$ .

O fato de se tentar encontrar a probabilidade de um *pixel*, que pertence a uma distribuição, dentro de outra distribuição, sendo as distribuições regiões das imagens, define a utilização de uma distribuição de probabilidade multivariada. Nesse caso, o espaço de probabilidade tem 6 dimensões onde os dados de cada distribuição estão correlacionados. Um exemplo clássico é adotado na jogada de um dado de 6 lados. A probabilidade de se ter um número par é 1/2 (2, 4 e 6). Agora, a probabilidade do número ser par e primo ao mesmo tempo é 1/6 (somente 2). Trazendo para as imagens, tendo-se o *pixel* em questão, procura-se encontrar a probabilidade de verossimilhança do *pixel* e da região selecionada para o cálculo nos 6 canais de cores.

<sup>21</sup> Hue, Saturation, Value – matriz, saturação, brilho

<sup>22</sup> Espaço de cores Lab, sendo: L (luminosidade); a (coordenada vermelho/verde); b (coordenada amarelo/azul)

Os experimentos atuais relacionados à detecção de estradas e sensores com fusão de imagens demonstram que os estudos se encontram em um nível tecnológico avançado, o que colabora para o desenvolvimento dessa pesquisa.

O estado da arte com base em publicações técnicas e científicas pesquisadas, sobretudo artigos científicos nacionais e internacionais relacionados com visão computacional e processamento de imagens, apresentam bons resultados. Assim, com base no que vem sendo desenvolvido, parece ser possível selecionar uma estratégia a fim de encontrar um algoritmo que defina o ponto de fuga e a área da estrada, com rápida resposta e baixo tempo de processamento, aplicando a fusão de imagens como catalisadora na detecção da área da estrada, corroborando para os objetivos geral e específicos dessa pesquisa.

## 2.5 Aquisição de vários quadros (*frames*)

Yoon, *et al.* (2016) propõem um algoritmo para tratar uma sequência de quadros (*frames*) de imagens, que será utilizado para testar vídeos da base de dados disponível. Esse método avalia continuamente a sequência de quadros e detecta se a cena foi alterada de forma significativa, para então reinicializar o algoritmo de segmentação já descrito. Para avaliar a mudança da cena, compara-se a área atual de estrada segmentada com a anterior. Sempre haverá diferença devido à alta variação de *pixels* de borda. Assim, 30% da imagem é descartada usando *erosion filter*<sup>23</sup> e ampliada usando *dilation filter*<sup>24</sup>. A área remanescente entre esses filtros é definida como uma área incerta para ser aplicado o algoritmo Grow-Cut (YOON, *et al. apud* Vezhnevets; Konouchine, 2005). São então definidos 3 rótulos para os *pixels*: 1 como sendo a área da estrada; -1 a área fora da estrada e 0 a área de interface.

Para finalmente identificar se o algoritmo precisa ser reinicializado pela diferença de quadros na imagem, é definida a Equação 25 para normalizar a correlação dos quadros. Essa equação impede que objetos em movimento, buracos e lombadas na estrada influenciem na avaliação:

---

<sup>23</sup> Filtro de Erosão - operação morfológica na imagem que utiliza uma estrutura de pixels para aplicar o filtro. A operação altera o valor dos pixels com o menor valor da vizinhança do mesmo. O tamanho da vizinhança é definido pela estrutura de pixels que aplica o filtro.

<sup>24</sup> Filtro de Dilatação - operação morfológica na imagem que utiliza uma estrutura de pixels para aplicar o filtro. A operação altera o valor dos pixels com o maior valor da vizinhança do mesmo. O tamanho da vizinhança é definido pela estrutura de pixels que aplica o filtro.

$$\rho_{PH} = \frac{\sum_{i=1}^n (P_i - \bar{P})(H_i - \bar{H})}{\sqrt{\sum_{i=1}^n (P_i - \bar{P})^2 \sum_{i=1}^n (H_i - \bar{H})^2}} \quad (25)$$

sendo  $H$  o histograma de intensidade dos *pixels* da região segmentada da estrada;  $P$  o histograma de intensidade de 10 quadros anteriores e  $n$  o limite de intensidade da imagem, no caso 255.  $\bar{P}$  e  $\bar{H}$  são os valores esperados para cada  $P_i$  e  $H_i$ .

Se o resultado da equação  $\rho_{PH}$  diminuir de forma rápida, o quadro precisa ser reinicializado. A taxa de variação é calculada experimentalmente.

### 3. MATERIAIS E METODOLOGIA

Neste capítulo é descrito como foi realizado o levantamento de imagens nas minas da Vale, que serviram de base de dados para os testes de aplicação dos códigos desenvolvidos. Em seguida, imagens são apresentadas para identificar as condições e os locais em que as mesmas foram obtidas e as diferenças das cenas entre as imagens RGB e térmicas. Conhecer o ambiente da mineração é importante para a aplicação do método correto de processamento de imagens.

Posteriormente, é descrita a metodologia da pesquisa e de desenvolvimento dos códigos; sendo detalhado como as imagens foram selecionadas e o motivo para tal escolha. Por fim, são apresentadas as etapas de desenvolvimento dos códigos que se resumem em: aquisição de imagens, pré-processamento, fusão de imagens, encontro do ponto de fuga, segmentação da área trafegável da estrada e aquisição de vários quadros (*frames*).

#### 3.1 Investigação do ambiente de mineração através de teste com câmeras para geração de base de dados

A equipe do Instituto Tecnológico Vale (ITV) vem desenvolvendo um projeto intitulado Direção Assistida de Equipamentos de Mineração. A partir das informações do levantamento de campo realizado em 2015, obteve-se base de imagens para o desenvolvimento do algoritmo proposto por essa pesquisa. As imagens e informações contidas nessa seção foram obtidas do “Relatório Testes com Câmeras para o

Sistema de Direção Assistida de Equipamentos de Mineração” (FREITAS, ZANETTI e MIOLA, 2015).

Algumas áreas da Vale já investigaram a utilização de equipamentos para a geração de alertas de proximidade e também para a operação de caminhões em condições climáticas adversas. Uma iniciativa de destaque foi executada pela Diretoria de Planejamento de Ferrosos, no ano de 2012, ao elaborar um parecer técnico sobre tecnologias existentes de sistemas de alerta de proximidade para equipamentos de mineração. O parecer concluiu que cada uma das tecnologias de sensoriamento, isoladamente, não proporcionou uma resposta robusta o suficiente para evitar colisões nas operações de mineração. O sistema ideal deve empregar dois ou mais tipos de tecnologias de instrumentação complementares.

As câmeras correspondem a um dos tipos de dispositivos de instrumentação que compõem o sistema de direção assistida, que também conta com o apoio de outros sensores incluindo lasers, radares e GPS, bem como outros possíveis recursos de mapeamento e comunicações. A maior vantagem da utilização de câmeras é o seu baixo custo. Entretanto, as imagens capturadas pelas câmeras estão sujeitas a alterações de iluminação, cores e efeitos dinâmicos relacionados à distância focal, que interferem no processamento das imagens. Entre os possíveis problemas estão incluídos a não detecção de obstáculos fixos ou móveis existentes, causando uma falsa impressão de segurança e também detecções imprecisas de obstáculos existentes no ambiente. Essa pesquisa faz parte de um projeto maior e mais complexo que visa garantir a segurança de operação com a utilização de um conjunto de sensores e vem sendo pesquisados e testados pela equipe do ITV.

### **3.1.1 Infraestrutura móvel para aquisição de vídeos**

A fim de realizar testes em campo com as câmeras, foi desenvolvida, pelo ITV, uma infraestrutura móvel para a operação simultânea dos equipamentos e gravação de vídeos. O objetivo desta implementação foi desenvolver uma infraestrutura autocontida, capaz de operar de maneira independente de qualquer outro elemento externo ao sistema. A infraestrutura possibilita a fixação dos equipamentos e fornece alimentação elétrica às câmeras e acessórios. O objetivo é permitir operar todas as câmeras simultaneamente, possibilitando a comparação dos resultados alcançados pelos diferentes sensores, nas mesmas condições de operação. Para essa pesquisa foram disponibilizadas somente as bases de imagem das câmeras Bosch VOT-320 e



Bosch MIC IP 7000 HD. Com essas câmeras já é possível obter imagens para compor o banco de dados da pesquisa. A adição de mais câmeras tornaria o desenvolvimento de algoritmos mais complexo e sem garantia de melhores resultados, uma vez que as outras câmeras existentes no teste possuíam recursos menos avançados.

A infraestrutura móvel, demonstrada na Figura 8, foi montada dentro do porta-malas de um veículo Renault Duster. Durante os testes, o porta-malas permaneceu aberto; o operador do sistema ficou sentado no banco de trás do veículo, de onde comandou as câmeras e os respectivos sistemas de gravação de imagens simultaneamente.



**Figura 8** – Câmeras e estrutura utilizadas para investigação do ambiente

Fonte: FREITAS; ZANETTI; MIOLA (2015)

A câmera Bosch MIC IP Dynamic 7000 é uma câmera comum (RGB), *full HD*<sup>25</sup>, com filtro antineblina, comunicação por protocolo Ethernet<sup>26</sup>, índice de proteção IP68<sup>27</sup>, PTZ (*Pan-Tilt-Zoom*). Bosch VOT-320 é uma câmera termográfica, com comunicação por protocolo Ethernet, índice de proteção IP66, possui imagens térmicas de onda longa, não resfriadas, mesmo sob condições de pouca visibilidade ou escuridão absoluta, com alta sensibilidade. Possui foco em objetos que irradiam calor e torna visíveis diferenças de temperatura de até 50 mK dependendo da distância do objeto filmado.

<sup>25</sup> *Full High Definition* ou alta definição

<sup>26</sup> Arquitetura de interconexão de redes locais baseada no envio de pacotes. Define cabeamento e sinais elétricos para a camada física, em formato de pacotes e protocolos para a subcamada de controle de acesso ao meio.

<sup>27</sup> IP (*Ingress Protection*) - indica o quão protegidas são as entradas de um objeto e determina o nível de resistência dos equipamentos contra água (partículas líquidas) e poeira (partículas sólidas). O número indica o grau de proteção sendo que quanto maior, mais protegido está o objeto.

Seguindo as diretrizes estipuladas, a infraestrutura móvel completa foi implementada conforme o diagrama apresentado na Figura 9, a seguir.

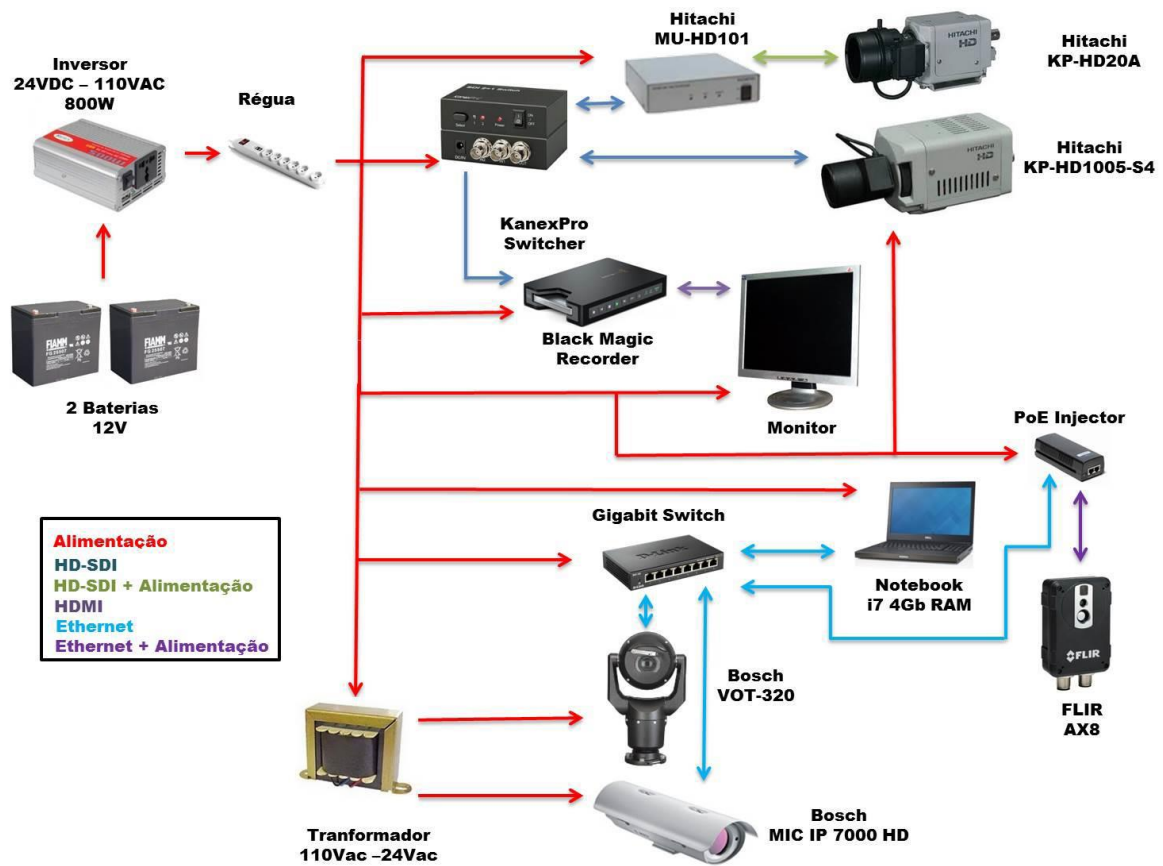
Na figura 9, a alimentação elétrica da infraestrutura é feita por duas baterias 12 Volts que ligadas em série fornecem 24Vcc para alimentação do inversor CC-CA (corrente contínua para corrente alternada). A saída do inversor é conectada a uma régua de tomadas que flexibiliza a utilização de várias cargas. Na régua foram conectadas as cinco câmeras presentes nos testes, um computador para configuração das câmeras, um monitor para visualização das imagens gravadas pelo *recorder*<sup>28</sup>, dois *switches* de rede para possibilitar a comunicação entre câmeras TCP/IP<sup>29</sup>. Um desses *switches* interligam o computador de configuração, o PoE Injector<sup>30</sup> que por sua vez alimenta e faz a comunicação com a câmera FLIR (não faz parte dessa pesquisa), a câmera Bosch VOT-320 e a câmera MIC IP Dynamic 7000. A alimentação elétrica dessas duas últimas foi feita através de um transformador de tensão 127Vca-24Vca.

---

<sup>28</sup> Dispositivo responsável pela gravação de imagens e áudio provenientes de câmeras e dispositivos de captura de áudio.

<sup>29</sup> Conjunto de protocolos de comunicação entre dispositivos em rede. Seu nome vem de dois protocolos: o TCP (*Transmission Control Protocol* - Protocolo de Controle de Transmissão) e o IP (*Internet Protocol* - Protocolo de Internet, ou ainda, protocolo de interconexão).

<sup>30</sup> PoE (*Power Over Ethernet*) – dispositivo que permite que a alimentação elétrica de equipamentos IP possa ser feita pelo próprio cabo de comunicação



**Figura 9** - Diagrama de montagem da infraestrutura móvel para testes de câmeras

Fonte: FREITAS; ZANETTI; MIOLA (2015)

### 3.1.2 Locais de execução dos testes

Os testes com câmeras para levantamento de imagens foram realizados em diferentes minas dos sistemas Sul, Sudeste e Norte da Vale. Segue a relação das minas visitadas e respectivas datas dos testes.

- Sistema Sul:
  - Mina Fábrica – 21/07/2015
  - Mina Pico – 12/08/2015
- Sistema Sudeste:
  - Mina Água Limpa – 22/07/2015
  - Mina Brucutu – 22/07/2015
  - Mina Fábrica Nova – 23/07/2015
  - Mina Fazendão – 23/07/2015
- Sistema Norte:
  - Mina Salobo – 27/07/2015

- Mina Carajás – 28 e 29/07/2015


### **3.1.3 Descrição dos vídeos dos testes e inferências sobre a diferença de percepção das cenas com imagens RGB e térmica**

Os experimentos realizados podem ser classificados em dois grupos principais: testes estáticos e testes dinâmicos. Durante os testes estáticos, o veículo no qual as câmeras foram instaladas permaneceu parado. As distâncias entre o veículo e os obstáculos nos testes foram aproximadamente 15m, 30m, 60m, 90m e 120m.

Nos testes dinâmicos, os alvos e/ou as câmeras mudaram de posição. Nos experimentos realizados, foram filmados veículos se movimentando em rampas de acesso e equipamentos em operação levantando poeira se locomovendo dentro da mina. Um dos principais objetivos dos experimentos consistiu em avaliar o desempenho das câmeras em diferentes condições de operação. Entre as condições investigadas estavam:

- Testes diurnos, com boas condições de iluminação;
- Testes noturnos, com pouca iluminação;
- Testes com presença de poeira;
- Testes com presença de neblina;
- Testes com presença de chuva.


Parte dos testes foram realizados combinando duas condições adversas, incluindo experimentos noturnos com a presença de poeira, neblina ou chuva. Os resultados do levantamento correspondem a imagens obtidas pelas duas câmeras, filmando simultaneamente as mesmas cenas. Desta forma, é possível comparar o desempenho de ambos instrumentos, nas mesmas condições de operação. Durante os testes com as câmeras, foram gerados inúmeros vídeos, totalizando 17,5 Gb de dados. A Figura 10 apresenta imagens de dois veículos trafegando na mina Carajás, no asfalto, sob a luz do sol. Esta corresponde a uma boa condição de operação, na qual o operador não teria problema em identificar a cena sem intermédio das imagens das câmeras.



**Figura 10** - Teste diurno, filmando dois veículos transitando numa estrada na mina Carajás

Fonte: FREITAS; ZANETTI; MIOLA (2015)

Além das minas da Vale, foi feito um teste na cidade de Ouro Preto, Minas Gerais. A Figura 11 apresenta imagens obtidas num final de tarde, próximo ao pôr do sol, com pessoas e veículos transitando numa ladeira. Neste caso é possível verificar que apenas parte do cenário observado está sob a incidência da luz solar, e mesmo assim a câmera termográfica consegue identificar as formas e contornos.



**Figura 11** - Teste diurno, filmando pessoas e veículos transitando numa ladeira na cidade de Ouro Preto


Fonte: FREITAS; ZANETTI; MIOLA (2015)

Os demais resultados de campo apresentados nesta seção correspondem a imagens obtidas pelas câmeras filmando rotinas e condições operacionais à noite. A principal característica de operação é a baixa luminosidade dos cenários observados. A Figura 12 e a Figura 13 apresentam imagens capturadas durante a noite, observando a mesma localidade dentro da mina, com a presença de estrada, leira e pontaletes com fita reflexiva. Na Figura 12, a região está iluminada pelo farol de um veículo. Já na Figura 13, a mesma região está sem iluminação.


Observa-se que a iluminação do farol não interfere nas imagens capturadas pela câmera termográfica Bosch VOT-320. Ambos termogramas apresentam boa

qualidade e definição, sendo possível diferenciar a estrada e a leira ao redor da mesma.

Já o desempenho da câmera Bosch MIC 7000 depende diretamente da iluminação da região. Na imagem da Figura 12, é possível identificar detalhes da estrada, leiras e pontaletes. Devido à baixa iluminação do ambiente, não é possível observar os mesmos detalhes na Figura 13.



**Figura 12** - Teste noturno com iluminação externa, filmando estrada, leira e pontalete na mina de Fábrica  
Fonte: FREITAS; ZANETTI; MIOLA (2015)



**Figura 13** - Teste noturno sem iluminação externa, filmando estrada, leira e pontalete na mina de Fábrica  
Fonte: FREITAS; ZANETTI; MIOLA (2015)

As Figuras 14, 15 e 16 apresentam imagens capturadas à noite nas minas de Fábrica, Fazendão e Salobo, ilustrando diferentes equipamentos da mineração em operação.

As imagens geradas pela câmera termográfica Bosch VOT-320 possuem boa qualidade e definição, independente das condições de iluminação no ambiente. Nestas imagens, é possível determinar a quantidade e os tipos de equipamentos que participam da operação.

O mesmo desempenho não é observado nas imagens captadas pela câmera Bosch MIC 7000, cujo desempenho é diretamente relacionado às condições de iluminação. Analisando as imagens, é possível detectar a presença de equipamentos em operação; entretanto, não fica claro para o expectador quantos e quais




equipamentos estão presentes em cada cena. Este efeito é agravado no caso em que há faróis apontando diretamente para a câmera.




**Figura 14** - Teste noturno filmando dois caminhões transitando na mina de Fábrica

Fonte: FREITAS; ZANETTI; MIOLA (2015)



**Figura 15** - Teste noturno filmando dois caminhões transitando na mina Fazenda

Fonte: FREITAS; ZANETTI; MIOLA (2015)




**Figura 16** - Teste noturno filmando três caminhões e uma escavadeira operando na mina do Salobo

Fonte: FREITAS; ZANETTI; MIOLA (2015)

A Figura 17 ilustra uma operação noturna na mina de Fábrica, onde é possível observar a presença de estrada, leiras, pontaletes e um veículo batedor posicionado a uma distância aproximada de 200m das câmeras, com o farol apontado na direção das mesmas.

Na imagem gerada pela câmera Bosch VOT-320, apesar de ser possível identificar alguns detalhes do terreno como leiras e montes para a fixação de pontaletes, o veículo aparece discretamente na imagem. Isto ocorre devido à elevada distância entre o veículo e a câmera. Outro detalhe importante é que as fitas refletivas presas ao pontalete não se destacam na imagem.




**Figura 17** - Teste filmando estrada, leira, pontaletes e um veículo localizado a 200m, se locomovendo em direção às câmeras, na mina de Fábrica

Fonte: FREITAS; ZANETTI; MIOLA (2015)

A capacidade das câmeras de identificar fitas reflexivas associadas a coletes, pontaletes e outras estruturas da mina é ilustrada nas Figuras 18 e 19. Estas imagens ilustram diferentes acessos filmados durante experimentos noturnos, realizados nas minas de Fábrica e Carajás. Cabe observar que as fitas refletivas equivalem aos principais pontos de referência para os operadores de equipamentos de mineração durante operações noturnas.

Nos termogramas obtidos pela câmera Bosch VOT-320, é possível identificar detalhes das estradas e leiras, além da presença de uma pessoa (Figura 19).


Apesar disso, a tecnologia de termografia não percebe as fitas refletivas presentes nos ambientes, utilizadas como sinalização durante operações noturnas. Esta incapacidade fica bem destacada nas Figuras 18 e 19, nas quais várias estruturas refletivas presentes nas minas não são identificadas.



**Figura 18** - Teste noturno filmando estrada, leira e pontaletes na mina de Fábrica

Fonte: FREITAS; ZANETTI; MIOLA (2015)






**Figura 19** - Teste noturno filmando leira, pontaletes e uma pessoa na mina de Carajás

Fonte: FREITAS; ZANETTI; MIOLA (2015)


A presença de poeira suspensa no ar corresponde a uma condição crítica, que pode prejudicar operações e danificar equipamentos utilizados na mineração. Para amenizar o problema, são utilizados sistemas de aspersão e caminhões pipa, transitando constantemente nas minas jogando água nas estradas e acessos.

As Figuras 20, 21 e 22 apresentam imagens capturadas à noite, ilustradas com a presença de estrada, leiras e pontalete com fita reflexiva. Durante este experimento equipamentos transitaram pelas estradas, levantando poeira no ar.




**Figura 20** - Teste noturno com presença de poeira, filmando estrada, leiras e pontalete na mina de Fábrica

Fonte: FREITAS; ZANETTI; MIOLA (2015)



**Figura 21** - Teste noturno com presença de poeira, filmando um caminhão localizado a 40m, na mina de Carajás

Fonte: FREITAS; ZANETTI; MIOLA (2015)




**Figura 22** - Teste noturno com presença de poeira, filmando um caminhão localizado a 29m, na mina Fazendão

Fonte: FREITAS; ZANETTI; MIOLA (2015)

A câmera Bosch VOT-320 apresenta resultados satisfatórios, fornecendo uma imagem com pouca interferência da poeira, na qual é possível reconhecer detalhes do caminhão. Já nas imagens obtidas pelas câmeras Bosch MIC 7000, é possível observar a presença da poeira em suspensão, dificultando a visualização de detalhes das imagens.

Além da baixa luminosidade e da poeira, a presença de neblina intensa é um dos principais fatores que acarreta a parada dos equipamentos de mineração e consequentemente gera perdas de produção.

As Figuras 23, 24 e 25 ilustram o desempenho da câmera termográfica em operações noturnas com a presença de neblina intensa, possibilitando a comparação com imagens obtidas por câmeras RGB. A Figura 23 apresenta imagens obtidas pelas câmeras Bosch VOT-320 e Bosch MIC 7000 observando um veículo de ré, a uma distância de aproximadamente 20m. Nas imagens geradas pelas câmeras Bosch MIC 7000 a detecção do veículo é facilitada pela luz de ré. Ainda assim, não fica claro, pelas imagens, qual é o tipo de veículo presente no ambiente, dificultando o seu reconhecimento.



**Figura 23** - Teste noturno com presença de neblina, filmando um veículo localizado a 20m, na mina de Brucutu

Fonte: FREITAS; ZANETTI; MIOLA (2015)

A imagem obtida pela câmera termográfica Bosch VOT-320 não capta a iluminação gerada pela luz de ré. O termograma não destaca o veículo do ambiente ao redor; isso ocorre devido ao fato de que o motor, que corresponde à principal fonte de calor do veículo, não ser diretamente visualizado pela câmera. Apesar das condições não ideais de operação, é possível reconhecer o veículo imerso na neblina.



**Figura 24** - Teste noturno com presença de neblina, filmando uma pessoa localizada a 10m e um veículo localizado a 40m, na mina de Brucutu  
Fonte: FREITAS; ZANETTI; MIOLA (2015)

Na Figura 24 acima, uma pessoa se desloca em relação ao veículo. Na imagem, a pessoa está a uma distância de 10 m das câmeras. Na Figura 25, são filmadas duas pessoas próximas a um veículo localizado a 30m da câmera.



**Figura 25** - Teste noturno com presença de neblina, filmando duas pessoas e um veículo localizados a 30m, na mina de Brucutu  
Fonte: FREITAS; ZANETTI; MIOLA (2015)

Este experimento da Figura 25 é um bom exemplo da capacidade da câmera termográfica de operar em ambientes com praticamente nenhuma iluminação. Mesmo com a presença de neblina intensa, a imagem captada pela câmera permite reconhecer o veículo e duas pessoas ao seu lado.

O mesmo não acontece com a câmera Bosch MIC 7000. Na imagem fornecida por esta câmera, é possível detectar apenas um pequeno ponto de luz; este ponto representa uma lanterna carregada por uma das pessoas ao lado do veículo. O resto


da imagem corresponde a ruídos de vídeo, gerados pelas condições desfavoráveis de operação.

A última condição climática adversa investigada durante os experimentos com câmeras é a presença de chuva. Chuvas intensas prejudicam a visibilidade dos operadores de equipamentos de mineração de maneira considerável, além de impactar diretamente nas estradas e acessos das minas. Esta também é uma condição crítica de operação, capaz de gerar grandes perdas de movimentação de minério.

Para produzir o ambiente de chuva, não presente naturalmente na época do levantamento dos dados, foram utilizados carros pipa durante os experimentos. Os carros pipa produziram jatos de água, posicionados entre as câmeras e os objetos alvos a serem identificados. Apesar da grande concentração de água gerada pelos carros pipa, as condições simuladas seriam semelhantes à operação das câmeras durante chuvas intensas e trombas d'água.

As Figuras 26 e 27 correspondem a experimentos em que as câmeras observam diferentes veículos posicionados atrás de jatos d'água. Na Figura 26, estão presentes na imagem uma escavadeira (atrás) e um caminhão (na frente). Já na Figura 27, há um caminhão (atrás) e um veículo batedor (na frente) posicionado diretamente embaixo do jato d'água.

A imagem da Figura 26 captada pela câmera termográfica Bosch VOT-320 permite detectar a presença de dois veículos atrás da cortina de água; apesar de possível, não é simples reconhecer quais são os veículos presentes no cenário.



**Figura 26** - Teste noturno com presença de jato d'água, filmando uma escavadeira e um caminhão, na mina do Salobo

Fonte: FREITAS; ZANETTI; MIOLA (2015)

Já na imagem da Figura 27, a câmera termográfica não permite a detecção dos equipamentos, devido ao contato direto da água com o veículo batedor.



**Figura 27** - Teste noturno com presença de jato d'água, filmando um caminhão e um veículo batedor, na mina Carajás

Fonte: FREITAS; ZANETTI; MIOLA (2015)

As imagens obtidas indicam que a tecnologia de fusão de imagens é promissora, aumentando a robustez do sistema ao se beneficiar das capacidades individuais das câmeras RGB e térmica.

### 3.2 Metodologia

Essa pesquisa aplicada desenvolve as etapas de aquisição e processamento de imagens, incluindo fusão de imagens térmicas e RGB; a detecção do ponto de fuga e da área dirigível da estrada, para posteriormente auxiliar na construção de um sistema de direção assistida capaz de fornecer informações aos motoristas, de forma a permitir a operação dos caminhões, em condições adversas e com pouca visibilidade. A aquisição da imagem RGB é essencial, pois essa imagem possui características semelhantes à visão humana. Sendo o sistema de direção assistida uma forma de auxiliar a operação de caminhões, a representação da cena semelhante à visão humana é primordial para gerar informação confiável sobre objetos à frente do caminhão de uma forma que o operador esteja acostumado.

Como foi comprovado pelos testes de campo realizados, apresentados na Seção 3.1.3, em uma cena capturada com câmera RGB é difícil identificar objetos e formas na presença de neblina e poeira, pois esses fenômenos obstruem a visualização da estrada. Já a câmera termográfica é capaz de detectar objetos e formas através de sua temperatura superficial, conseguindo identificá-los mesmo sob condições adversas. Entretanto a câmera termográfica não reproduz, através de sua imagem, uma cena parecida com a visão humana, o que dificulta seu uso isolado, além de não possibilitar a diferenciação das cores de objetos nas imagens.

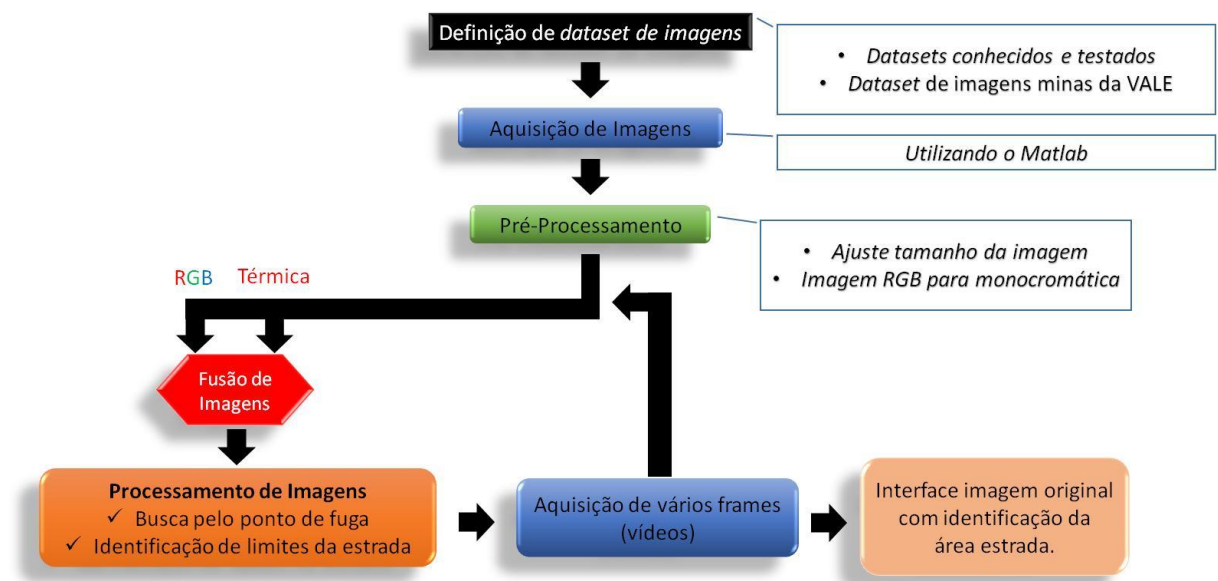
Assim, o ideal é realizar a fusão das imagens térmica e RGB para produzir uma imagem combinada, capaz de retratar a cena à frente do caminhão e que identifique

a diferença de cores dos objetos e vários níveis de brilho provenientes de luzes como fitas refletivas e faróis, com a informação adicional de objetos detectados pela câmera termográfica mesmo em condições climáticas adversas.

Para esse trabalho, de forma mais específica, foram definidas as etapas da pesquisa aplicada e da geração da prova de conceito sintetizadas a seguir:

- a) Análise e definição de base de dados de imagens a ser utilizada;
- b) Aquisição de imagens;
- c) Pré-processamento de imagens;
- d) Fusão de imagens;
- e) Processamento da imagem para encontrar o ponto de fuga da estrada e definição da região dirigível da estrada;
- f) Aquisição e indicação da área da estrada em vários quadros sequenciais.

A Figura 28 ilustra a sequência de execução das etapas da pesquisa listadas acima.



**Figura 28** - Etapas do método para processamento de imagens

Fonte: elaborado pelo autor

A seguir são detalhadas as atividades realizadas em cada uma das etapas ilustradas na Figura 28.

### 3.2.1 Definição da base de dados (*dataset*) de imagens existentes

Os testes e levantamento de dados realizados pela equipe do ITV, descritos na Seção 3.1, forneceram imagens e vídeos que compuseram a base de dados de imagens dessa pesquisa. Para validação de algoritmos pesquisados, foram utilizados



também bases de imagens de autores e imagens da internet, quando foi possível a aquisição dessas junto às suas respectivas fontes.

A base de imagens filmadas pelo ITV foi filtrada e foram selecionadas algumas imagens e trechos de vídeos. Alguns vídeos têm tanto ruído, que mesmo com a aplicação de filtros robustos não há como utilizar suas imagens nos algoritmos propostos. A redução dos ruídos passa pela aplicação de filtros passa baixa, pois os mesmos estão relacionados com altas frequências. Com isso, a imagem é suavizada alterando consideravelmente seus detalhes que demonstram a textura do solo. A aplicação de filtros passa baixa altera os resultados dos filtros aplicados para identificação de texturas, o que inviabiliza o uso dessas imagens para algoritmos que usam essa técnica.

Outras imagens foram filmadas em ambientes onde não há estrada: praças de carregamento por escavadeiras, pátios de troca de turno de caminhões, entre outros. Nesses casos, as imagens e vídeos foram desprezados, pois o foco da pesquisa é trabalhar com estradas. Ao final da seleção de imagens e vídeos foram selecionados os seguintes cenários, identificados por: “Ce” (cenário estático) e “Cd” (cenário dinâmico) seguidos de um sequencial numérico:

- Ce1 - Caminhão de grande porte passando na frente da câmera;
- Ce2 - Caminhonete passando e levantando poeira;
- Ce3 - Simulação de chuva utilizando o caminhão pipa;
- Cd1 - Percurso em movimento ao longo de uma estrada da mina;
- Cd2 - Percurso em movimento ao longo de uma estrada da mina, contendo obstáculos e outros veículos em movimento;
- Cd3 - Percurso em movimento ao longo de uma estrada da mina, com veículo à frente da câmera;

Para todos os cenários, há vídeos filmados pela câmera RGB e térmica. Ambas filmagens foram feitas no mesmo instante, estando sincronizadas. Entretanto, as câmeras têm uma pequena defasagem de posição, pois foram instaladas lado a lado no veículo que fez o levantamento. A resolução das câmeras é diferente, o que gera imagens de tamanhos diferentes. O tamanho das imagens e a defasagem são ajustados na fase de pré-processamento. As imagens foram capturadas com taxas de gravação de quadros, ou fps (*frames per second*), diferentes. As imagens utilizadas,

totalizando 80 (40 RGB e 40 térmicas), para o teste do algoritmo são quadros dos vídeos filmados das câmeras RGB e termográfica.

Além dos vídeos do teste do projeto de Direção Assistida, imagens obtidas de bases disponíveis na internet também foram utilizadas. A fonte das imagens foi o Google, realizando pesquisa através das palavras chaves “*unstrucutre road dataset*”. Essas imagens e vídeos serviram de referência para os primeiros testes dos algoritmos elaborados. Por se tratarem de imagens em ambientes onde a definição de formas e da estrada é mais nítida, faz sentido testar os algoritmos primeiramente nessas imagens e vídeos, para depois aplicá-los nas imagens das minas que possuem grande quantidade de ruídos e poderiam prejudicar os resultados preliminares. Procurou-se buscar imagens com estradas em asfalto com a cor e limites bem definidos e em ambientes de estradas não pavimentadas. Por fim, imagens utilizadas por autores foram adquiridas de artigos de bases científicas renomadas no assunto. No total, foram utilizadas 100 imagens em cenários como estradas de terra, neve, deserto, cenas noturnas e estradas pavimentadas. Foram utilizados também 5 vídeos de estradas pavimentadas e não pavimentadas, sendo um deles sob forte neblina.

### **3.2.2 Aquisição de imagens**

A etapa de aquisição de imagens consiste basicamente em ler uma imagem ou vídeo de um dispositivo de captura, uma câmera por exemplo, ou de um arquivo de base de dados previamente capturado. Para essa pesquisa, como já esclarecido na Seção 3.2.1, foram utilizadas a base de dados dos testes efetuados pelo ITV nas minas da Vale e a base de dados da internet e de autores.

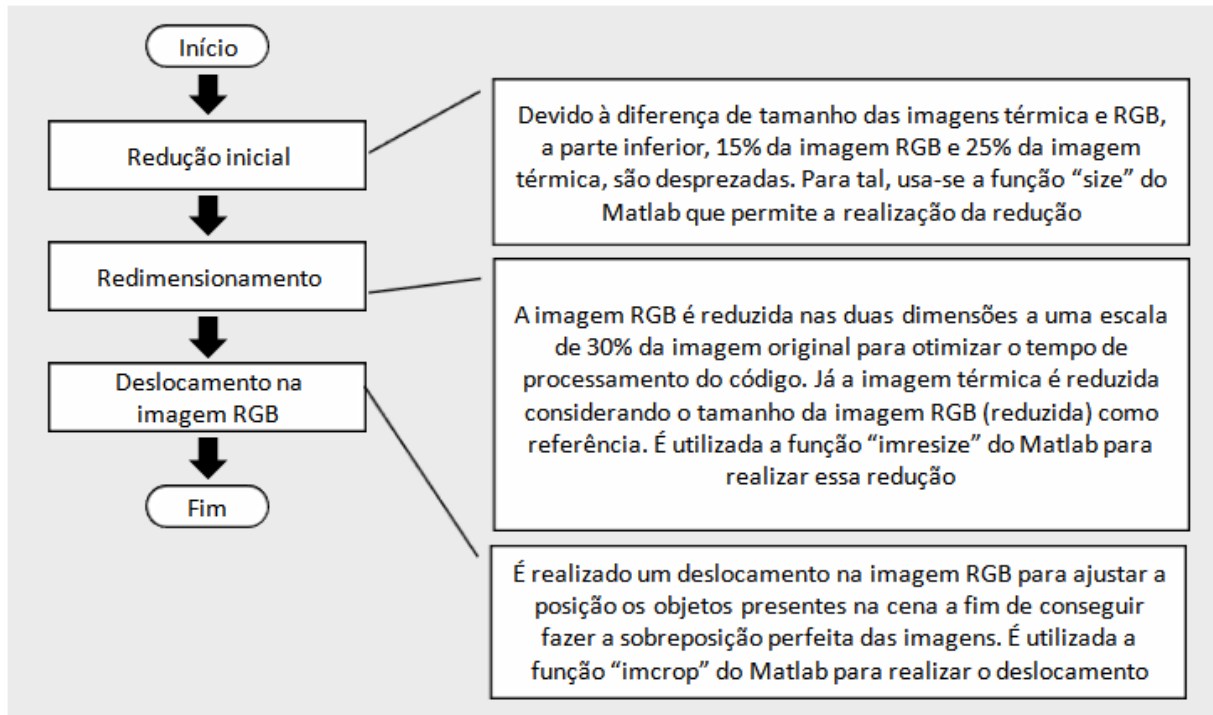
Após a leitura da imagem ou vídeo, utilizando o software Matlab, o algoritmo traduz o formato ou padrão de imagem conhecido, como por exemplo, JPG, TIFF, BMP, utilizados para visualização em sistemas computacionais, para um padrão de dados capaz de ser processado e analisado. Foram efetuadas transformações nos sistemas de cores das imagens para possível aplicação em determinadas funções dos algoritmos. A imagem originalmente no mapa RGB foi transformada em escala de cinza, HSV e Lab.

Para leitura de imagens e vídeos da base de dados de testes do ITV, foram executados algoritmos de adequação de tamanho e posição das imagens, pois as câmeras geram imagens de diferentes tamanhos e estavam instaladas no veículo no



qual foi feita a filmagem lado a lado, gerando uma pequena defasagem de posição. É necessário as imagens serem idênticas com relação ao tamanho e posição, pois na próxima etapa de fusão, as mesmas devem ficar sobrepostas.

O algoritmo de adequação do tamanho da imagem e dos vídeos é descrito na Figura 29.



**Figura 29** - Algoritmo de adequação do tamanho das imagens

Fonte: elaborado pelo autor

Outra adequação necessária é a quantidade de quadros por segundo. Apesar dos vídeos terem o mesmo tempo total, a quantidade de quadros por segundo varia. Como o algoritmo deve ler quadro a quadro, para posteriormente executar o processamento de imagens, os quadros dos vídeos devem ter as formas da imagem na mesma posição, possibilitando sua perfeita fusão. Portanto, o algoritmo considerou um pequeno atraso de quadros para o vídeo das imagens térmicas que possuem naturalmente menos quadros que o vídeo das imagens RGB. Devido a esse atraso, alguns quadros do vídeo de imagens RGB são desprezados, o que não interfere na dinâmica geral do vídeo, que possui 15 quadros por segundo.

É importante entender os padrões das imagens para ser possível traduzi-las da melhor forma em estruturas de dados matriciais, que são facilmente processados e analisados de acordo com a necessidade do algoritmo.

### 3.2.3 Pré-processamento de imagens

A principal tarefa a ser executada nessa etapa é a adequação da imagem para o processamento em relação à forma, textura e cor. A imagem na maioria das vezes é capturada com elementos indesejáveis para seu processamento, que precisam ser eliminados por estarem em baixa qualidade, podendo algum filtro atuar como otimizador.

Muitas imagens da base da Vale disponível foram gravadas durante a noite e com baixa luminosidade. Entretanto, como já citado, para a retirada dos ruídos relacionados com altas frequências da imagem, é necessário aplicar filtros passa-baixa que retiram as altas frequências não alterando as baixas. Na prática, esse filtro suaviza a imagem, alterando a textura que interfere na aplicação dos algoritmos de encontro do ponto de fuga. Na Figura 30 foi aplicado um filtro passa baixa.



**Figura 30** - Imagem original (esq.), imagem filtrada para retirada de ruído (dir.)

Fonte: FREITAS; ZANETTI; MIOLA (2015)

Na imagem original da esquerda é possível perceber uma quantidade maior de ruído, principalmente na região do céu, onde o fundo é preto. Na imagem da direita, na qual foi aplicado o filtro passa baixa, os ruídos diminuíram, mas a alteração de textura também foi suavizada, o que influenciaria negativamente o algoritmo. Portanto, os filtros devem ser utilizados com cuidado quando se trata de um processamento de imagens com análise de textura.

Nessa pesquisa, a imagem RGB foi filtrada após ser lida utilizando um “Filtro Mediana” de duas dimensões, com uma área de atualização de 3x3 *pixels*. Ou seja, cada *pixel* recebeu, após a execução do filtro, o valor médio dos *pixels* a sua volta. Para a imagem térmica não se percebeu nenhuma vantagem na utilização de filtros e os mesmos não foram utilizados.

### 3.2.4 Fusão das imagens

Essa etapa é executada após o pré-processamento de imagens, para auxiliar a aplicação dos algoritmos de processamento das imagens RGB e térmica após a fusão, interpretando-as como uma única imagem, dando mais robustez ao algoritmo. Imagens RGB sofrem interferências consideráveis das luzes presentes na mina, como faróis de veículos, por exemplo. A poeira também interfere bastante na imagem RGB como demonstrado anteriormente. Dessa forma, a fusão da imagem RGB com a imagem térmica, que sofre menos interferências, é benéfica à execução do algoritmo, facilitando a identificação da estrada.

Nessa pesquisa, foi utilizado o método *Alpha Compositing* descrito na Seção 2.2 dessa dissertação.

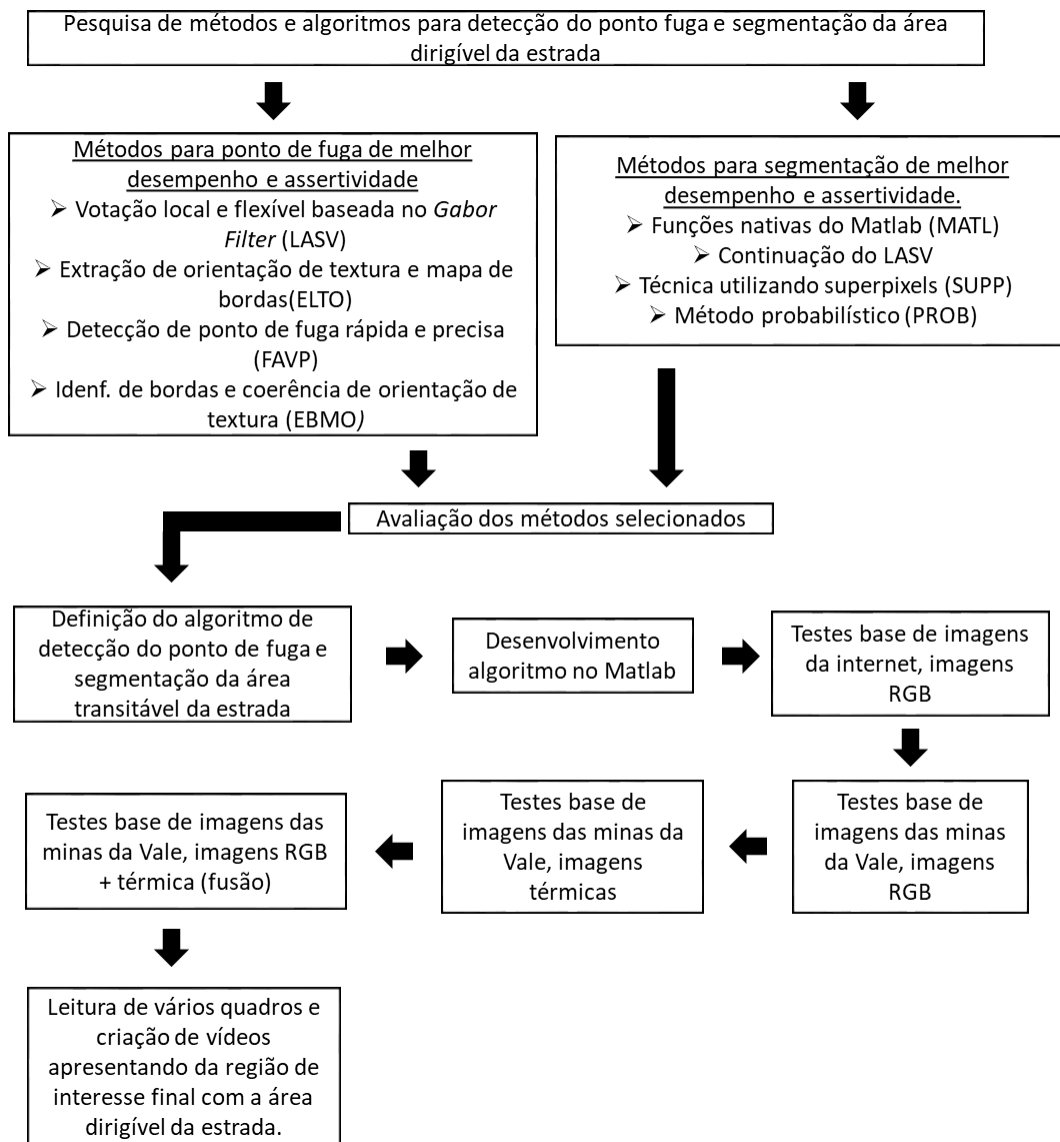
### 3.2.5 Processamento das imagens

Após a aquisição das imagens e vídeos e a execução do pré-processamento e fusão das imagens, a próxima etapa a ser executada, de acordo com a metodologia apresentada na Figura 28, é o processamento das imagens para identificação da área trafegável da estrada. Essa etapa envolveu uma série de algoritmos e técnicas. Muitas técnicas foram pesquisadas e estão descritas na revisão bibliográfica dessa dissertação, porém, somente algumas foram consideradas com desempenho e assertividade adequadas para o ambiente agressivo da mineração. A Figura 31 ilustra o processo adotado na seleção das técnicas para o processamento de imagens, elencando todas as etapas para definição dos algoritmos de encontro do ponto de fuga e segmentação da área da estrada.

#### 3.2.5.1 Algoritmo para encontrar o ponto de fuga

O cenário das estradas das minas, sob condições climáticas adversas, exige algoritmos robustos capazes de lidar com imagens aonde é difícil a definição de formas, com pouca alteração de cores e baixa luminosidade.

Conforme definido por Kong; Audibert; Ponce (2010) acontece um fenômeno natural em estradas não pavimentadas, onde a orientação de textura do solo é alterada por sulcos de marcas de pneus que definem a direção do ponto de fuga da estrada. No caso de estradas curvas essas linhas diminuem de tamanho, mas como há a extensão das mesmas, após a normalização é possível também encontrar o ponto de fuga.



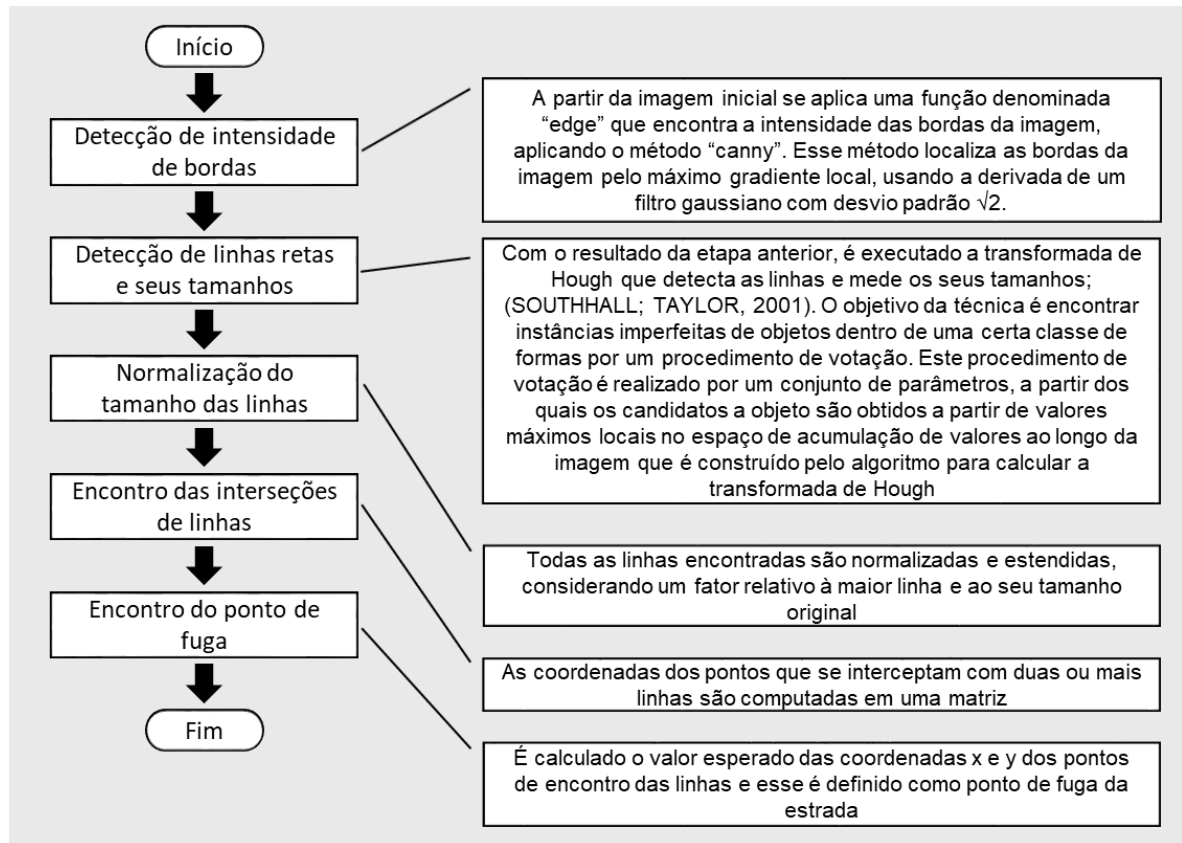
**Figura 31** - Fluxo do processo de desenvolvimento do algoritmo de processamento de imagens

Fonte: elaborado pelo autor

Na tentativa de definir o melhor método para encontrar o ponto de fuga das estradas, os quatro algoritmos considerados de melhor desempenho e com maior assertividade nos resultados, de acordo com a pesquisa, foram estudados detalhadamente. Os algoritmos foram implementados no Matlab, desenvolvendo códigos e efetuando os devidos testes.

Diante da falta de resultados satisfatórios, utilizando as informações, ferramentas e recursos disponíveis, foi proposto um novo método além dos quatro pesquisados e descritos. Os resultados e motivos que levaram a não utilização e tratativas efetuadas em cada algoritmo estão descritas na seção de resultados dessa dissertação.

Tomando como base o algoritmo EBMO, o algoritmo desenvolvido pelo autor dessa dissertação identifica e lista as principais linhas retas da imagem e o valor esperado dos pontos de interseção das linhas indica o ponto de fuga. Baseado nisso, a Figura 32 ilustra o método desenvolvido pelo autor, com os passos para a execução do algoritmo proposto.



**Figura 32 - Algoritmo final utilizado para detecção do ponto de fuga**

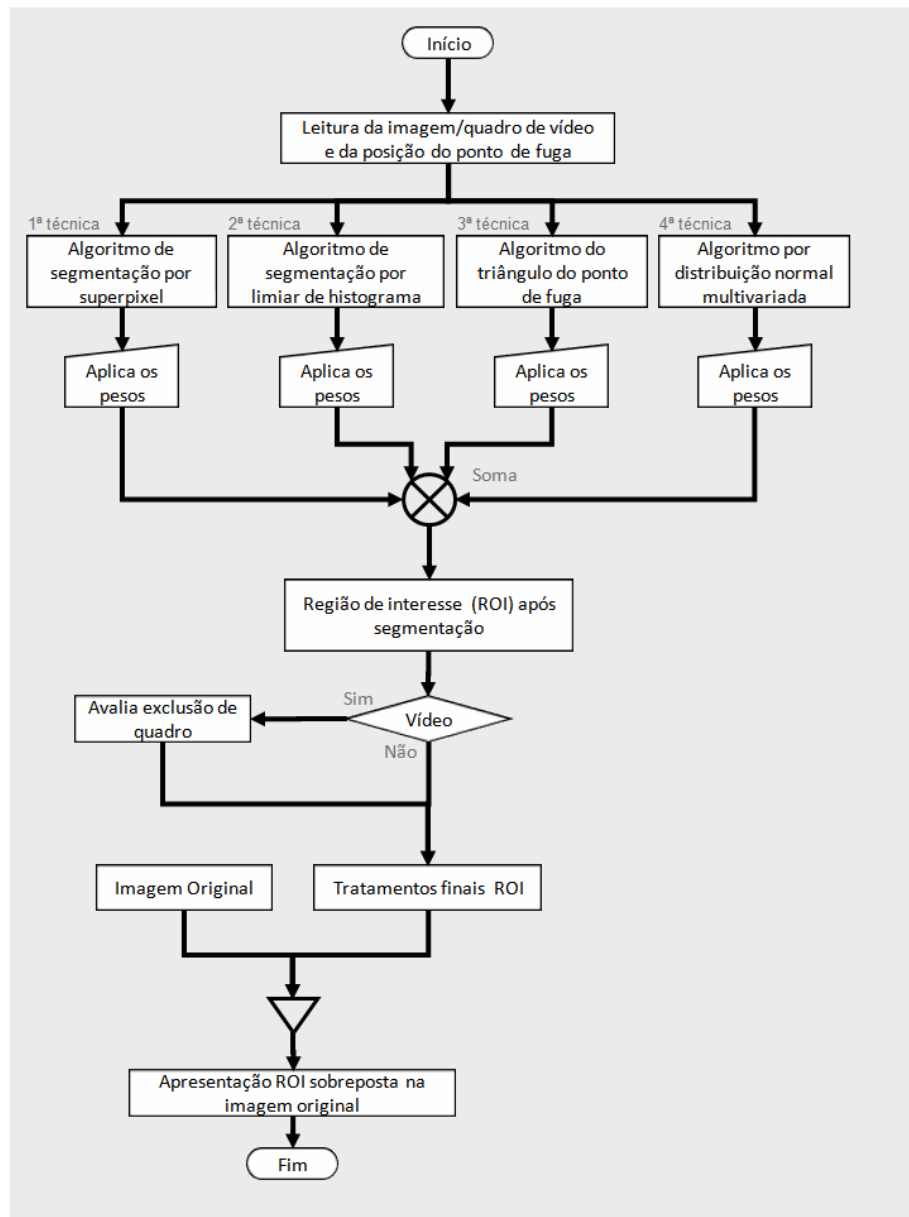
Fonte: elaborado pelo autor

### 3.2.5.2 Algoritmo para segmentação da área da estrada

A segunda parte do algoritmo de processamento de imagens passa pela definição da área dirigível da estrada. Para essa etapa, são utilizadas quatro técnicas denominadas: a) *superpixel*; b) segmentação por limiar de histograma de cores RGB; c) triângulo de ponto de fuga; d) segmentação por Distribuição Normal Multivariada.

Para chegar a essas quatro técnicas, foi investigado o conteúdo científico apresentado na Seção 2.4 dessa dissertação. As técnicas foram selecionadas devido aos bons resultados apresentados pelos autores e a aderência das mesmas ao ambiente de estradas de mina, ponto chave para essa pesquisa. A terceira técnica foi desenvolvida pelo autor dessa dissertação e tem como base o ponto de fuga já encontrado pelo método descrito da Seção 3.2.5.1.

A Figura 33 apresenta os passos do algoritmo final de forma simplificada. Para facilitar seu entendimento, os detalhes de cada que são apresentados posteriormente.



**Figura 33** - Algoritmo final utilizado para segmentação da região de interesse da estrada

Fonte: elaborado pelo autor

#### a) Primeira técnica – Segmentação por superpixel

A primeira técnica é fundamentada na utilização da função “*superpixel*” do Matlab. Essa função tem como parâmetros de entrada a imagem que sofrerá a segmentação, o número de *superpixel* a serem segmentados e uma variável (verdadeira ou falsa) que define se a variável de entrada tem mapa de cores Lab ou não.

Essa função encontra áreas na imagem que são denominadas *superpixels*, que nada mais são que *pixels* originais agrupados por afinidade de cores. É utilizado o

algoritmo *Simple Linear Iterative Clustering* (SLIC) (ACHANTA, *et al.*, 2012). O algoritmo começa definindo *clusters centers* (pequenas sub-regiões na imagem com um *pixel* central em cada uma delas) em função da posição e cores no mapa Lab. O número de *clusters centers* é definido por uma variável  $k$ . Os centros dos *clusters centers* são movidos para locais na imagem de menor gradiente, evitando assim que eles se localizem nas bordas, o que dificultaria a execução do algoritmo. Cada *pixel* na imagem é então associado a um *cluster center* limitando a zona de busca em duas vezes o tamanho do *cluster center*. No próximo passo, é calculado a distância de cada *pixel* dos *clusters* ao seu centro e são atualizados os centros para coincidirem com o vetor médio de todos os *pixels pertencentes* ao *cluster* no domínio de cores Lab.

### b) Segunda técnica – Limiar e histograma

A segunda técnica utiliza, inicialmente, segmentação através de um limite encontrado no histograma da imagem, em escala de cinza, utilizando método definido por Otsu, (1979). Tomados os *pixels* de uma imagem em escala de cinza, os mesmos são representados em  $L$  níveis de cinza  $[1,2,...L]$ . Seu histograma pode ser normalizado e considerado como uma distribuição de probabilidade de acordo com a Equação 26:

$$\sum_{i=1}^L p_i = 1 \quad (26)$$

Supõe-se que os *pixels* são classificados em duas classes ( $C_0$  e  $C_1$ ), nomeadas como plano de fundo (*background*) e objetos, respectivamente, e fracionadas por um limiar  $k$ ;  $C_0$  é definido pelos níveis de cinza  $[1,2,...k]$  e  $C_1$  é definido pelos níveis  $[k+1,...L]$ . As probabilidades de uma classe ocorrer (Equações 27 e 28) e as médias dos níveis das classes (Equações 29 e 30) são dadas por:

$$\omega_0 = \sum_{i=1}^k p_i = \omega(k) \quad (27)$$

$$\omega_1 = \sum_{i=k+1}^L p_i = 1 - \omega(k) \quad (28)$$

$$\mu_0 = \sum_{i=1}^k \frac{ip_i}{\omega_0} = \frac{\mu(k)}{\omega(k)} \quad (29)$$

$$\mu_1 = \sum_{i=k+1}^L \frac{ip_i}{\omega_1} = \frac{\mu_T - \mu(k)}{1 - \omega(k)} \quad (30)$$

sendo  $\mu_T$  os momentos cumulativos de primeira ordem do histograma até o  $k$ -ésimo termo, respectivamente, definido pela Equação 31:

$$\mu_T = \sum_{i=1}^L ip_i \quad (31)$$

As variâncias das classes são definidas pelas Equações 32 e 33:

$$\sigma_0^2 = \sum_{i=1}^k \frac{(1 - \mu_0)^2 p_i}{\omega_0} \quad (32)$$

$$\sigma_1^2 = \sum_{i=k+1}^L \frac{(1 - \mu_1)^2 p_i}{\omega_1} \quad (33)$$

Para avaliar a eficiência do limiar  $k$ , são introduzidos três critérios distintos:

$$\lambda = \frac{\sigma_B^2}{\sigma_W^2} \quad \kappa = \frac{\sigma_T^2}{\sigma_W^2} \quad \eta = \frac{\sigma_B^2}{\sigma_T^2} \quad (34)$$

sendo:

$$\sigma_W^2 = \omega_0 \sigma_0^2 + \omega_1 \sigma_1^2 \quad (35)$$

$$\sigma_B^2 = \omega_0 \omega_1 (\mu_1 - \mu_0)^2 \quad (36)$$

$$\sigma_T^2 = \sum_{i=1}^L (1 - \mu_T)^2 p_i \quad (37)$$

O problema é reduzido à busca do limiar  $k$  que maximiza uma das funções do critério. Sabendo que os critérios são equivalentes entre si, é possível notar que  $\sigma_W^2$  e  $\sigma_T^2$  estão em função do limiar  $k$  e  $\sigma_B^2$  é independente de  $k$ . Também,  $\sigma_W^2$  é baseado em estatística de segunda ordem (variâncias), enquanto  $\sigma_B^2$  é baseado em estatística de primeira ordem (médias). Dessa forma,  $\eta$  (contido na Equação 34) é o critério mais simples para encontrar a função de otimização do limiar  $k^*$ , sendo  $*$  o identificador de  $k$  onde  $\sigma_B^2(k)$  tem o valor máximo, que é definida pela Equação 38:


$$\sigma_B^2(k^*) = \max_{1 \leq k \leq L} \sigma_B^2(k) \quad (38)$$



O valor de  $k$  \* permite a imagem ser segmentada fazendo a divisão das duas classes definidas pelo método. Antes da aplicação do método descrito, deve ser calculado o histograma da imagem original nos três canais de cores RGB e aplicá-lo individualmente em cada canal. Após a aplicação da segmentação, é verificado o resultado na parte inferior da imagem que normalmente contém parte da estrada a ser segmentada. Se a imagem segmentada não contiver, na parte inferior, a maioria dos *pixels* que representem a estrada, significa que o resultado ficou invertido e o mesmo é ajustado.

Para retirada de partes da imagem segmentada que sejam indesejadas, como por exemplo, o céu, é criado um limite definido pela aplicação da função “bwmorph” utilizando o parâmetro de entrada “skel”. Essa função faz uma operação morfológica na imagem binária segmentada, removendo *pixels* nas partes interiores dos objetos, mas não permite que os objetos se separem. Os *pixels* restantes compõem o esqueleto da região de interesse. Se o esqueleto da região de interesse tiver uma ruptura ao se passar linhas horizontais, igualmente espaçadas, é identificada uma descontinuidade de limites, o que mostra que a parte superior a esses limites não representa a continuação da área da estrada, que está sendo identificada. A parte superior da ruptura é eliminada da região de interesse segmentada.

A Figura 34 demonstra um exemplo real de aplicação da função “bwmorph” em que a linha vermelha da terceira imagem define o limite para a eliminação da parte superior à mesma.



**Figura 34** - Exemplo de aplicação da função *bwmorph* com o parâmetro *skel*.

Fonte: Acervo do autor

Após a aplicação da função “bwmorph” é realizado tratamento final na região de interesse binária segmentada unindo *pixels* isolados e preenchendo pequenos buracos com as funções “imclose” e “imfill” respectivamente.

### c) Terceira técnica – Triângulo do ponto de fuga

A terceira técnica utiliza a função do Matlab “roipoly” para encontrar uma área que representa um triângulo definido pelo ponto de fuga, encontrado utilizando o método descrito na Seção 3.2.5.1 e as duas extremidades inferiores da imagem (esquerda e direita) que de uma forma grosseira representam a área dirigível da estrada. A função do Matlab retorna um polígono, que determina a região de interesse no formato de imagem binária na qual todos os *pixels* interiores às bordas do polígono são verdadeiros e os demais falsos. Somente essa técnica não proporciona uma segmentação satisfatória, mas aliada com as outras técnicas, colabora significativamente para a detecção da área da estrada.

#### **d) Quarta técnica – Distribuição normal multivariada**

A quarta e última técnica utiliza o método probabilístico do algoritmo PROB para verificar de qual região cada *pixel* (abaixo do ponto de fuga) pertence. Assim, a partir de uma imagem com todos os *pixels* em zero (falso lógico), de mesmo tamanho da imagem original, os *pixels* que pertencerem à área da estrada ganham o valor verdadeiro.

Inicialmente são definidas matrizes constituídas pelos dados dos seis canais de cores (RGB e HSV) e das cinco regiões identificadas na Figura 8. Com essas regiões definidas, são criadas distribuições para cada conjunto de dados, utilizando a função “fitdist” com o parâmetro “Normal” que define a distribuição como uma curva gaussiana. Para cada distribuição é calculada a média utilizando a função “mean”. É calculada as duas matrizes de covariância, sendo a primeira entre as três áreas pertencentes à estrada e a segunda das duas áreas de fora da estrada, utilizando a função “cov”, onde os valores de entrada são as médias. São calculados os pesos de cada distribuição, presentes na Equação 22, pela razão entre o número de *pixels* da distribuição e o número todas de todas as distribuições. A probabilidade de um determinado *pixel* estar dentro de uma distribuição (Equação 24) é calculada utilizando a função “mvnpdf” que possui como parâmetros de entrada: o valor do *pixel* testado; o vetor da média dos 6 canais de cores (RGB e HSV) da distribuição; a matriz de covariância de dentro ou fora da estrada. Por fim, é calculado qual soma de probabilidade (dentro ou fora da estrada, Equação 22) foi maior para segmentar o *pixel*.

#### **e) Composição da ROI (*Region of Interest* – Região de Interesse) final segmentada**

Após executadas as quatro técnicas, é possível compor a região de interesse final segmentada. Para tal, são definidos experimentalmente pesos para cada resultado obtido com as técnicas. No caso da segunda técnica de segmentação, são definidos pesos para cada canal de cor RGB resultante. O cálculo é realizado através do somatório de todas as imagens segmentadas em cada técnica, de acordo com a Equação 39, para posteriormente segmentar a imagem final, através de um limite  $k$  encontrado experimentalmente de acordo com a Equação 40. A região segmentada recebe um mapa de cores RGB sendo selecionada a cor vermelha para exibição do resultado final:

$$Im_{final}(x, y) = \sum_{i=1}^6 I_i(x, y) \cdot P_i \quad (39)$$

$$ROI_{final}(x, y, 1) = \begin{cases} 255, & \text{tal que } Im_{final}(x, y) \geq k \\ 0, & \text{tal que } Im_{final}(x, y) < k \end{cases} \quad (40)$$

$$ROI_{final}(x, y, 2) = 0 \text{ e } ROI_{final}(x, y, 3) = 0, \text{ para todo } x \text{ e } y$$

sendo  $i$  o índice da técnica ou método utilizado;  $I(x, y)$  o resultado binário da segmentação de uma técnica  $i$ ;  $P_i$  o peso dado para a técnica  $i$  variando de 0 a 1;  $Im_{final}(x, y)$  é a imagem binária final e  $ROI_{final}(x, y, 1)$  é a região de interesse no canal vermelho.

Antes de gerar o resultado final, alguns últimos ajustes são efetuados na imagem. É aplicado ao resultado final, a função “imfill” que preenche falhas e lacunas na região segmentada da imagem para evitar pequenos “buracos”.

Para retirar os *outliers*<sup>31</sup>, é implementado um algoritmo usando a função “bwmorph” com o parâmetro “open” que realiza uma operação morfológica na região de interesse, realizando uma operação de erosão seguida de uma dilatação. A operação de erosão altera o valor dos *pixels* com o menor valor da vizinhança do mesmo. A operação de dilatação, de forma contrária, altera o valor dos *pixels* com o maior valor da vizinhança dos mesmos. Na prática, a região de interesse sofre um “emagrecimento” nas áreas que têm pouca conectividade e depois um “inchaço”. Isso faz com que regiões com pouca conectividade, que são *outliers*, sejam desconectadas da maior área que representa a estrada. Dessa forma, formam-se subáreas que são

---

<sup>31</sup> Valor aberrante ou valor atípico, é uma observação que apresenta um grande afastamento das demais da série

eliminadas utilizando a função “bwconncomp” que identifica o tamanho das áreas e permite que seja mantida somente a maior área que representa a área transitável da estrada.

Para finalizar o algoritmo, o resultado da segmentação é sobreposto à imagem original. No caso de processamento de vídeo, o resultado da segmentação é sobreposto ao quadro do vídeo original e o algoritmo passa para a análise do próximo quadro. Para realizar a sobreposição de imagens, utiliza-se a função “imshowpair” do Matlab com o parâmetro de entrada “blend”. Aplicando esse método encontra-se de maneira rápida e eficiente a região da estrada que é transitável.

### **3.2.6 Aquisição de vários quadros (*frames*)**

Após definida a região de interesse pela Equação 40 e a realização dos ajustes finais, os quadros resultantes devem ser apresentados em uma imagem através de uma interface. O Matlab possibilita a criação de vídeos a partir de quadros individuais e a manipulação dos mesmos efetuando comandos de “*start, pause e stop*”. Porém, não é possível salvar dinamicamente esses vídeos em arquivos com formatos padrões como, por exemplo, “.avi, .mp4”. Assim, os quadros foram salvos em formato de imagem e os vídeos, demonstrando os resultados finais, foram criados utilizando o software editor de vídeos VideoPad.

Utilizando como base o método proposto por Yoon, *et al.* (2016) e descrito na Seção 2.5 dessa dissertação, cada quadro é avaliado com os quadros anteriores e uma grande diferença entre eles significa que houve um erro na execução do algoritmo, pois a forma da estrada à frente do veículo não se altera de forma abrupta, em menos de um segundo.

Como o vídeo resultante possui 15 quadros por segundo, os últimos 15 quadros são avaliados para verificar alterações. Ou seja, grandes variações são avaliadas a cada segundo do vídeo. Experimentalmente, verificou-se que os erros contribuem, de forma aleatória, para o aumento da região de interesse. Portanto, se o quadro em processamento alterar mais de 30% em relação ao anterior e essa alteração for no sentido de aumento da região de interesse, esse quadro é descartado, mantendo o anterior desprovido de erros. A cada ciclo do algoritmo, a imagem atual é atualizada impedindo que ocorra um erro permanente.

## 4. IMPLEMENTAÇÕES REALIZADAS E RESULTADOS OBTIDOS

Como ilustrado na Figura 28, após a avaliação e testes dos algoritmos selecionados, foi possível criar o algoritmo final apresentado nessa dissertação. Os resultados obtidos com esses códigos estão divididos em três categorias: fusão de imagens, resultados para a detecção do ponto de fuga e resultados para segmentação da área dirigível da estrada, os mesmos são apresentados a seguir nessa ordem. Alguns algoritmos não tiveram resultados satisfatórios na detecção do ponto de fuga, o que impediu o teste de segmentação da estrada, que seria uma continuação do mesmo. Outros não calculam o ponto de fuga e já partem para a segmentação da estrada. A Tabela 1 ilustra essas situações.

**Tabela 1** - Algoritmos e etapas para apresentação de resultados


Algoritmo	Deteção do Ponto de Fuga	Resultado ponto de fuga	Segmentação da Estrada	Resultado Segmentação
LASV	Possui	<u>Ruim</u>	Possui	Não realizado devido aos resultados ruins para o ponto de fuga
ELTO	Possui	Não realizado pois foi despriorizado em relação aos outros métodos	Possui	Não aplicável
FAVP	Possui	<u>Razoável</u>	Não possui	Não aplicável
EBMO	Possui	<u>Satisfatório</u>	Não possui	Não aplicável
MATL	Não possui	Não aplicável	Possui	<u>Ruim</u>
SUPP	Não possui	Não aplicável	Possui	<u>Satisfatório. Utilizado no algoritmo final de segmentação de estradas</u>
PROB	Idêntico ao LASV	Ruim	Possui	<u>Ruim. Utilizado no algoritmo final de segmentação de estradas</u>

Fonte: elaborado pelo autor

O algoritmo LASV teve resultados ruins para a detecção do ponto de fuga e, portanto, não foi desenvolvido código para segmentação da estrada utilizando esse algoritmo. O algoritmo ELTO não foi priorizado em relação aos outros pois a base de imagens apresentada nos artigos fontes eram basicamente de estradas pavimentadas, bem diferentes das existentes nas minas. O algoritmo MATL foi desenvolvido como teste inicial e não é aplicável para atingimento dos resultados finais esperados. Os outros algoritmos, indicados na Tabela 1, foram priorizados para o desenvolvimento de códigos no Matlab, sendo apresentados posteriormente nas Seções 4.2 e 4.3.

## 4.1 Fusão de imagens

A Figura 35 contém imagens típicas de um ambiente de mina. Para possibilitar a fusão das imagens RGB e térmica, foi reduzido o tamanho da imagem RGB para coincidir com a imagem térmica, através da função “imresize” do Matlab. Além do ajuste de tamanho, a posição dos objetos na imagem foi ajustada utilizando a função “imcrop” e foi realizada a fusão com a função “imshowpair”, com o parâmetro “blend”.



**Figura 35** - Imagens RGB (esq.), Térmica (centro) e após fusão (dir.)

Fonte: FREITAS; ZANETTI; MIOLA (2015)

Fica claro o provável benefício da fusão de imagens, pois na linha 2 da Figura 35, o farol do veículo que ofusca a imagem RGB isolada, quando fundida, afeta menos a visibilidade, sendo gerada uma melhor condição para o processamento das imagens sem essa interferência.

## 4.2 Detecção do ponto de fuga

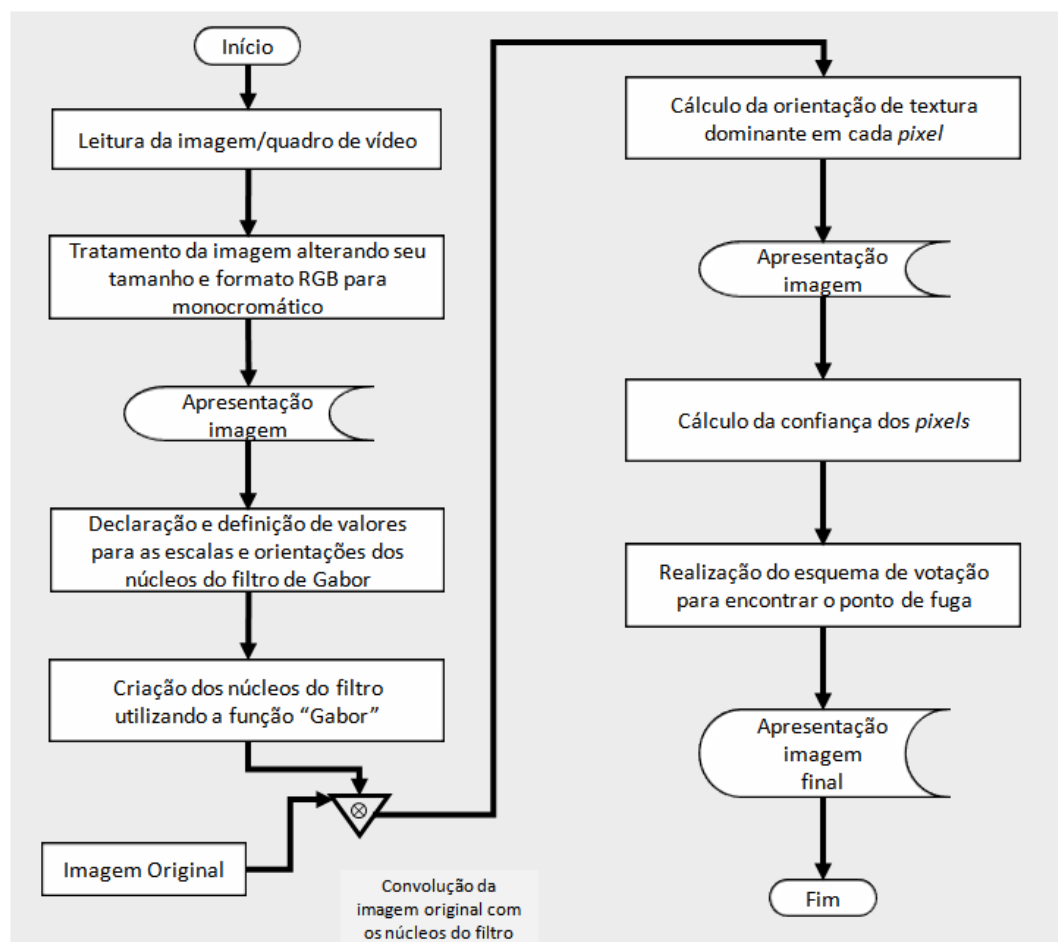
Como descrito na Seção 3.2.5, inicialmente, pretendia-se desenvolver quatro algoritmos para comparação dos resultados e escolha da melhor técnica. O algoritmo ELTO não foi priorizado devido à natureza da sua base de imagens ser estritamente de estradas pavimentadas. Além disso, as técnicas utilizadas nesse algoritmo são totalmente novas em relação aos outros, ocasionando uma ruptura na evolução do algoritmo inicial, fato que desmotivou reiniciar o desenvolvimento através dele. Os

resultados dos algoritmos restantes estão apresentados, a seguir, na ordem crescente de assertividade. Portanto, o terceiro, obteve melhor resultado, sendo sugerida sua utilização no projeto de direção assistida. Os erros obtidos nos testes de um algoritmo foram usados como informação para o desenvolvimento do próximo, aplicando melhorias para resolução dos problemas encontrados.

#### 4.2.1 Votação local e flexível baseada no Filtro de Gabor (*Gabor-based LASV - Locally Adaptive Soft-Voting*)

No primeiro algoritmo testado, denominado LASV (KONG; AUDIBERT; PONCE, 2010), inicialmente é estimada a orientação de textura em cada *pixel*. Depois é realizado um esquema de votação adaptativo e local.

Para elaboração desse código são executados os seguintes passos no Matlab conforme Figura 36.



**Figura 36** - Algoritmo de Votação local e flexível baseada no Filtro de Gabor

Fonte: elaborado pelo autor

O anexo B apresenta algumas imagens da base de autores (colunas A; B e C) e das minas da Vale (colunas D; E e F) com os resultados do método acima citado, para encontro do ponto de fuga.

O processo do método de votação para encontrar o ponto de fuga mostrou-se de implementação complexa e processamento lento, pois executa de forma cíclica uma varredura no semicírculo inferior (raio medindo 35% do tamanho da diagonal da imagem) de cada *pixel* candidato a ponto de fuga. Em virtude disso, o algoritmo não será utilizado e testado para segmentação da área da estrada, uma vez que existem outros métodos de implementação mais simples e de melhor desempenho.

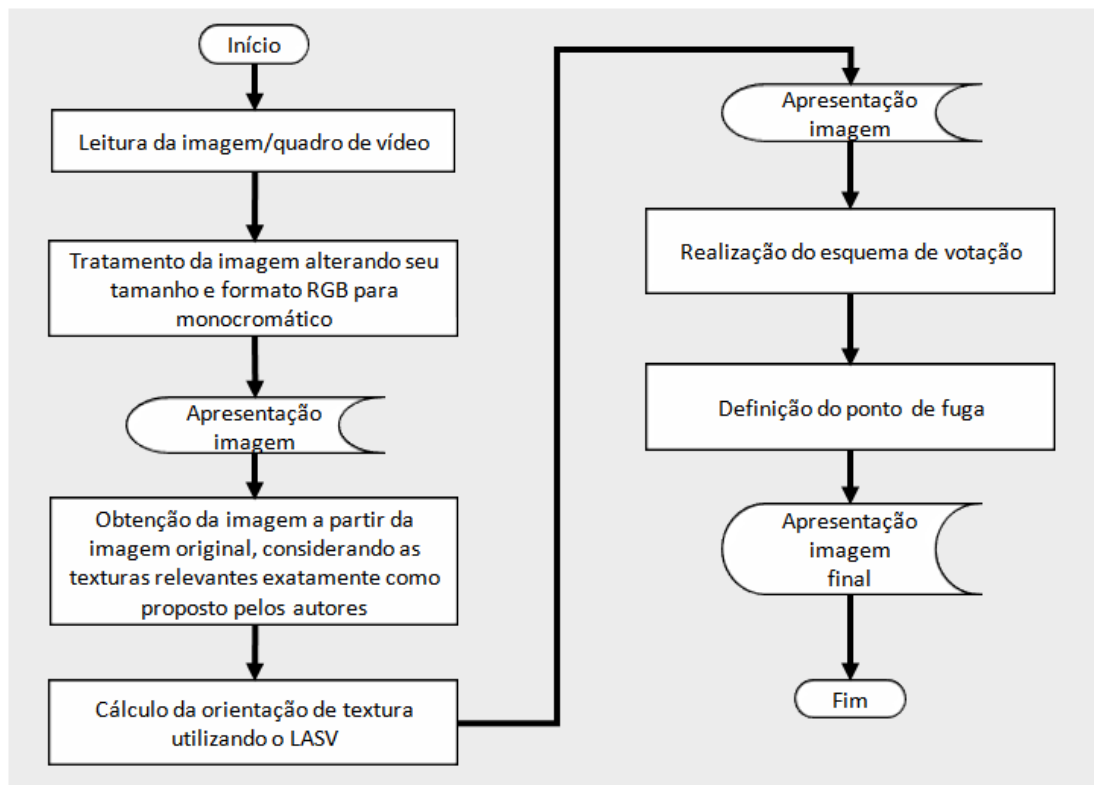
Utilizando o Matlab como ferramenta de programação e um computador com processador Intel Core I7 (2,4GHz, 8GB RAM, 64 Bits), o tempo de processamento de uma imagem, somente para encontrar o ponto de fuga, é em torno de 1 minuto, o que inviabiliza completamente seu uso em uma aplicação de campo com leitura de dados *online*. Autores indicam que esse algoritmo é executado em torno de 3 segundos, com hardware compatível com o utilizado nesse teste. Essa grande diferença, possivelmente, acontece devido a limitação das ferramentas de software utilizadas e da estruturação de manipulação de dados dos algoritmos. Como o algoritmo demonstrou erros de localização do ponto de fuga, procurou-se outro algoritmo ao invés de aprofundar na investigação do problema do tempo de processamento.

Os resultados obtidos demonstram que esse método não seria aplicável ao projeto de operação assistida porque a localização do ponto de fuga, na maioria das imagens, não retrata o local correto. Avaliando as imagens com as orientações de textura dominantes é possível verificar que os vetores de orientação, muitas vezes, não apontam para o ponto de fuga real, como era de se esperar e possuem comportamento estranho, que afeta o resultado esperado. Pode-se considerar que o código interno da função “gabor” e da função “imgaborfilt”, que realiza a convolução entre a imagem original e os núcleos do Gabor Filter tem algum comportamento não esperado. Acredita-se que a função “fft” (*Fast Fourier Transform*), utilizada pela função “imgaborfilt”, esteja fazendo alguma aproximação que gere esse erro. O algoritmo LASV, com resultados comprovados por vários autores, foi seguido completamente e não foi possível verificar o motivo do erro nas funções do Matlab.



#### 4.2.2 Detecção do ponto de fuga através de método rápido e preciso (*Fast and Accurate Vanishing Point Detection - FAVP*)

Procurando encontrar uma solução para o problema de exatidão no cálculo do ponto de fuga e do tempo de processamento, buscou-se algum algoritmo que apresentasse em teoria um melhor desempenho. O algoritmo proposto por Yang; Fang ; Tang (2016) foi implementado seguindo os passos da Figura 37.



**Figura 37** - Algoritmo de Detecção de ponto de fuga por método rápido e preciso

Fonte: elaborado pelo autor

No anexo C é apresentado algumas imagens da base de imagens de autores (colunas A; B e C) e de imagens das minas da Vale (colunas D; E e F) com os resultados desse método, para encontro do ponto de fuga.

Verifica-se que o rendimento do método FAVP de localização do ponto de fuga melhorou em relação ao método LASV. Entretanto, como também é utilizado o cálculo da orientação de textura dominante utilizando o LASV, os erros que aconteceram nesse algoritmo também ocorreram no FAVP. O desempenho como prometido pelos autores melhorou consideravelmente, atingindo desempenho médio de 30 segundos para o cálculo do ponto de fuga de uma única imagem. Esse tempo ainda torna o algoritmo inviável para a implantação no projeto de direção assistida. A redução do

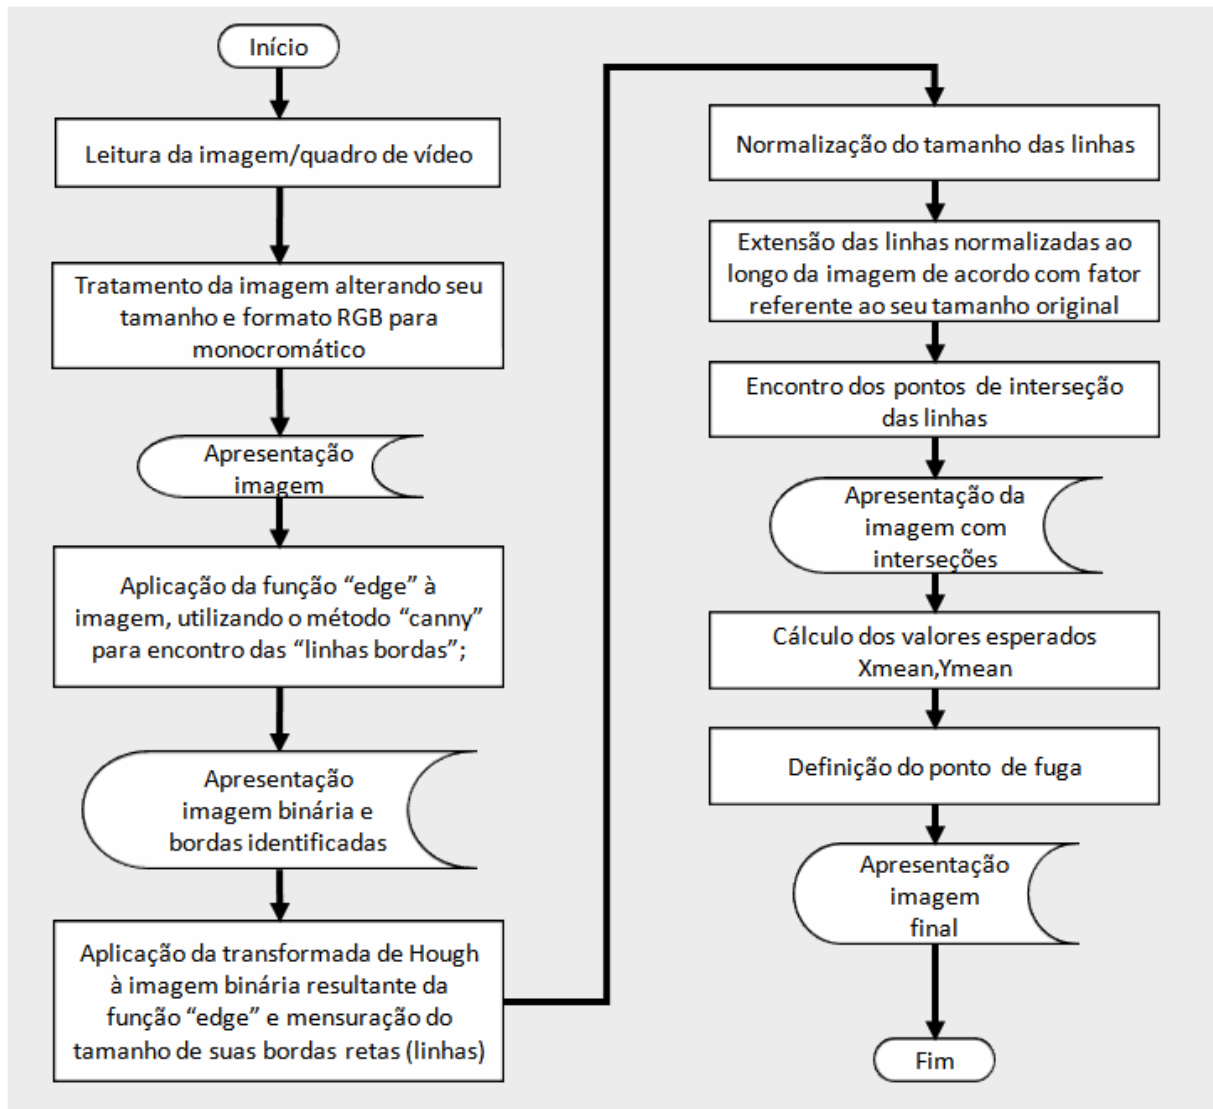
tempo de execução do algoritmo é relacionada com o filtro de *pixels*, que seleciona somente os que possuem textura relevante, os quais votam para o ponto de fuga, reduzindo consideravelmente o número de votações totais e, portanto, o número de execuções desse passo pelo algoritmo. O tempo de 30 segundos de execução, em sua grande maioria, é devido a parte do algoritmo LASV presente nesse método. Esse método não apresenta técnica para segmentação da área da estrada. As técnicas utilizadas e testadas para esse fim serão apresentadas posteriormente.

#### **4.2.3 Métodos baseados em identificação de bordas e aplicação de coerência de orientação de métodos baseados em textura (*Edge-based methods and the orientation coherence concept - EBMO*)**

Após ser verificado o problema do cálculo da orientação dominante de textura no Matlab em dois algoritmos e ser avaliado que a falta de recursos técnicos e prazos disponíveis para a realização da pesquisa poderiam afetar o resultado final, o foco foi alterado da definição do ponto de fuga pela análise de textura das imagens para novos métodos com outras técnicas.

Lu (2012) propõe um método baseado inicialmente na identificação de linhas retas dominantes na imagem original, aplicando funções de encontro de bordas e transformada de Hough. Inicialmente esse método se mostrou promissor, pois não utiliza a problemática forma de cálculo dos métodos anteriores. Após a identificação das linhas retas presentes naturalmente nas formas e cores das imagens, as linhas são medidas e ajustadas para ser possível definir os pontos de interseção entre elas. Esse método, normalmente, é funcional para estradas pavimentadas e utilizadas por veículos leves nas quais há referências visuais para as linhas que devem ser identificadas.

Essa pesquisa teve como um de seus objetivos específicos testar algoritmos usualmente utilizados para veículos leves em imagens e vídeos do ambiente da mineração. Dessa forma, efetuou-se uma modificação no algoritmo EBMO calculando o ponto de fuga como sendo o valor esperado da amostra dos pontos de interseção das linhas encontradas pelo método. Os passos executados nesse algoritmo encontram-se na Figura 38.



**Figura 38** - Algoritmo de métodos baseados em identificação de bordas e aplicação de coerência de orientação de métodos baseados em textura

Fonte: elaborado pelo autor

O anexo D apresenta imagens da base de dados de autores (colunas A; B e C) e de imagens das minas da Vale (colunas D; E e F) com os resultados desse método para encontro do ponto de fuga.

Os resultados apresentados para encontrar o ponto de fuga se mostraram satisfatórios, tanto para a base de imagens dos autores, quanto para a base de imagens das minas da Vale. No segundo caso, tanto para imagens RGB, quanto para imagens térmicas, foi possível detectar o ponto de fuga corretamente na maioria dos casos, quantificados posteriormente na Seção 4.5.2. Fica claro que para esse método, marcas e diferenças nas cores de ruas pavimentadas ajudam a detecção do ponto de fuga, mas mesmo em estradas não pavimentadas houve êxito, uma vez que as

ranhuras e sulcos deixados por pneus e pela textura do solo formam também bordas e linhas na imagem, que contribuem para a detecção do ponto de fuga. Nas imagens das bases de dados de autores e encontradas na internet, foi possível perceber que para estradas pavimentadas e retas, a detecção do ponto de fuga acontece com exatidão.

O algoritmo apresentou problemas para identificar o ponto de fuga em estradas curvas, pois as linhas encontradas no algoritmo tangenciam a curva, gerando interseções que não representam exatamente o ponto de fuga. O mesmo acontece em estradas não pavimentadas. O algoritmo se mostrou robusto para condições adversas como ambientes com neve e de deserto. Quando a parte da imagem que representa a estrada é pequena em relação ao resto da imagem, ocorrem erros, pois as linhas e bordas de outras partes da imagem são maiores e são priorizadas pelo algoritmo. Em uma situação real, na qual a câmera seria instalada na frente do caminhão, esse fato não aconteceria.

Quanto ao desempenho relacionado ao tempo de execução, o algoritmo apresentou resultado satisfatório. Utilizando computador com processador Intel Core i7 (2,4Ghz, 8GB RAM, 64 Bits) o tempo de processamento de uma imagem, somente para encontrar o ponto de fuga não ultrapassa 1 segundo.

Os resultados do processo de detecção da área da estrada estão descritos a seguir.

### **4.3 Segmentação da área da estrada**

Após ser encontrado um algoritmo que através do código desenvolvido no Matlab conseguiu alcançar resultados satisfatórios para a detecção do ponto de fuga, aprofundou-se no desenvolvimento de códigos para a segmentação da área da estrada, utilizando o ponto de fuga encontrado.

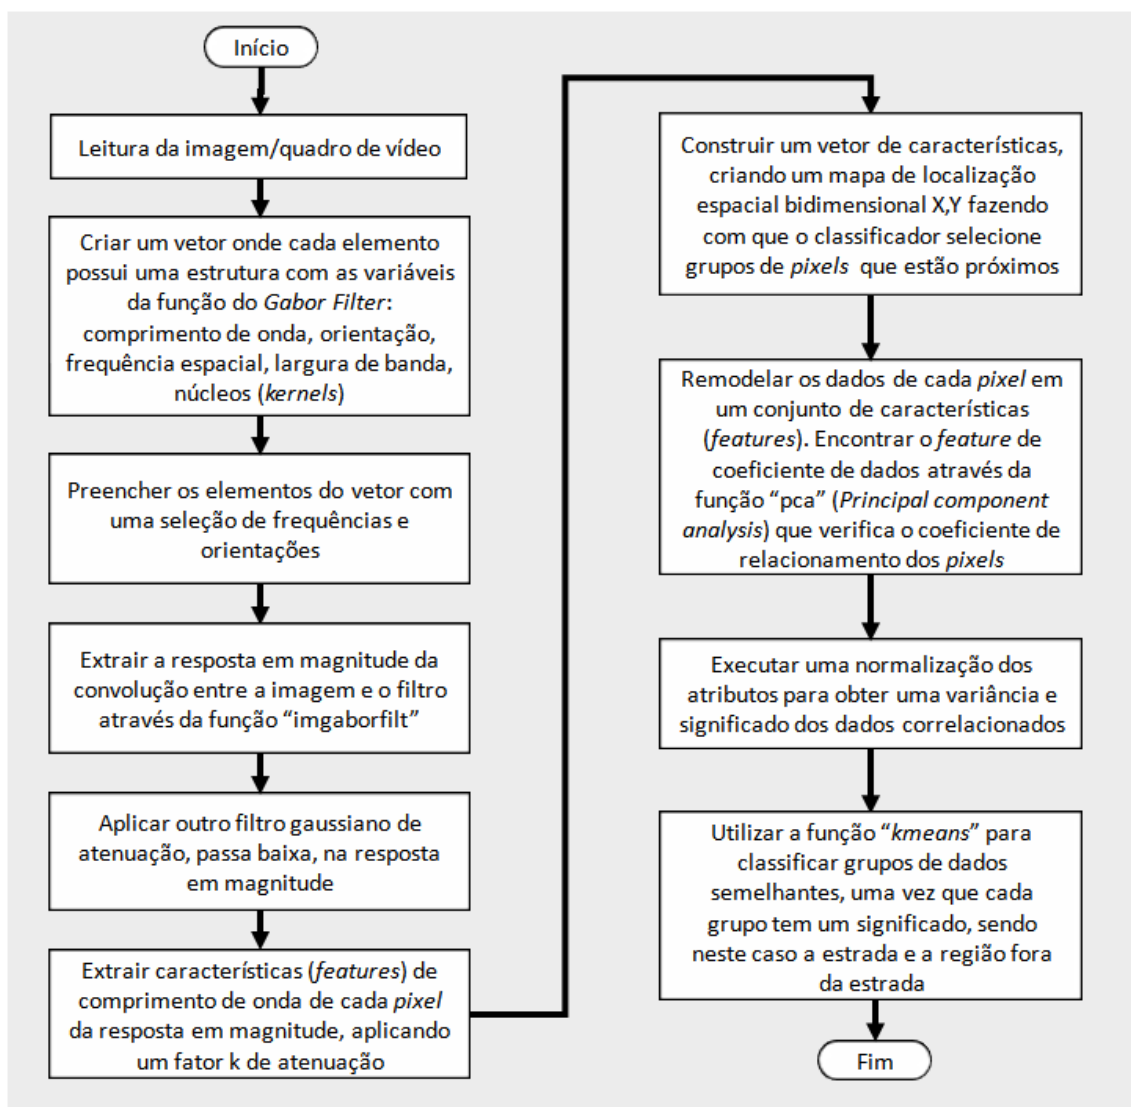
Alguns algoritmos utilizados nos testes de detecção do ponto de fuga não obtiveram bons resultados para esse fim, logo não foram aproveitados para testar a segmentação da área da estrada. Outros nem possuem esse objetivo e, portanto, também não foram utilizados. A Tabela 1 elucida essas situações.

A seguir, são apresentados os resultados de dois algoritmos investigados (Seções 4.3.1 e 4.3.2) e posteriormente (Seção 4.4) apresenta-se o resultado do algoritmo criado pelo autor dessa dissertação, o qual obteve os melhores resultados.

### 4.3.1 Classificador baseado em Gabor Filter utilizando *kmeans* (*Gabor-based classified using kmeans*)

O primeiro algoritmo estudado e testado foi o *Gabor-based classified using kmeans* (MATL). O software Matlab possui em sua biblioteca várias funções de processamento de imagens que possibilitam a execução desse algoritmo de forma simples e em função disso foi o primeiro a ser testado.

Esse algoritmo realiza a segmentação de textura em uma imagem, aplicando o *Gabor Filter* e a partir da resposta em magnitude desse filtro é feita uma amenização através de uma variável *k*, criando características (*features*) que possibilitam a segmentação da imagem. A Figura 39 apresenta as etapas desse algoritmo.



**Figura 39** - Classificador baseado em Gabor Filter utilizando *kmeans*

Fonte: elaborado pelo autor

Nos testes preliminares foi utilizado a base de imagens RGB e térmica. Nessa fase da pesquisa, a fusão de imagens acontecia após a extração de atributos e segmentação da área da estrada e, portanto, não foi realizada.

O anexo A apresenta os resultados da identificação de leiras e obstáculos executados pelo algoritmo com as marcações na cor branca. A marcação na cor vermelha indica a localização da leira e obstáculos reais para ser possível a comparação e identificação do desempenho do algoritmo.

A partir da observação dos resultados infere-se que:


- a) O algoritmo não apresentou resultados satisfatórios que permitam sua aplicação no projeto de operação assistida;
- b) Quando a textura da estrada se assemelha ou se confunde com a textura da leira, como ocorre na prática, não é possível identificar a base da leira, sendo identificado o topo da mesma, onde há variação de textura;
- c) A identificação de veículos apresentou bons resultados, ainda sem robustez suficiente para implantação, mas comprovando que os mesmos podem ser identificados por algoritmos de análise de textura;
- d) A união das informações das imagens RGB e térmica para uma mesma cena constrói uma interpretação do cenário melhor do que somente uma delas;
- e) Luzes de faróis de veículos alteram os resultados esperados para a imagem RGB e influenciam muito pouco na imagem térmica;
- f) A poeira influencia os resultados nas duas imagens, o que já era esperado, uma vez que a poeira altera a textura das superfícies influenciando na resposta do *Gabor Filter*;
- g) O algoritmo utiliza apenas uma orientação no núcleo do *Gabor Filter*, o que se mostrou pouco eficaz.

Foi necessário buscar algoritmos mais robustos que conseguissem identificar a base da leira das estradas de mina.

#### **4.3.2 Segmentação utilizando *superpixels***

A técnica de *superpixels* (SUPP) utiliza basicamente a função do Matlab, de mesmo nome, e posteriormente efetua uma série de tratamentos na saída dessa

função. Como o código dessa técnica foi utilizado no algoritmo final, o mesmo está detalhado na Seção 4.4. A Figura 40 apresenta alguns resultados após aplicação do algoritmo SUPP. A região de interesse, representando a área da estrada, é identificada pela cor vermelha nas imagens. Percebe-se que em muitos casos a região de interesse toma a forma da estrada, mas em muitos outros, isso não acontece. Assim, somente o uso dessa técnica, não garante a identificação da área da estrada de uma forma confiável para uma implantação real.



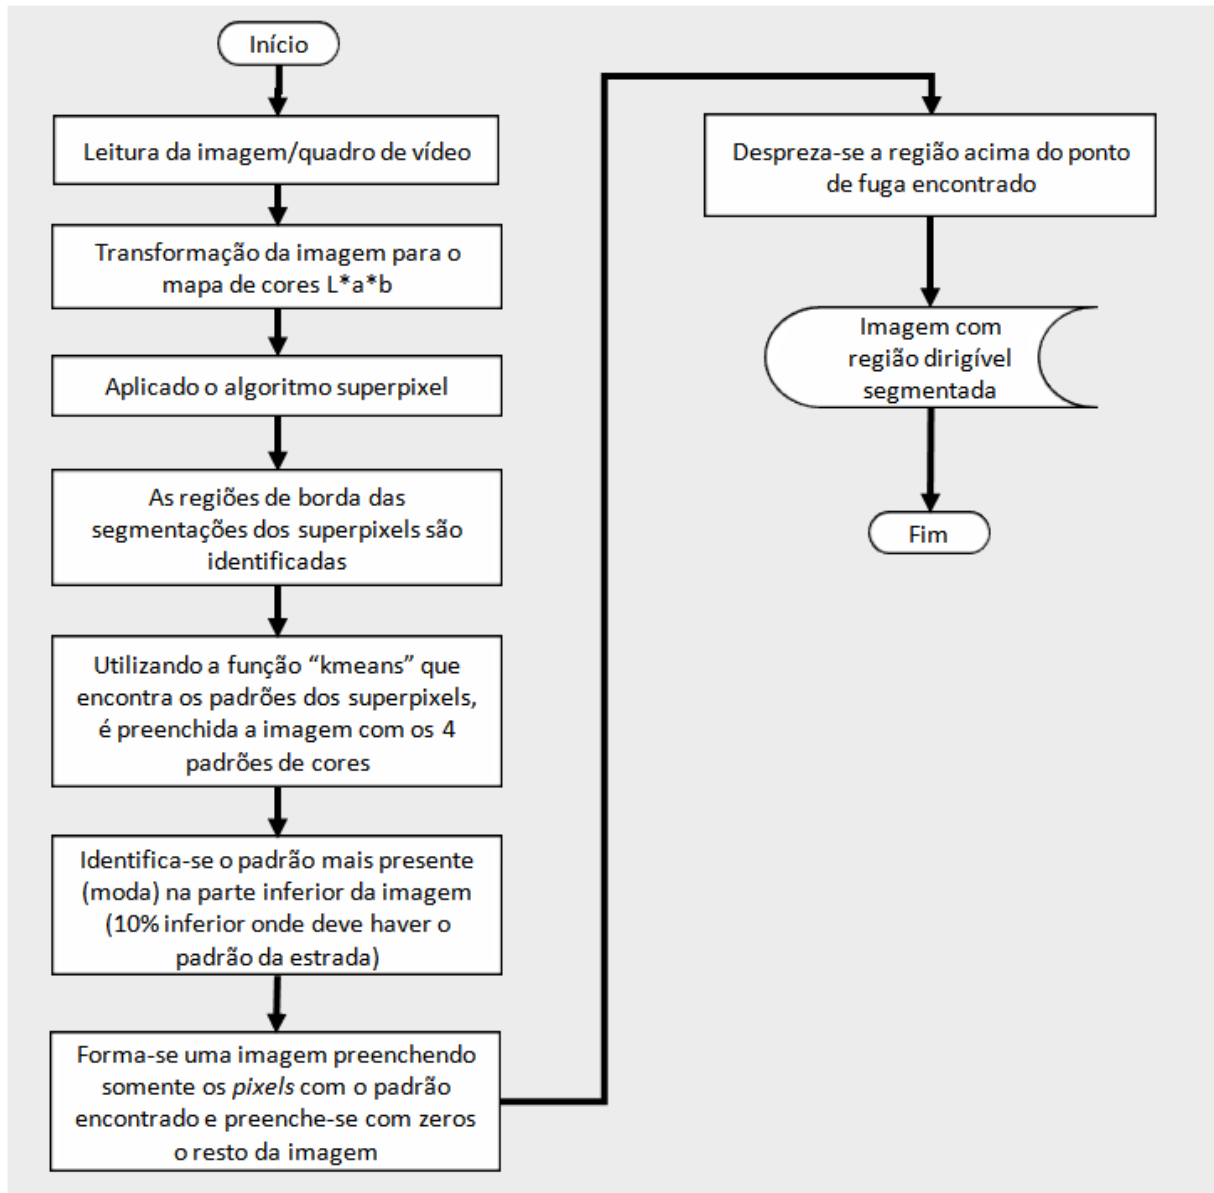
**Figura 40** - Regiões de interesse após aplicação do algoritmo SUPP

Fonte: elaborado pelo autor

#### 4.4 Algoritmo final implementado para segmentação da área da estrada

Para a detecção da área da estrada, foi proposto um método híbrido que utiliza quatro técnicas para identificação de padrões nas imagens que reflitam a forma da estrada, conforme descrito na Seção 3.2.5.2. As técnicas são aplicadas em cada imagem não importando a ordem pois são independentes. As Figuras 41 a 44 apresentam os algoritmos das quatro técnicas.

Na primeira técnica, considera-se que a estrada possui um padrão de cores semelhante na área de rodagem, sendo esse padrão diferente nas áreas de fora da estrada. A seguir são listados os passos para executar o algoritmo. A Figura 41 ilustra o algoritmo da técnica.

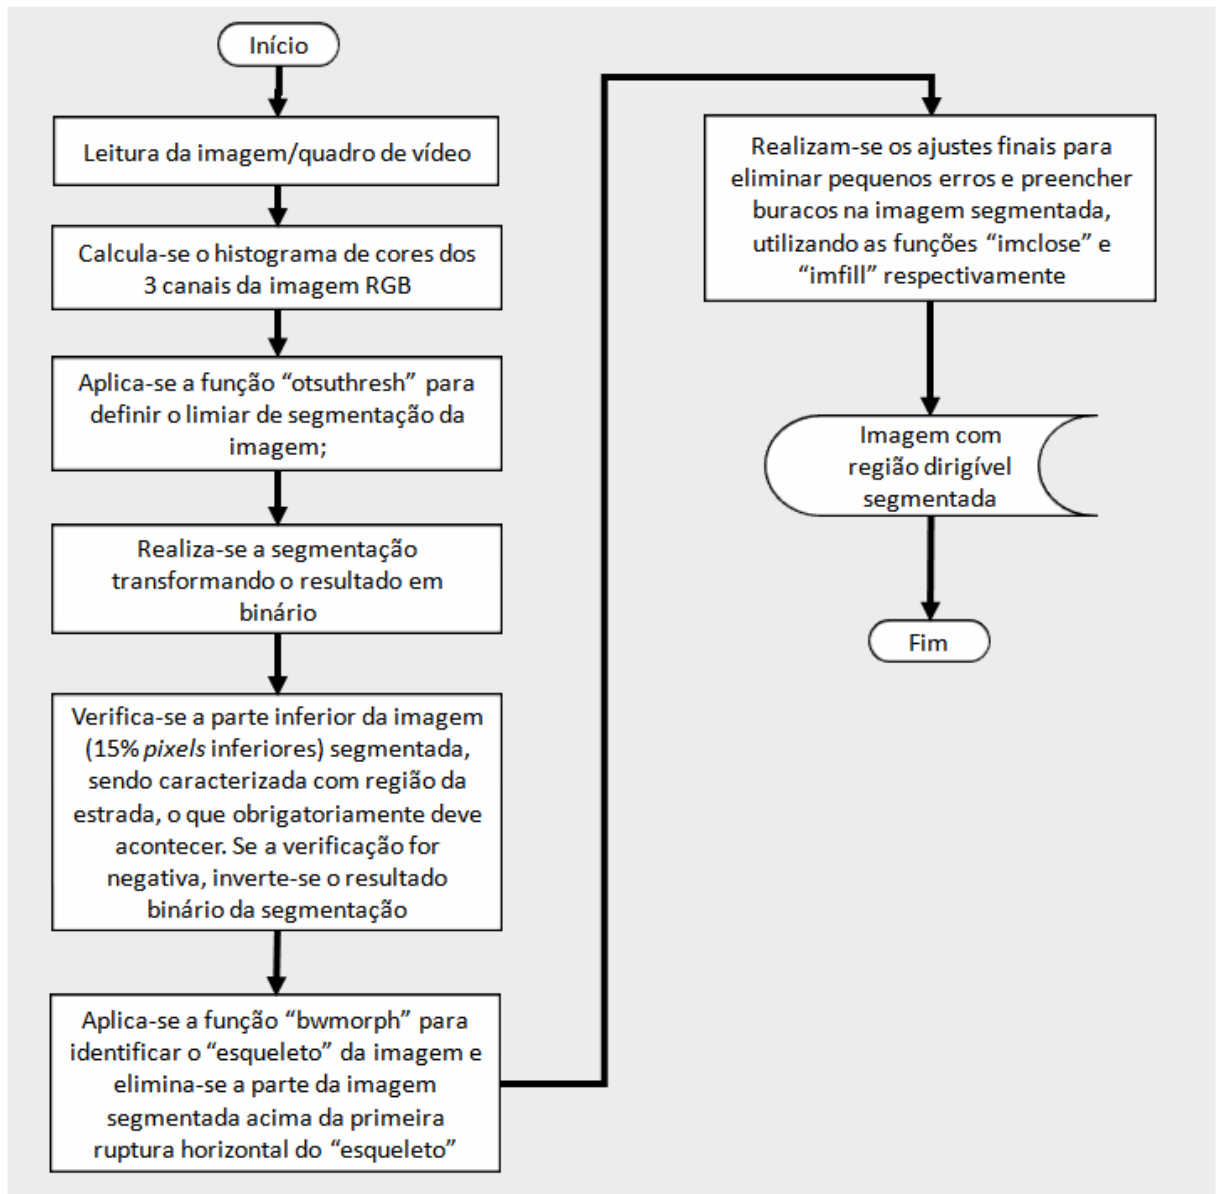


**Figura 41** - Algoritmo segmentação por *superpixel*

Fonte: elaborado pelo autor

A segunda técnica é executada através de análise do histograma de cada canal de cor RGB (vermelho, verde e azul), conforme apresentado na Figura 42.

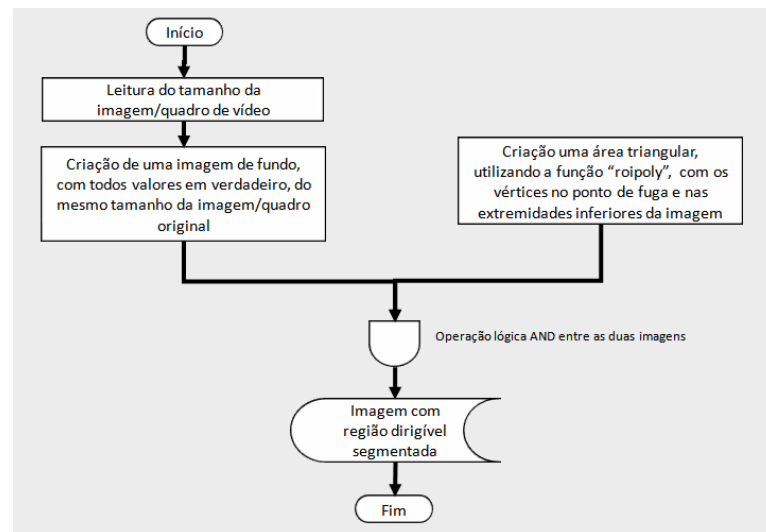




**Figura 42** - Algoritmo de segmentação por limiar de histograma

Fonte: elaborado pelo autor

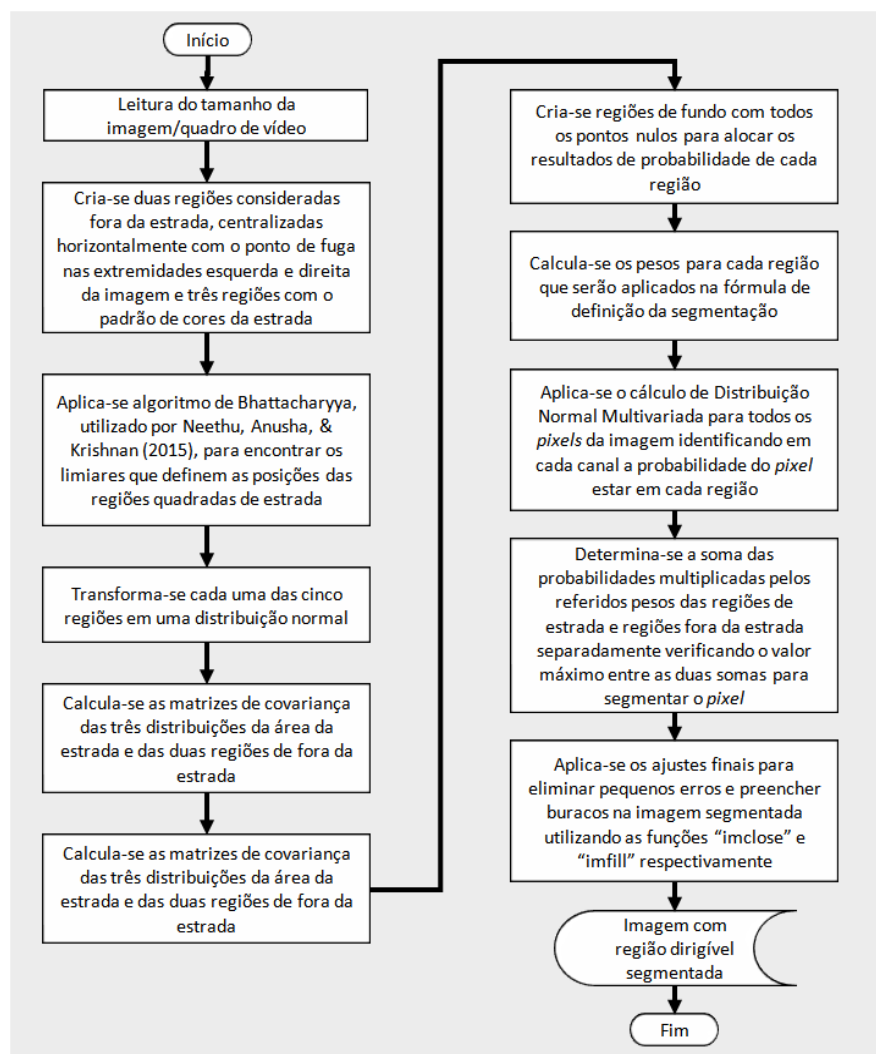
A terceira técnica cria uma imagem de fundo do tamanho da imagem a ser analisada e define os valores lógicos de todos os *pixels* em 1(verdadeiro). Depois multiplica essa imagem de fundo com a região encontrada entre o ponto de fuga e as extremidades inferiores da imagem. A técnica é ilustrada na Figura 43.



**Figura 43** - Algoritmo triângulo do ponto de fuga

Fonte: elaborado pelo autor

A quarta técnica tem seus passos descritos abaixo na Figura 44.



**Figura 44** - Algoritmo distribuição normal multivariada


Fonte: elaborado pelo autor

Nas Figuras 45 e 46 é possível verificar alguns resultados da segmentação de área dirigível de estradas, utilizando as quatro técnicas fundamentais, de base de imagens da internet e de autores (Figura 45) e de imagens das minas da Vale (Figura 46). Na Figura 45, os resultados finais estão dispostos lado a lado com as imagens originais. O anexo E apresenta outras imagens complementares para ilustrar melhor os resultados.



**Figura 45** - Resultado de identificação de área de estrada (base de imagens internet e autores)

Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road dataset” no Google Imagens e obtidas após a execução do algoritmo



**Figura 46** - Resultado de identificação de área de estrada (base de imagens minas Vale)

Fonte: FREITAS; ZANETTI; MIOLA (2015) imagens obtidas após a execução do algoritmo

## 4.5 Apresentação dos resultados

Após a execução dos algoritmos, os resultados foram validados através de métricas de medição de desempenho. A seguir são apresentados:

- Resultados de desempenho da fusão de imagens;
- Resultados comparativos entre os métodos selecionados para detecção do ponto de fuga;
- Resultados de segmentação da área dirigível da estrada.

### 4.5.1 Resultados de desempenho da fusão de imagens

Para mensurar o quanto a fusão de imagens colaborou no processamento das mesmas, foi definido um teste em que as imagens RGB e térmicas foram processadas separadamente pelo algoritmo final e a região de interesse (ROI) da estrada foi encontrada utilizando cada tipo de imagem de forma individual sem realizar a fusão. Depois, o mesmo algoritmo foi executado realizando a fusão das imagens RGB e térmica para posteriormente executar os algoritmos de encontro do ponto de fuga e segmentação da área de interesse da estrada.


Foram selecionadas vinte e duas diferentes cenas, totalizando sessenta e seis imagens. Não foi possível realizar esse teste nas imagens da base da internet pois as mesmas não possuem imagens térmicas da mesma cena. O teste consistiu em:

- Definir manualmente nas imagens RGB, térmica e após a fusão, a área dirigível da estrada;
- Executar o algoritmo final somente nas imagens RGB e plotar a área de interesse segmentada na interface de imagens do Matlab. Sobrepor a mesma à área real da estrada definida manualmente. Para calcular o desempenho dos algoritmos, utiliza-se o método de Sorensen-DICE (SØRENSEN, 1948), no qual os pixels são identificados como verdadeiros positivos, falsos positivos e falsos negativos. Aplicando o mesmo método, deve-se encontrar o índice de Sorensen-Dice. Quanto maior o índice, melhor será o desempenho.
- Repetir o passo anterior executando o algoritmo novamente e realizando os mesmos cálculos de desempenho, utilizando o método de Sorensen-DICE, para as imagens térmicas;

- Repetir o segundo passo, executando o algoritmo novamente e realizando os mesmos cálculos de desempenho, utilizando o método de Sorensen-DICE, para as imagens após realizar a fusão;


O Gráfico 3 apresenta o desempenho calculado para a as áreas das estradas. Após a coleta de resultados para cada uma das 66 imagens processadas foi possível calcular as médias obtidas no processamento de imagens RGB, imagens térmicas e imagens após a fusão.

**Gráfico 3 - Resultados do cálculo da área da estrada**



Fonte: elaborado pelo autor utilizando resultados do algoritmo executado no software Matlab

**Gráfico 4 - Resultados da média de resultados entre imagens para distância do ponto de fuga e medição da área da estrada encontrada**



Fonte: elaborado pelo autor utilizando resultados do algoritmo executado no software Matlab

O Gráfico 4 apresenta as médias aritméticas dos resultados comparando as imagens RGB, térmicas e após a fusão. Observando esse gráfico, percebe-se que as imagens RGB e térmica processadas sem a fusão obtiveram desempenho médio menor, 76% e 65% respectivamente. Após a fusão, o resultado médio subiu para 82%, sendo 7,8% melhor que o processamento isolado das imagens RGB e 26,2% melhor que o processamento isolado das imagens térmicas. Portanto, o desempenho do cálculo da área das imagens após a fusão melhorou, o que evidencia que o método é válido para o processamento de imagens proposto.

Após a medição das médias das amostras de resultados para processamento de imagens RGB, térmicas e após a fusão, aplicou-se a análise de “*T Student*” (BOX, 1987) para verificar a probabilidade de uma das amostras se sobrepor a outra. Em todos os casos a probabilidade foi menor que 0,1%, excluindo-se essa possibilidade.

#### **4.5.2 Resultados comparativos entre os métodos selecionados para detecção do ponto de fuga**

Para a seleção do melhor método para a detecção do ponto de fuga foi criada uma métrica quantitativa. Avaliou-se a exatidão do cálculo da posição do ponto de fuga, classificando a medição como “precisa”, “válida” e “inválida”. No caso de medição precisa, o erro máximo de medição da distância do ponto de fuga calculado e real é de 10 pixels. Ou seja, visualmente não se consegue verificar erro de posicionamento. No caso da medição válida, há um erro máximo de 20 pixels que não interfere no cálculo da área dirigível da estrada e no caso de medição inválida, o erro é maior que 20 pixels e essa imagem não pode ser utilizada para a continuação do algoritmo. O ponto de fuga real foi marcado manualmente em cada imagem. A distância calculada foi dividida pela diagonal da imagem para normalização dos resultados

Na Tabela 2, a seguir, são apresentados os resultados dos algoritmos para a detecção do ponto de fuga seguindo a métrica de classificação descrita acima.


**Tabela 2** - Resultados de localização ponto de fuga

Método	Imagens Vale (após fusão de RGB e térmica)	Precisa	Válida	Inválida
LASV	40	2	7	31
FAVP	40	1	9	30
EBMO	40	11	11	18
<b>Total</b>	<b>126</b>	<b>12</b>	<b>35</b>	<b>79</b>
Método	Imagens internet (somente RGB)	Precisa	Válida	Inválida
LASV	100	5	15	80
FAVP	100	2	20	78
EBMO	100	44	34	22
<b>Total</b>	<b>300</b>	<b>35</b>	<b>88</b>	<b>177</b>

Fonte: elaborado pelo autor


Os dois primeiros algoritmos (LASV e FAVP) apresentaram muitos erros, inviabilizando o uso dos mesmos. Já o terceiro algoritmo (EBMO) apresentou resultados satisfatórios, como é possível verificar na Tabela 2.

No Gráfico 5 é ilustrado o resultado para o método EBMO para a base de dados de imagens da internet, totalizando 100 imagens. No Gráfico 6 é apresentado o resultado para a base de imagens da Vale, totalizando 40 imagens. Cada ponto representa o resultado de uma imagem. O eixo vertical representa a distância do ponto de fuga calculado com o real, já normalizado. O eixo representa a sequência de imagens. É possível verificar que o resultado nas imagens da internet foi superior ao das minas da Vale, o que é compreensível, pois as texturas e definição de linhas das imagens da internet são mais definidas e visíveis o que facilita a execução dos algoritmos.

**Gráfico 5** - Resultados do cálculo da distância do ponto de fuga calculado em relação ao real para base de imagens da internet

Fonte: elaborado pelo autor utilizando resultados do algoritmo executado no software Matlab

**Gráfico 6** - Resultados do cálculo da distância do ponto de fuga calculado em relação ao real para base de imagens das minas da Vale.




Fonte: elaborado pelo autor utilizando resultados do algoritmo executado no software Matlab

#### 4.5.3 Resultados para segmentação da área da estrada

Para a detecção da área dirigível da estrada foi utilizado o mesmo método aplicado para a medição de desempenho da fusão, (SØRENSEN, 1948). Neste caso, para a base de imagens das minas da Vale só foram consideradas as 40 imagens após a fusão. Para a base de imagens da internet, foram consideradas todas as 100 imagens disponíveis.

O Gráfico 7 demonstra o resultado da base de imagens da internet no qual 100 imagens, em diferentes cenas, foram submetidas ao algoritmo. O eixo das abscissas representa o número da imagem e o eixo das ordenadas o desempenho do algoritmo. O Gráfico 8 apresenta o resultado para as imagens das minas da Vale.


**Gráfico 7** - Resultado de desempenho de identificação de área da estrada de imagens da internet



Fonte: elaborado pelo autor utilizando resultados do algoritmo executado no software Matlab



**Gráfico 8** - Resultado de desempenho de identificação de área da estrada das imagens das minas da Vale



Fonte: elaborado pelo autor utilizando resultados do algoritmo executado no software Matlab

O método aplicado determina um limiar (definido pelo método Sorensen- DICE) identificado no gráfico através da linha azul. Todas as regiões segmentadas na imagem que obtiverem um resultado acima desse limiar (0,7) podem ser consideradas uma segmentação correta. Dessa forma, para as imagens da internet foi possível realizar uma segmentação satisfatória em 67% das imagens e para as imagens das minas da Vale em 48%.

As quatro técnicas utilizadas para a identificação da área das estradas foram utilizadas e obtiveram resultados parciais distintos.

a) Algoritmo “Segmentação por cores utilizando *superpixel (kmeans)*”

- Esse algoritmo é relativamente simples, pois há funções nativas do Matlab que auxiliam a elaboração do código. Obteve-se resultados de aproximadamente 50% de acerto na detecção de estradas.

b) Limiar e histograma

- Usando estatística, esse algoritmo encontra um limiar que representa a cor dominante em determinada região da estrada. Assim, tentou-se aplicar essa regra na parte inferior da imagem onde predominantemente ocorre a presença da estrada. Verificou-se que a aplicação do método no canal vermelho da imagem RGB apresentou resultados bem melhores que nos canais verde e azul. Esse fato já era esperado, visto que a cor vermelha de uma forma geral se destaca mais em relação a outras cores quando se compara intensidade. Assim esse algoritmo teve desempenho razoável no canal vermelho e o mesmo não ocorreu nos outros canais. Somente a sua utilização não se mostrou viável para a identificação de estradas.

c) Triângulo do ponto de fuga

- A terceira técnica une o ponto de fuga já calculado às extremidades da imagem para formar um triângulo e o preenche com o valor 1 (verdadeiro) transformando a imagem em binária. Esse triângulo identifica um trecho provável da estrada representando uma aproximação da forma real, pois utiliza linhas retas como referência das bordas da estrada. Por ser utilizado o resultado do algoritmo EBMO como informação inicial para plotar o ponto de fuga, o desempenho desse algoritmo, desprezando os erros de aproximação das bordas reais curvas, tem os mesmos resultados do EBMO no encontro do ponto de fuga, tendo, portanto, uma acurácia de 78% para imagens da internet e 55% para imagens das minas da Vale.

d) Distribuição normal multivariada


- A última técnica aplicada não obteve resultados satisfatórios, apresentando baixos resultados absolutos de probabilidades que geraram valores nulos entre o *pixel* analisado e as regiões padrões definidas. Entretanto, nos momentos em que a probabilidade não foi nula, houve identificação correta de *pixels* em regiões da estrada e, portanto, há contribuição desse algoritmo no resultado final.

As Figuras 47 e 48 apresentam alguns resultados parciais e o resultado final do algoritmo de identificação de estradas através das quatro técnicas fundamentais descritas nessa dissertação. As figuras são organizadas de tal forma que: na 1ª coluna: imagem original. 2ª coluna: resultado algoritmo superpixel. 3ª coluna: resultado canal vermelho análise histograma de cores. 4ª coluna: triângulo do ponto de fuga. 5ª coluna: imagem final segmentada.



**Figura 47** - Resultados das técnicas fundamentais.

Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road dataset” no Google Imagens e obtidas do algoritmo executado



**Figura 48** - Resultados das técnicas fundamentais (continuação).

Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road dataset” no Google Imagens

Os resultados individuais obtidos com as quatro técnicas definiram os valores iniciais para os pesos aplicados à soma das mesmas. Quanto melhor o resultado individual, maior foi o peso pré-definido. Inicialmente, foi adotado peso 2 para as técnicas de *superpixel* e triângulo do ponto de fuga. Para as técnicas de análise de histogramas, foi aplicado peso 1 para o canal vermelho e peso 0,5 para os demais

canais. Para a técnica de Distribuição Normal Multivariada, foi adotado peso 1. Após diversos testes, os pesos foram ajustados experimentalmente sendo finalmente definidos em:

- Peso *Supapixel* = 3;
- Peso Histograma R = 1;
- Peso Histograma G = 0,5;
- Peso Histograma B = 0,5;
- Peso Ponto de Fuga = 2;
- Peso Distribuição Normal Multivariada = 2;

Como a base de imagens utilizada possui diversos tipos de cenas, os pesos de uma forma geral podem ser utilizados para qualquer imagem, porém cada imagem possui um peso ideal, uma vez que alterando o tipo de cena da imagem, a resposta do algoritmo pode ser diferente, sendo necessário alterar os pesos de cada algoritmo para encontrar a melhor região de interesse que represente a estrada real.

Foi atribuído maior peso para as técnicas que mais colaboraram para um resultado positivo, nessa ordem de relevância: *supapixel*, triângulo ponto de fuga, distribuição normal multivariada e histograma de cores

Após a definição dos pesos, utilizando-se a Equação 39, é possível escolher o valor de  $k$  que representa o limiar para segmentação da imagem para aplicação na equação de segmentação (definida pela Equação 30). Considerando a imagem resultante em escala de cinza, com todos os *pixels* da área segmentada com valor unitário, aplica-se a soma ponderada e o resultado é normalizado com o valor máximo de cada *pixel*. Após a normalização, o valor  $k=0,4$  foi definido experimentalmente.

O método experimental utilizado para definição do melhores pesos e valores de  $k$ , foi a permutação simples com a restrição dos pesos mais influentes sempre maiores que os menos influentes. Os valores da variável  $k$  foram  $0,1 \leq k \leq 1$ , com espaçamento de 0,1 e os pesos  $0,5 \leq pesos \leq 4$ , com espaçamento de 0,5. O método foi aplicado em dez imagens e foi verificado que os pesos e variável  $k$  estavam ajustados para todas elas. Em um trabalho futuro, sugere-se considerar o desenvolvimento de algoritmo para ajuste automático dos pesos e a variável  $k$  de acordo com as características das imagens a serem processadas.

## 5. DISCUSSÕES DOS RESULTADOS

Desde o início dessa pesquisa, buscou-se algoritmos robustos, capazes de identificar as estradas em ambientes de mina. Não falta material disponível relacionado ao tema, nas bases de pesquisa, principalmente na IEEE Xplore<sup>32</sup>. Entretanto, os artigos disponíveis apresentam técnicas sem o detalhamento necessário para seu correto entendimento. Para realizar o desenvolvimento dos códigos, foi utilizada a ferramenta Matlab. Buscou-se otimizar o trabalho nesse software, utilizando ao máximo funções prontas e evitando o uso de longos *loops* para processar rotinas. Ao final da etapa de desenvolvimento, foi realizada revisão geral nos códigos, retirando trechos desnecessários e utilizando estruturas de dados mais avançadas para diminuir o tempo de processamento.

Quanto às imagens utilizadas para o teste, a base de imagens da internet e de autores de artigos foi selecionada visando representar a maior quantidade de estradas, em ambientes de diferentes formatos e cores. Quanto maior o número de imagens, menor a incerteza dos resultados; todavia, considera-se que a base utilizada é suficiente para validação dos algoritmos.

A base de imagens das minas da Vale apresentam condições climáticas adversas o que dificulta sua interpretação mesmo com as câmeras de alta qualidade utilizadas nos testes do projeto de direção assistida. Os vídeos disponibilizados tinham baixa qualidade devido à luminosidade precária do ambiente de mina. Tentou-se filtrar as imagens, porém muitas vezes não foi possível, pois a resposta da saída dos filtros alterava consideravelmente a textura, que é variável essencial para o cálculo do ponto de fuga. Considera-se essa base de imagens ainda insuficiente para validação final dos algoritmos em ambientes de mina.

Para a instalação definitiva das câmeras no projeto de direção assistida, deve-se fazer testes exaustivos nas mesmas, para verificação da qualidade das imagens, nas piores condições visuais encontradas em um ambiente de mina. Vídeos e imagens com a qualidade utilizada nessa pesquisa não se mostram promissores quando se pensa em uma implantação real, independente da técnica de processamento de imagens a ser utilizada. Todas as bases de imagens utilizadas por autores em artigos inovadores, recentes e com resultados comprovados, utilizam

---

<sup>32</sup> Biblioteca científica focada em conteúdos técnicos. (IEEE – *Institute of Electrical and Electronics Engineers*)

imagens de melhor qualidade do que às imagens de ambiente de mina selecionadas nessa pesquisa.

Funções do Matlab como “imgaborfilt” e “cov” demonstraram comportamento inesperado durante os testes. A primeira retornou a resposta ao filtro de Gabor com informações diferentes do previsto para o cálculo da orientação de textura dominante para um determinado *pixel*. Isso gerou orientações dominantes que não apontavam para o ponto de fuga da estrada impedindo seu cálculo corretamente. A segunda gerou resposta não esperada para o cálculo da matriz de covariância o que atrapalhou a execução do algoritmo de detecção de estrada por distribuições normais multivariadas.

A pesquisa buscou métodos eficientes para a fusão de imagens, a detecção do ponto de fuga e segmentação da área dirigível da estrada. Os fatores que influenciaram os resultados dos métodos aplicados estão descritos a seguir.

## **5.1 Fusão de imagens RGB e térmica para facilitar a identificação da área dirigível das estradas**


A fusão de imagens se mostrou eficiente, pois melhorou os resultados de identificação de estradas se comparado com os resultados das imagens em separado utilizando o mesmo algoritmo. O desempenho do algoritmo na identificação da estrada em imagens RGB e térmicas analisadas separadamente foi inferior ao desempenho do mesmo algoritmo utilizando as imagens após fusão executada a priori. Esse fato é percebido principalmente quando a imagem RGB sofre uma interferência, como ruído gerado pela própria câmera para corrigir a baixa luminosidade, por presença de faróis contra a lente da câmera, entre outros, que não afetam a imagem da câmera termográfica.

De uma forma geral, a fusão contribuiu para a diminuição de ruídos presentes em sua grande maioria na imagem RGB. A imagem térmica também contribuiu destacando as cores presentes da estrada, as quais após a fusão ficaram mais marcantes, facilitando a identificação da área da estrada pelo algoritmo.

A Figura 49 apresenta a melhoria proporcionada pela fusão de imagens em um frame retirado da filmagem realizada nas minas da Vale, pelas câmeras RGB e térmicas. A segmentação da estrada melhorou consideravelmente após a fusão.




No próximo exemplo da Figura 50, a melhoria gerada pela fusão das imagens fica mais evidente. Na presença do farol do caminhão, a imagem RGB não consegue identificar a estrada, a imagem térmica tem melhor desempenho, mas ainda assim também não consegue individualmente identificar a estrada. Entretanto, a imagem após a fusão mostra desempenho bem melhor na identificação da estrada. A interferência de luzes, principalmente no período noturno, influencia de maneira negativa na imagem RGB e a fusão ajuda o desempenho do algoritmo para esse tipo de cenário.



**Figura 49** - Quadro de vídeo câmera RGB (esquerda.); câmera termográfica (meio); após fusão (direita)

Fonte: acervo autor



**Figura 50** - Quadro de vídeo câmera RGB (esquerda.); câmera termográfica (meio); após fusão (direita)

Fonte: acervo autor

Os resultados comparativos entre o desempenho no processamento das imagens encontram-se na Tabela 3, conforme detalhado na Seção 4.5.1.

**Tabela 3** - Resultados de desempenho da fusão das imagens

Tipo de Imagem	Índice de desempenho
RGB	76%
Térmica	65%
Após fusão	82%

Fonte: elaborada pelo autor



## 5.2 Detecção do ponto de fuga das estradas

Na detecção do ponto de fuga, considera-se que o resultado foi atingido, em um nível satisfatório somente para a base de imagens da internet, utilizando o algoritmo EBMO com as melhorias desenvolvidas pelo autor e detalhadas nessa dissertação. Permanece como pontos de atenção para esse método:

- a) O desempenho em imagens térmicas é inferior ao desempenho em imagens RGB, uma vez que as bordas são mais facilmente percebidas na imagem RGB, que é base para o cálculo do algoritmo;
- b) Obstáculos como veículos alteram o resultado final e “atraem” o ponto de fuga para próximo deles pois possuem textura diferente da estrada;
- c) O desempenho do algoritmo para imagens das minas da Vale não foi satisfatório já que as bordas das estradas não são facilmente identificadas nas imagens, devido as mesmas se confundirem com as leiras que possuem a mesma cor e textura;

A Tabela 4 sumariza os resultados para a detecção do ponto de fuga, conforme detalhado na Seção 4.5.2.

**Tabela 4** - Resultados de desempenho para detecção do ponto de fuga

Base de Imagens	Índice de desempenho
Internet	78%
Minas Vale	53%

Fonte: elaborada pelo autor

## 5.3 Identificação da área da estrada e segmentação da imagem

Na identificação de área dirigível das estradas, foram utilizadas quatro técnicas com resultados distintos.

### 5.3.1 Segmentação por cores utilizando *superpixel*

No algoritmo SUPP, os resultados obtidos alcançaram aproximadamente 50% de *pixels* da área real identificados como área dirigível, o que não dá segurança para uma aplicação final, ficando pendente para o resultado da prova de conceito a utilização de um algoritmo mais assertivo. Como o algoritmo faz a segmentação

através de cores, erros acontecem quando as cores da área fora da estrada se assemelham às cores da área da estrada ou quando há mais de um padrão de cores dentro da área da estrada.

### **5.3.2 Limiar de histograma de cores**

No algoritmo que utiliza a análise de histograma de cores, a presença de cores dominantes na parte inferior da imagem inicialmente foi considerada uma referência para definir um padrão de cores existentes na área da estrada, entretanto, as imagens analisadas muitas vezes não possuem grandes variações entre a área real da estrada e a área ao seu redor. Isso faz com que áreas incorretas sejam consideradas pelo algoritmo.

### **5.3.3 Triângulo do ponto de fuga**

A técnica de triângulo do ponto de fuga utiliza os resultados já obtidos para detecção do ponto de fuga. Assim, é um algoritmo que contribui de forma efetiva. O erro desse algoritmo vem da forma definida entre o ponto de fuga e as extremidades inferiores da imagem. As linhas retas do triângulo, dificilmente refletem a real forma da estrada, representando uma aproximação.

### **5.3.4 Distribuição normal multivariada**

Como já descrito, esse algoritmo contribuiu para o resultado final somente quando a probabilidade calculada para o *pixel* estar na área da estrada não for nula, o que raramente aconteceu. Para a elaboração desse algoritmo foi aplicado o conceito definido por Neethu, Anusha, & Krishnan, (2015). A primeira parte, na qual se calcula o fator de Bhattacharyya, foi executada e testada sem erros.

Na segunda parte do algoritmo, são criadas áreas que demonstram padrões de cores definidos como área de dentro e de fora da estrada. A definição das dimensões e posições na imagem dessas áreas também foi executada e testada sem erros. Portanto, os erros só podem ter ocorrido nas etapas seguintes do algoritmo. Para transformar o conjunto de dados, nos canais de cores RGB e HSV, das áreas definidas a priori como de estrada ou fora da estrada, foi utilizada a função do Matlab “fitdist”. Essa função cria uma distribuição normal a partir dos dados passados como

parâmetros de entrada. Por se tratar de um cálculo relativamente simples e de fácil verificação, que foi executada, não acredita-se em erros nessa etapa.

A próxima etapa calcula a matriz de covariância entre as distribuições representadas por áreas da estrada e por área fora da estrada separadamente. Para efetuar esse cálculo, utiliza-se a função “cov”. Essa função possui um erro interno no Matlab. As bibliotecas *online* e grupos técnicos de discussão orientam utilizar um artifício para solucionar esse problema. Deve-se somar uma matriz identidade de valor desprezível, não nulo, na diagonal da matriz de covariância para garantir que o resultado não fique nulo. Devido a esse fato, acredita-se que foi inserido um erro no algoritmo que sempre calculou matrizes de covariância com valores nulos ou muito pequenos. Isso gerou resultados de segmentação muitas vezes nulos. Entretanto, nas vezes que foram calculados valores de covariância não nulos ou desprezíveis, a resolução do algoritmo detectou *pixels* na área da estrada de forma correta, razão pela qual a técnica não foi desprezada.

### 5.3.5 Ajustes finais nas imagens processadas

Por fim, a aplicação dos ajustes finais na imagem e a soma ponderada das quatro técnicas demonstraram que foi efetiva a escolha por esse método. Os resultados individuais das técnicas inviabilizam qualquer implantação desse algoritmo em uma aplicação real. Entretanto, depois de somadas as técnicas, houve melhora significativa nos resultados, que ainda não possibilitam uma implantação direta no projeto de operação assistida, pois o mesmo demanda alta segurança operacional e não pode aceitar falhas de localização das estradas. Mesmo assim, o resultado desse algoritmo, se somado a outras tecnologias de medições e processamento de dados como, por exemplo, o LIDAR<sup>33</sup>, pode contribuir efetivamente para o projeto de Direção Assistida, desenvolvido pelo ITV e descrito nessa dissertação, pois disponibiliza informações úteis a respeito do ambiente hostil em que os caminhões operam.

Os resultados obtidos na segmentação da área dirigível da estrada evidenciam que o método selecionado ainda precisa de otimizações e melhorias. Mesmo assim, quando se executa o algoritmo processando uma sequência de quadros, ou seja, um vídeo, o resultado da segmentação da região de interesse permite uma interpretação

---

<sup>33</sup> Tecnologia óptica de detecção remota que mede propriedades da luz refletida de modo a obter a distância e/ou outra informação a respeito um determinado objeto ao redor do sensor.

que é válida para a identificação da estrada. A Tabela 5 sumariza os resultados para a identificação da área dirigível da estrada.


**Tabela 5** - Resultados de desempenho para identificação da área dirigível da estrada

Base de Imagens	Índice de desempenho
Internet	67%
Minas Vale	48%

Fonte: elaborada pelo autor

Avaliando-se os resultados da Tabela 5 acima, verifica-se que os mesmos foram insuficientes para contribuir no projeto de direção assistida. A técnica quantitativa (Sorensen-Dice) para medição de desempenho da segmentação da área da estrada se mostrou muito rigorosa, pontuando de forma negativa segmentações da estrada que poderiam auxiliar o operador na condução dos caminhões em condições climáticas adversas.

Na Figura 51 é possível verificar 6 quadros aleatórios de 4 vídeos com o resultado final da segmentação para alguns cenários diferentes. Na 1ª linha: estrada pavimentada; 2ª linha: estrada não pavimentada; 3ª linha: estrada pavimentada sob forte neblina; 4ª linha: estrada de mina sob condições adversas



**Figura 51** - Resultados de quadros aleatórios de vídeos demonstrando a região identificada como área dirigível das estradas.

Fonte: acervo autor

## 6. CONCLUSÃO

Após pesquisa bibliográfica, desenvolvimento dos algoritmos e testes nas bases de imagens disponíveis, verificou-se a possibilidade de identificar os limites de uma estrada em ambiente de mina, durante condições climáticas adversas, usando a fusão de imagens RGB e térmica. Considera-se o algoritmo desenvolvido eficiente para encontrar o ponto de fuga da estrada, porém o algoritmo de detecção da área da estrada não pode ser usado isoladamente no projeto de direção assistida, sendo necessário agregar outros sensores como, por exemplo, o LIDAR.

O objetivo geral da pesquisa foi atingido, permitindo, apesar das limitações, verificar a capacidade do algoritmo em identificar os limites de uma estrada em ambiente de mina, durante condições climáticas adversas.

A fusão de imagens se mostrou eficiente, sendo possível perceber seus benefícios, como já demonstrado. Atingiu-se o objetivo específico de validar essa técnica como facilitadora na identificação de limites ao longo das estradas.

Foram identificados os melhores algoritmos para detecção do ponto de fuga e identificação da área da estrada, a saber: EBMO e Quatro Técnicas Fundamentais, respectivamente. Dessa forma, foi atingido o objetivo específico de verificar o desempenho de alguns algoritmos já desenvolvidos e identificar a melhor técnica, que na verdade foi uma junção de técnicas existentes com inclusões e desenvolvimentos próprios do autor dessa pesquisa.

Muitas das técnicas utilizadas são usualmente aplicadas em vias pavimentadas, para veículos leves, como é o exemplo da EBMO. Foi comprovado que o seu uso, com algumas modificações necessárias, é adequado para estradas não pavimentadas, cumprindo-se o último objetivo específico.


O levantamento bibliográfico realizado mostrou que existem muitas pesquisas referentes ao assunto. Entretanto, a base de conhecimento disponível é recente e constituída de artigos que abordam técnicas de forma superficial, não aprofundando e detalhando o seu desenvolvimento. Mesmo assim, foi possível utilizar informações para gerar um algoritmo, composto por técnicas, métodos de diversos autores e desenvolvimentos próprios do autor dessa dissertação.

A ferramenta selecionada (Matlab) pareceu inicialmente eficiente, pois possui várias funções prontas para processamento de imagens, o que parecia ser ideal no início da pesquisa. Durante o desenvolvimento do algoritmo ficou claro que a maioria

dos autores utilizam outras ferramentas, o que dificultou a comparação de resultados entre essa pesquisa e as bases de resultados dos autores. Outro problema foi que não se conseguiu implementar no Matlab algoritmos com tempo de processamento aderentes às necessidades de uma aplicação de tempo real. Por fim, a manipulação de vídeos não possui todas as funcionalidades necessárias para essa pesquisa.

A base de imagens utilizada na pesquisa demonstrou ser outro desafio. Foram utilizadas duas fontes básicas: (1) imagens RGB de autores de artigos e da internet e (2) levantamento de campo a partir de filmagens com câmeras RGB e termográfica em diversas minas da Vale. A base de imagens dos autores é de difícil acesso, sendo possível adquirir somente algumas imagens, permanecendo a internet como fonte da maioria das imagens. Foram selecionadas imagens de boa qualidade em ambiente diurno, com diversas formas e superfícies de terreno, no intuito de estressar os algoritmos em diversas situações.

A segunda fonte conta com vídeos filmados em ambiente de mina, durante a noite, que procuram simular a pior condição de operação de caminhões com baixa luminosidade, presença de neblina e poeira. A qualidade das imagens prejudicou os testes dos algoritmos. Houve a preocupação em simular a pior condição de operação, mas muitas imagens estão com as cenas totalmente desconfiguradas, não sendo possível nem na imagem térmica identificar qualquer forma. Infere-se que nem mesmo o algoritmo mais robusto conseguiria identificar a estrada com essas imagens. A Figura 52 exemplifica algumas cenas nessas condições.



**Figura 52** - Exemplos de imagem de baixa qualidade da base de imagens Vale

Fonte: FREITAS; ZANETTI; MIOLA (2015)

O projeto do ITV, de Direção Assistida, propõe o uso de LIDAR e radar para auxiliar na identificação de estradas. Essa instrumentação, fora de escopo dessa pesquisa, contribuirá para a correta identificação das estradas, devendo ser usada em conjunto com as informações disponibilizadas pelo algoritmo desenvolvido nesse trabalho, a fim de integrar um sistema mais completo e robusto que consiga atender a alta demanda de segurança do projeto. Todavia, a entrega dessa pesquisa é uma prova de conceito e não tem pretensão de suprir a demanda completa do projeto que disponibilizará informações suficientes ao operador de caminhão para operação segura em condições climáticas adversas.

## **6.1. Principais contribuições da dissertação**

O projeto de pesquisa contribuiu para o desenvolvimento de ferramentas computacionais de processamento de imagens, que podem ser aplicadas em diferentes equipamentos, na mineração e em outras indústrias. Com os resultados obtidos, será possível prover para o projeto de direção assistida, desenvolvido pelo ITV, um algoritmo que realiza a fusão de imagens RGB e térmica robusto de tal forma, que mesmo sob condições climáticas adversas, gera informação que agrega na identificação das estradas.

A pesquisa conseguiu também reunir dados relevantes do ambiente real da mineração e propôs uma metodologia de desenvolvimento de códigos de processamento de imagens e de testes da eficiência dos mesmos na identificação de estradas. Essa metodologia e os códigos não estão bem descritos na literatura existente e contribuem no projeto de direção assistida possibilitando também a publicação de artigos em revistas científicas.

Acredita-se que os resultados obtidos durante a execução do projeto possam contribuir para o desenvolvimento do projeto de direção assistida do ITV, que planeja gerar como benefício o aumento da produtividade dos equipamentos de mina e a redução dos riscos de acidentes com colisões de equipamentos na área de mineração. Em virtude disso, o trabalho apresentado nessa dissertação é de suma importância e os resultados alcançados mostram sua aplicabilidade e contribuição efetiva com o projeto.

## 6.2 Trabalhos futuros

A continuação da pesquisa, através de trabalhos futuros, passa, inicialmente, pelo aprimoramento dos algoritmos desenvolvidos para melhoria de desempenho com relação ao tempo de processamento e identificação de estradas. Os algoritmos devem ser capazes de lidar com aplicações de tempo real e realizarem a segmentação das áreas dirigíveis das estradas em tempo hábil para a correta tomada de decisão dos operadores de caminhão. Para lidar com os vídeos, os algoritmos precisam de técnicas mais robustas de tratamentos de erros em cada quadro para gerar uma segmentação das imagens mais uniforme e menos abrupta em relação a transição de cada quadro da imagem. Eles devem ser traduzidos em plataformas de softwares embarcados de alto desempenho e serem instalados nos caminhões para efetuarem a interface com sistemas de automação desses equipamentos. Os algoritmos devem ser desenvolvidos de tal forma que reduzam o custo computacional, relacionado ao tempo de processamento, o que permitiria o processamento das imagens em tempo real.

Para uma aplicação real de direção assistida de caminhões em ambiente de mineração, é necessário o desenvolvimento de infraestrutura adequada para o ambiente agressivo com presença de sujeira, umidade, altas temperaturas e vibração. O hardware embarcado em um caminhão, que trabalha em ambiente de mineração, deve ser robusto e ser instalado de forma correta, tendo alta disponibilidade, para evitar interrupções que afetem a produtividade.

Uma abordagem interessante deve ser aplicada em trabalhos futuros: a detecção do nível de neblina ou poeira e o tratamento da imagem em virtude desses fenômenos. Gallen, *et al.* (2015) propõem um método para caracterização do tipo de neblina à frente do veículo, durante a noite, enviando essa informação para um sistema de direção assistida que emite o alerta ao condutor. O método avalia a presença de neblina utilizando como referência as variações e correlação de valores conhecidos das imagens ao redor dos feixes dos faróis dos veículos. Choi; Jeong; Song (2017) apresentam um método de *de-fog* que retira a neblina de imagens possibilitando melhores condições para auxiliar um sistema de direção assistida.

Por fim, devem ser utilizados outros sensores para auxiliar a correta identificação da estrada, como o LIDAR, por exemplo, que torna o sistema mais assertivo, com menor possibilidade de erros na detecção da área dirigível da estrada.



Além da identificação da estrada, os sensores devem ser capazes de identificar obstáculos à frente do caminhão, como outros veículos e pessoas, para garantir a segurança do sistema de direção assistida, tema não abordado nessa dissertação.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

- ACHANTA, R. et al. SLIC superpixels compared to state-of-the-art superpixel methods. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Novembro 2012. 2274-2281.
- ALON, Y.; FERENCZ, A.; SHASHUA, A. Off-road path following using region classification and geometric projection constraints. **Computer Vision and Pattern Recognition, 2006 IEEE Computer Society Conference**, 1, 2006. 689-696.
- ÁLVAREZ, J. M.; GEVERS, T.; LÓPEZ, A. M. Vision-based road detection using road models. **Image Processing (ICIP), 2009 16th IEEE International Conference**, 10 Novembro 2009. 2073-2076.
- BELLINO, M.; MENESES, Y. L. D.; JACOT, P. R. A. J. Lane detection algorithm for an onboard camera. **European Workshop on Photonics in the Automobile. International Society for Optics and Photonics**, 2005.
- BOX, J. F. Guinness, gosset, fisher, and small samples. **Statistical Science**, 1987. 45-52.
- CRISMAN, J. D.; THORPE, C. E. SCARF: a color vision system that tracks roads and intersections. **Robotics and Automation, IEEE Transactions on**, 1993. 49-58.
- FREITAS, G.; ZANETTI, E.; MIOLA, W. **Testes com Câmeras para o Sistema de Direção Assistida de Equipamentos de Mineração**. Ouro Preto. 2015.
- GAO, Q.; LUO, Q.; MOLI, S. Rough set based unstructured road detection through feature learning. **International Conference on Automation and Logistics, IEEE**, 21 Agosto 2007. 101-106.
- HAGUE, T.; MARCHANT, J. A.; TILLET, N. D. Ground based sensing systems for autonomous agricultural vehicles. **Computers and Electronics in Agriculture** **25.1**, 2000. 11-28.
- KONG, H.; AUDIBERT, J.-Y.; PONCE, J. General road detection from a single image. **IEEE Transactions on Image Processing**, 19, Agosto 2010. 2211-2220.
- KUMAR, K. S. et al. **Visual and thermal image fusion for UAV based target tracking**. Rijeka: InTech Europe, 2011. 307-326 p.
- KWANG YEON CHOI, K. M. J. B. C. S. Fog detection for de-fogging of road driving images. **IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)**, 2017.
- LIAO, W. et al. Two-stage fusion of thermal hyperspectral and visible RGB image by PCA and guided filter. **2015 7th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)**, 5 Junho 2015. 4. teste.
- LOOKINGBILL, A. et al. Reverse optical flow for self-supervised adaptive autonomous robot navigation. **International Journal of Computer Vision** **74**, 2007. 287-302.
- LU, X. New efficient vanishing point detection from a single road image based on intrinsic line orientation and color texture properties. **Optical Engineering** **51**, 2012. 1-15.

- MADHAVAN, R. et al. Evaluation of internal navigation sensor suites for underground mining vehicle navigation. **International Conference on Robotics & Automation**, 1999. 999-1004.
- NEETHU, J.; ANUSHA, B.; KRISHNAN, K. A reliable method for detecting road regions from a single image based on color distribution and vanishing point location. **Second International Symposium On Computer Vision and the Internet**, 2015. 2-9.
- NGUYEN, L.; PHUNG, S. L.; BOUZERDOUM, A. Efficient vanishing point estimation for unstructured road scenes. **International Conference on Digital Image Computing: Techniques and Applications (DICTA)**, 2016.
- OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on System, Man and Cybernetics**, 1979. 62-66.
- PISANO, P. A.; GOODWIN, L. C.; ROSSETTI, M. A. US highway crashes in adverse road weather conditions. **24th Conference on International Interactive Information and Processing Systems for Meteorology, Oceanography and Hydrology**, 2008.
- PORTER, T.; DUFF, T. Compositing digital images. **Computer Graphics Project Lucasfilm Ltd.**, Julho 1984. 7.
- RASMUSSEN, C. Grouping dominant orientations for ill-structured road following. **Computer Vision and Pattern Recognition, IEEE, 2004**, 1, 2004. 1-470.
- ROMAIN GALLÉN, A. C. N. H. É. D. A. D. A. Nighttime visibility analysis and estimation method in the presence of dense fog. **IEEE Transactions on Intelligent Transportation Systems**, 01 Fevereiro 2015. 310-319.
- SHENGYAN, Z. et al. Road detection using support vector machine based on online learning and evaluation. **Intelligent Vehicles Symposium (IV), 2010 IEEE**, 24 Junho 2010. 256-261.
- SHI, J.; WANG, J.; FU, F. Fast and robust vanishing point detection for unstructured road following. **IEEE Transactions on Intelligent Transportation Systems**, 17, Abril 2016. 970-979.
- SMITH, A. R. Image compositing fundamentals. **Technical Memo 4**, 15 Agosto 1995. 8.
- SØRENSEN, T. A method of establishing groups of equal amplitude in plant sociology based on similarity of species and its application to analyses of the vegetation on Danish commons. **Kongelige Danske Videnskabernes Selskab**, 1948. 1-34.
- SOUTHALL, J. B.; TAYLOR, C. Stochastic road shape estimation. **Proc. IEEE Int. Conf. Computer Vision**, 2001. 205-212.
- SUSPERREGI, L. et al. RGB-D, laser and thermal sensor fusion for people following in a mobile robot. **International Journal of Advanced Robotic Systems**, 7 Agosto 2013. 1-9.
- TOET, A. et al. Fusion of visible and thermal imagery improves situational awareness. **TNO Human Factors Research Institute**, 18 Agosto 1997. 85-95.

WANG, B.; FREMONT, V.; RODRIGUEZ, S. A. Color-based road detection and its evaluation on the KITTI road benchmark. **Intelligent Vehicles Symposium Proceedings, 2014 IEEE**, 11 Junho 2014. 31-36.

WANG, H. et al. Road detection via superpixels and interactive image. **The 4th Annual IEEE International Conference on Cyber Technology in Automation**, 4 jul. 2014. 152-155.

WU, M.; LAM, S.-K.; SRIKANTHAN, T. Nonparametric technique based high-speed road surface detection. **Intelligent Transportation Systems, IEEE Transactions**, 16, Abril 2015. 874-884.

XIA, X. et al. Segmentation based on the unstructured road with shadow. **8th International Conference on Intelligent Human-Machine Systems and Cybernetics**, 2016. 501-504.

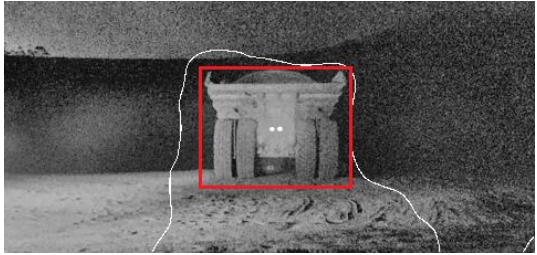
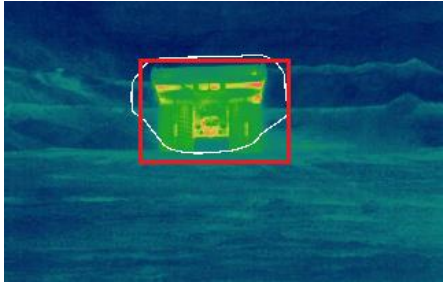
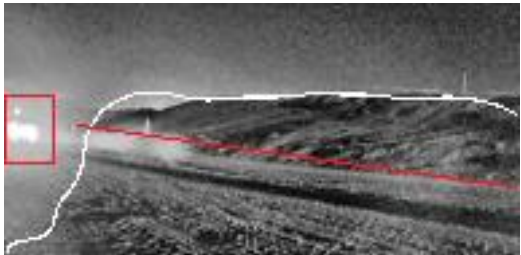
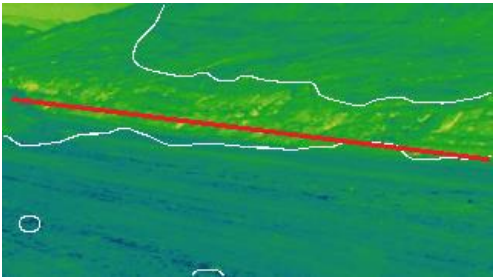
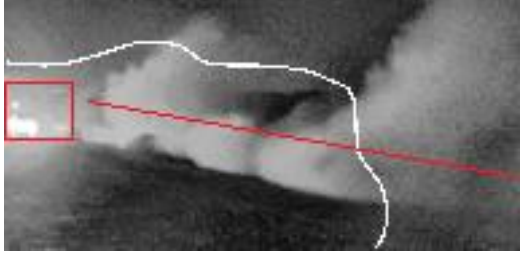

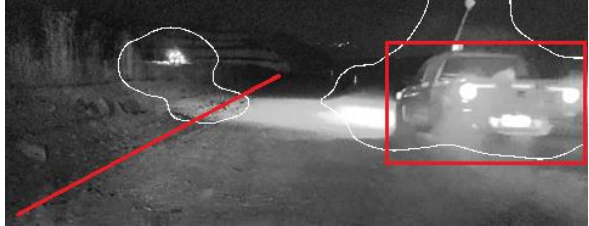
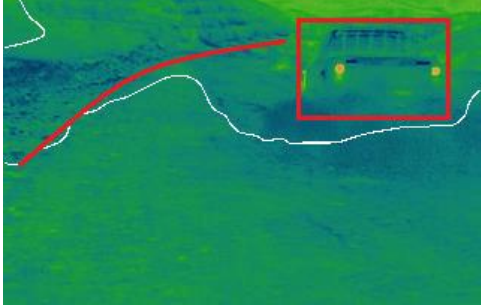
YANG, W.; FANG, B.; TANG, Y. Y. Fast and accurate vanishing point detection and its application in inverse perspective mapping of structured road. **IEEE Transactions on Systems, Man and Cybernetics**, Março 2016. 1-11.

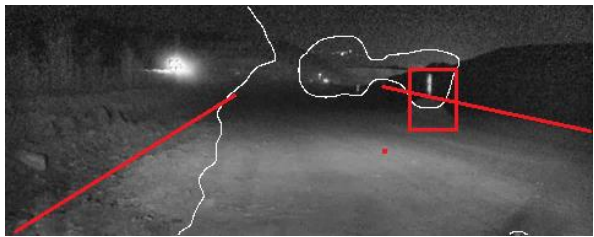
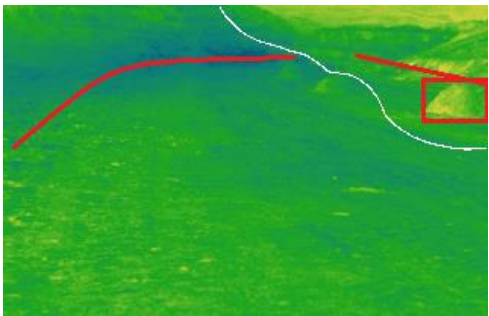
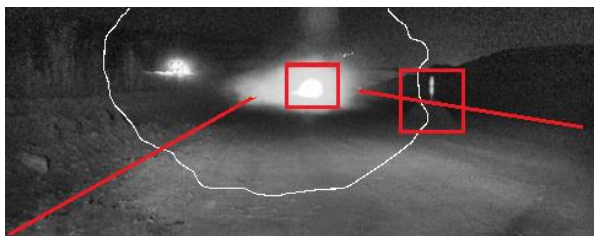
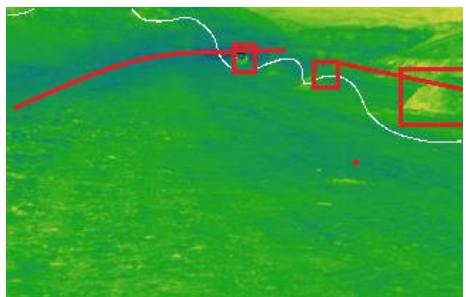
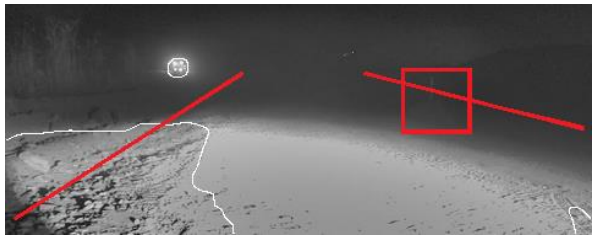

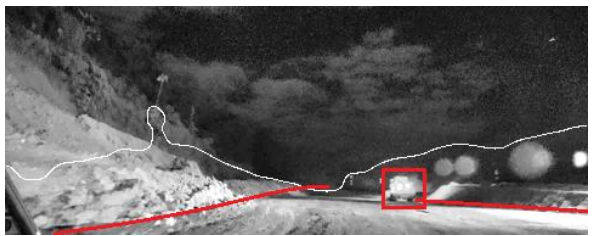
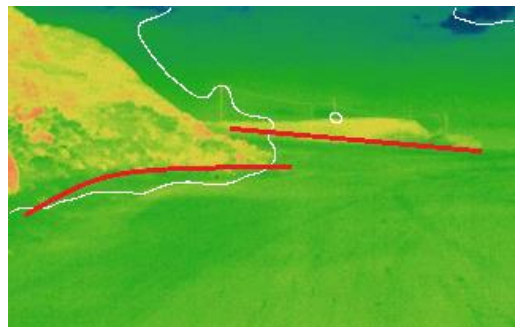
YOON, J. S. et al. Thermal-infrared based drivable region detection. **IEEE Intelligent Vehicles Symposium**, Junho 2016. 978-985.


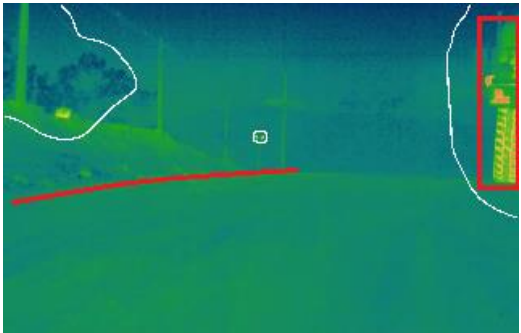

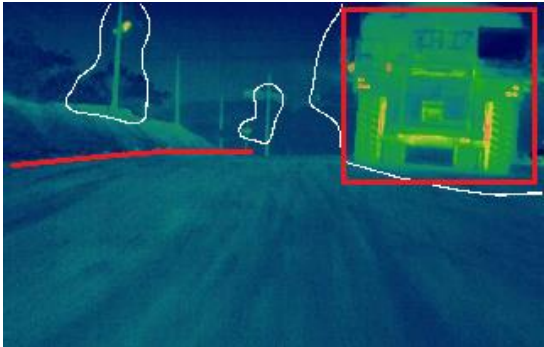


YOUNG, T. E. A. The Bakerian Lecture: On the theory of light and colours. **Philosophical Transactions of the Royal Society of London**, 92, 1802. 12-48.

ZHEN, H. et al. Robust road detection from a single image using road shape prior. **Image Processing (ICIP), 2013 20th IEEE International Conference**, 18 Setembro 2013. 2757-2761.



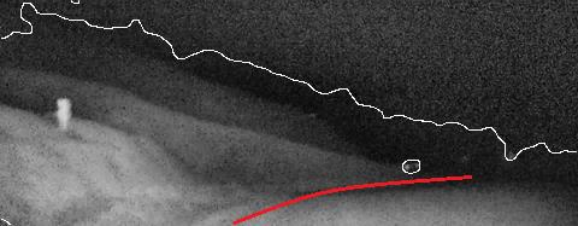
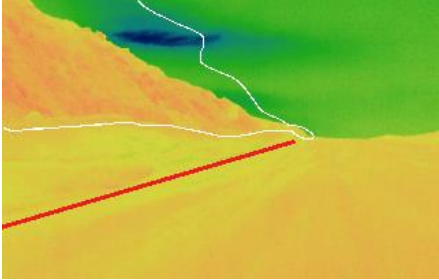
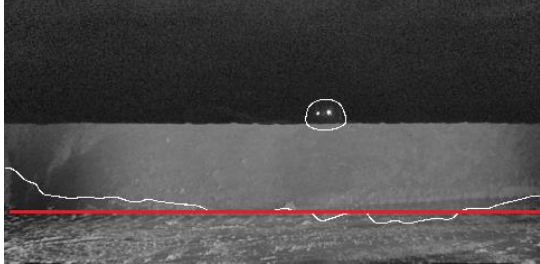
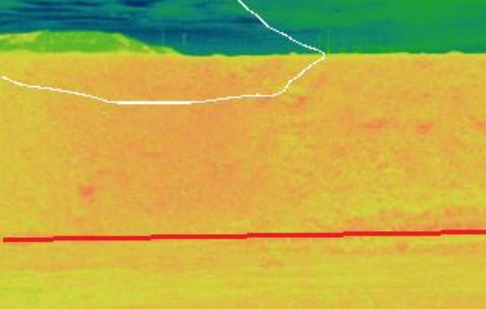
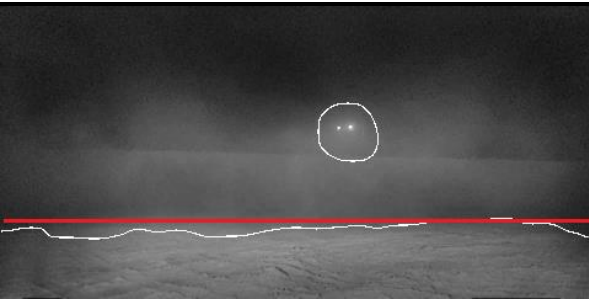
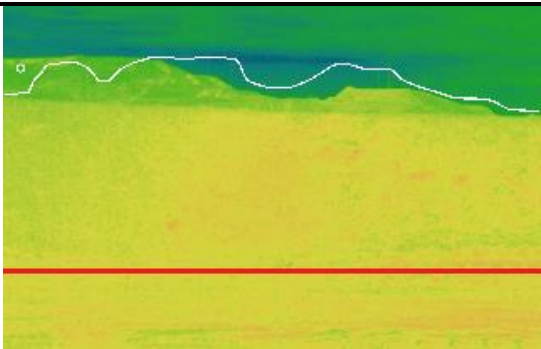
## ANEXO A – Resultados algoritmo MATL

Imagens RGB	Imagens térmica
	
	
	
	
<p><b>Figura 53</b> - Resultados algoritmo MATL          Fonte: FREITAS; ZANETTI; MIOLA (2015)</p>	


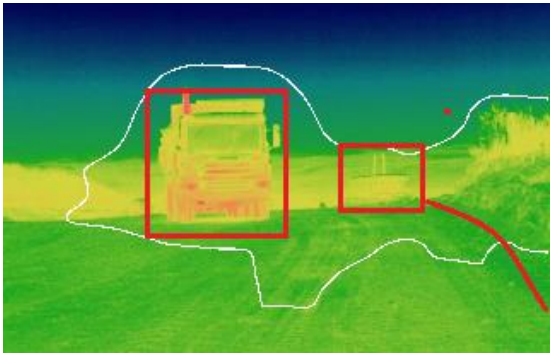
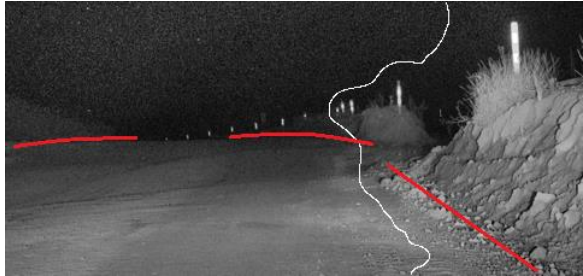
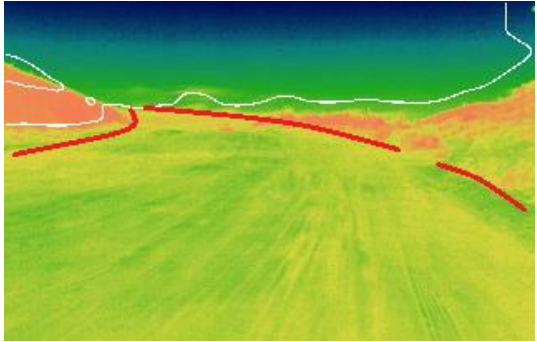
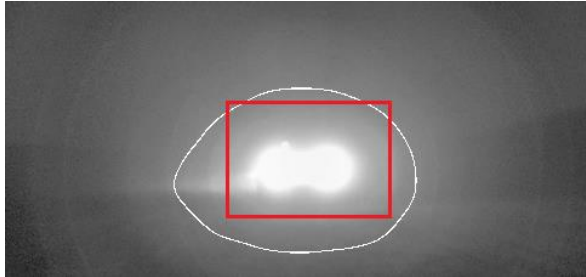

Imagens RGB	Imagens térmica
	
	
	
	
<p><b>Figura 54</b> - Resultados algoritmo MATL (continuação)          Fonte: FREITAS; ZANETTI; MIOLA (2015)</p>	

Imagens RGB	Imagens térmica
	
	
	
<p><b>Figura 55</b> - Resultados algoritmo MATL (continuação) Fonte: FREITAS; ZANETTI; MIOLA (2015)</p>	

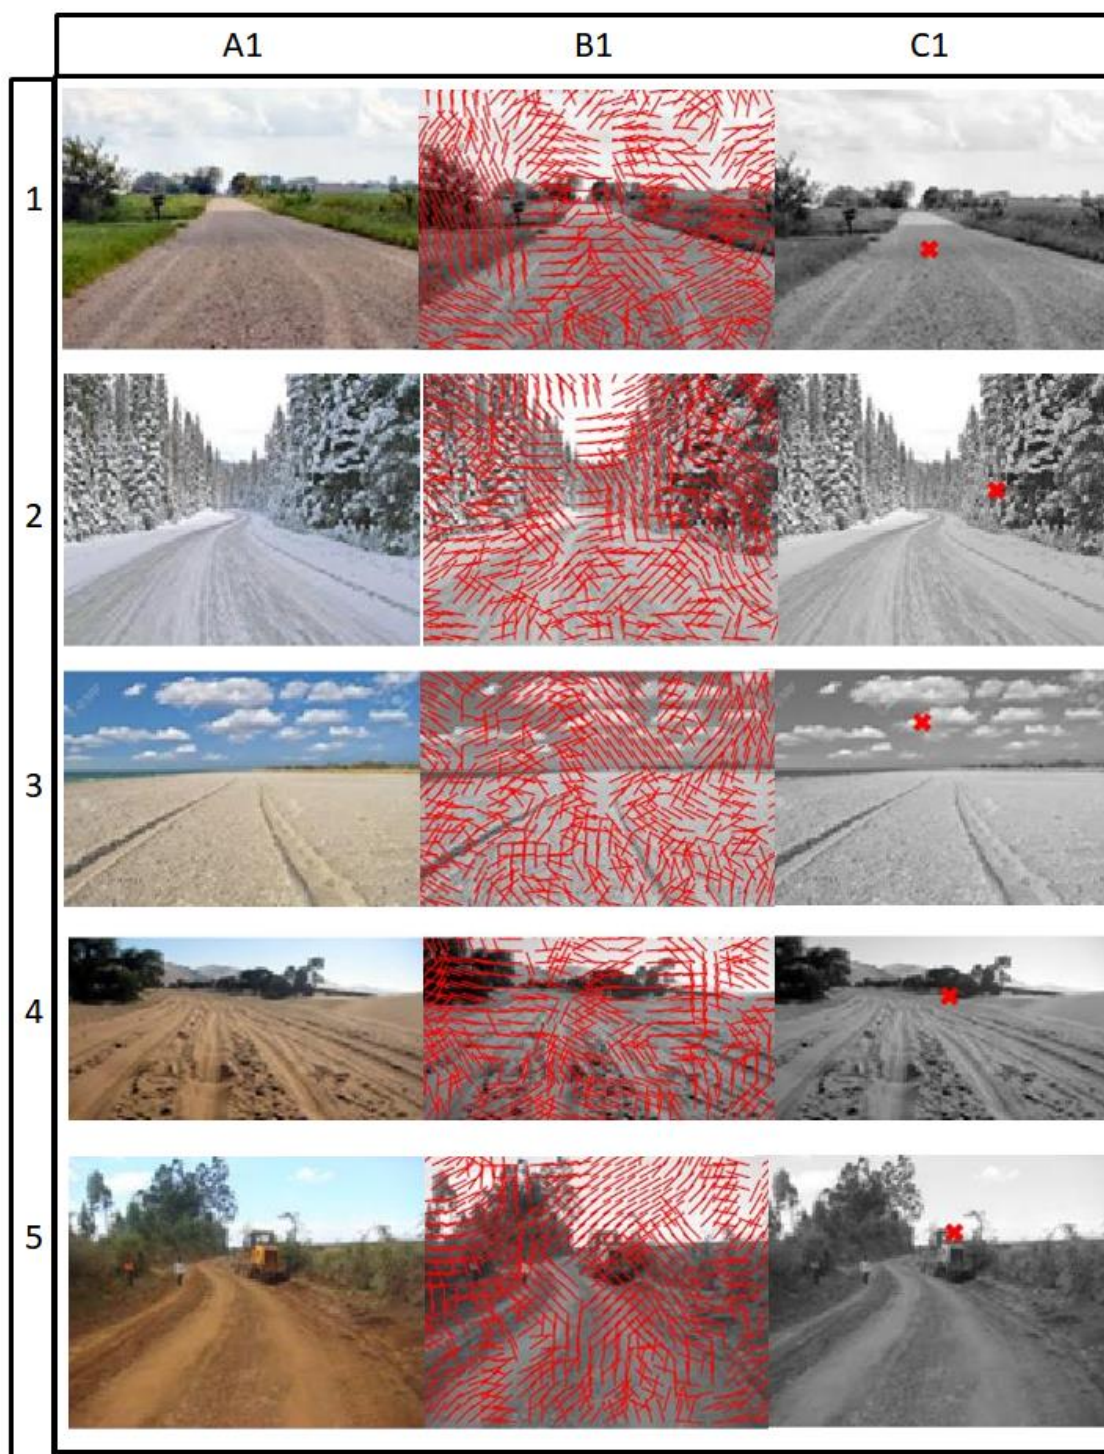


Imagens RGB	Imagens térmica
	
	
	
	
<p><b>Figura 56</b> - Resultados algoritmo MATL (continuação)  Fonte: FREITAS; ZANETTI; MIOLA (2015)</p>	



Imagens RGB	Imagens térmica
	
	
	
<p><b>Figura 57</b> - Resultados algoritmo MATL (continuação) Fonte: FREITAS; ZANETTI; MIOLA (2015)</p>	

## ANEXO B – Resultados algoritmo LASV



**Figura 58** - Resultado localização ponto de fuga algoritmo LASV (A1;B1;C1)

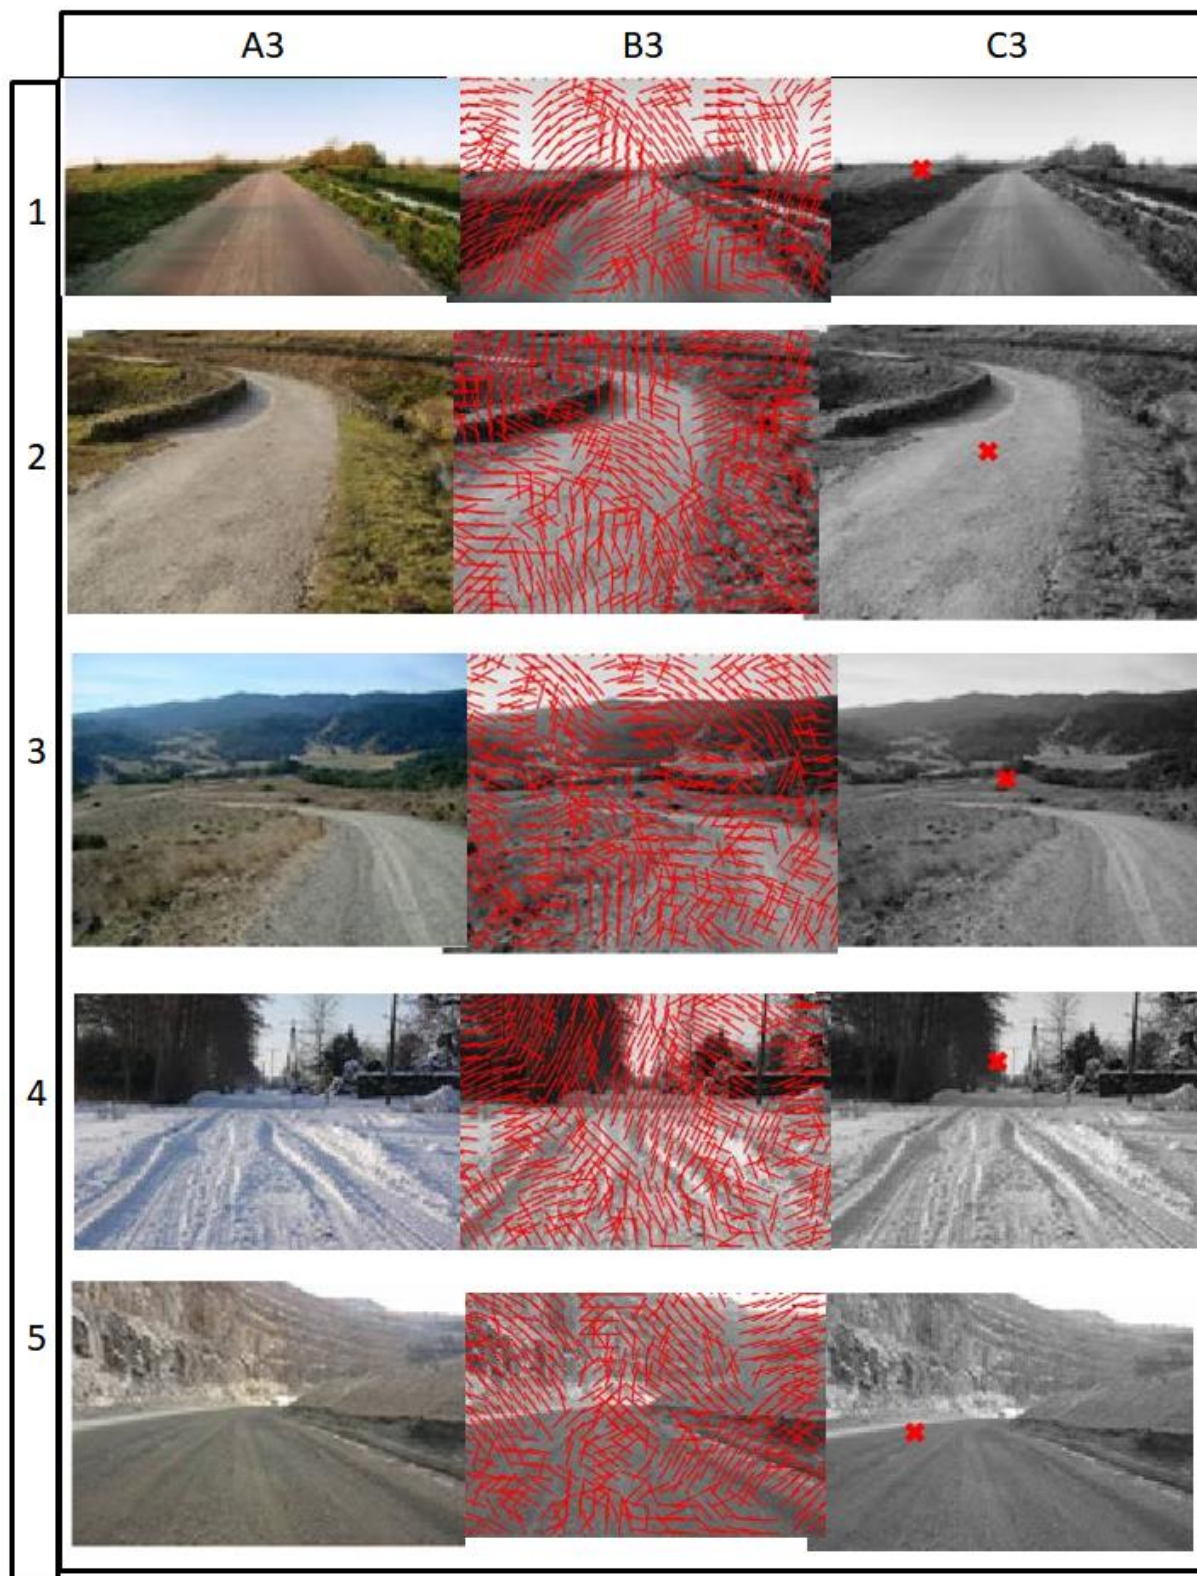
Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road dataset” no Google Imagens





**Figura 59** - Resultado localização ponto de fuga algoritmo LASV (A2;B2;C2)

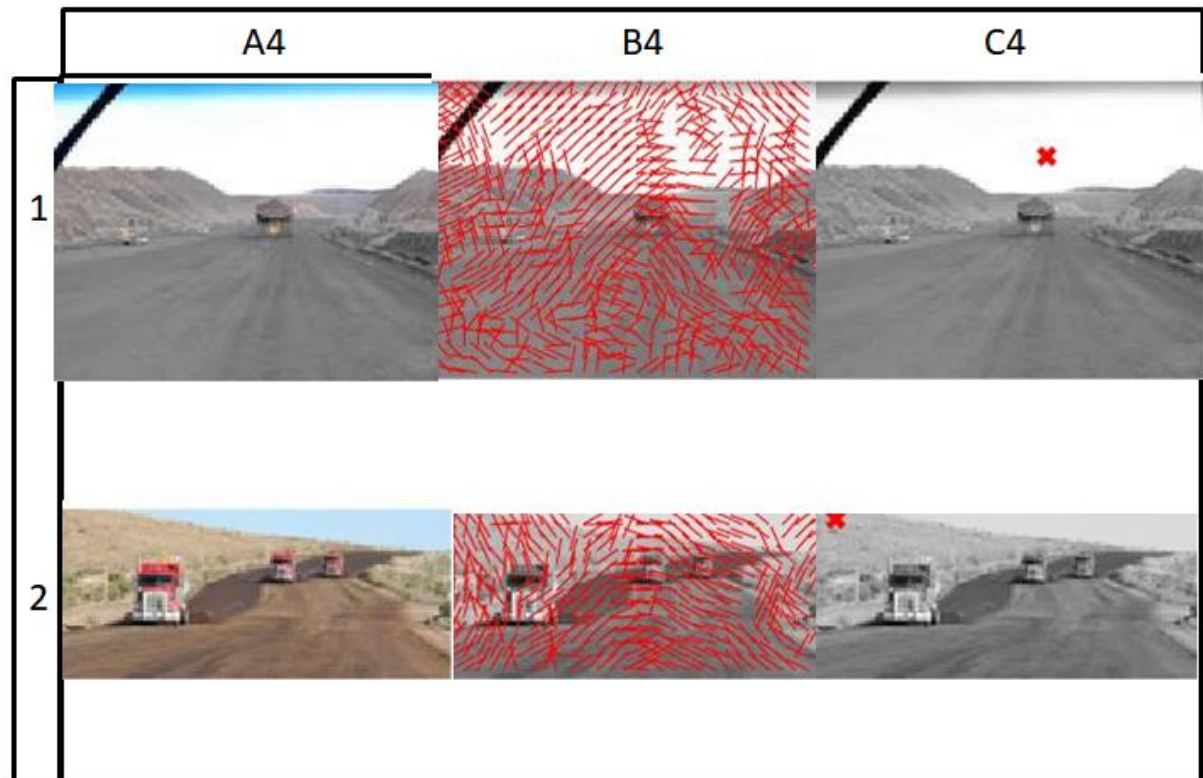
Fonte: imagens retiradas da internet por pesquisa de "unstrucutre road dataset" no Google Imagens



**Figura 60** - Resultado localização ponto de fuga algoritmo LASV (A3;B3;C3)


Fonte: imagens retiradas da internet por pesquisa de "unstrucutre road dataset" no Google Imagens






**Figura 61** - Resultado localização ponto de fuga algoritmo LASV (A4;B4;C4)

Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road dataset” no Google Imagens

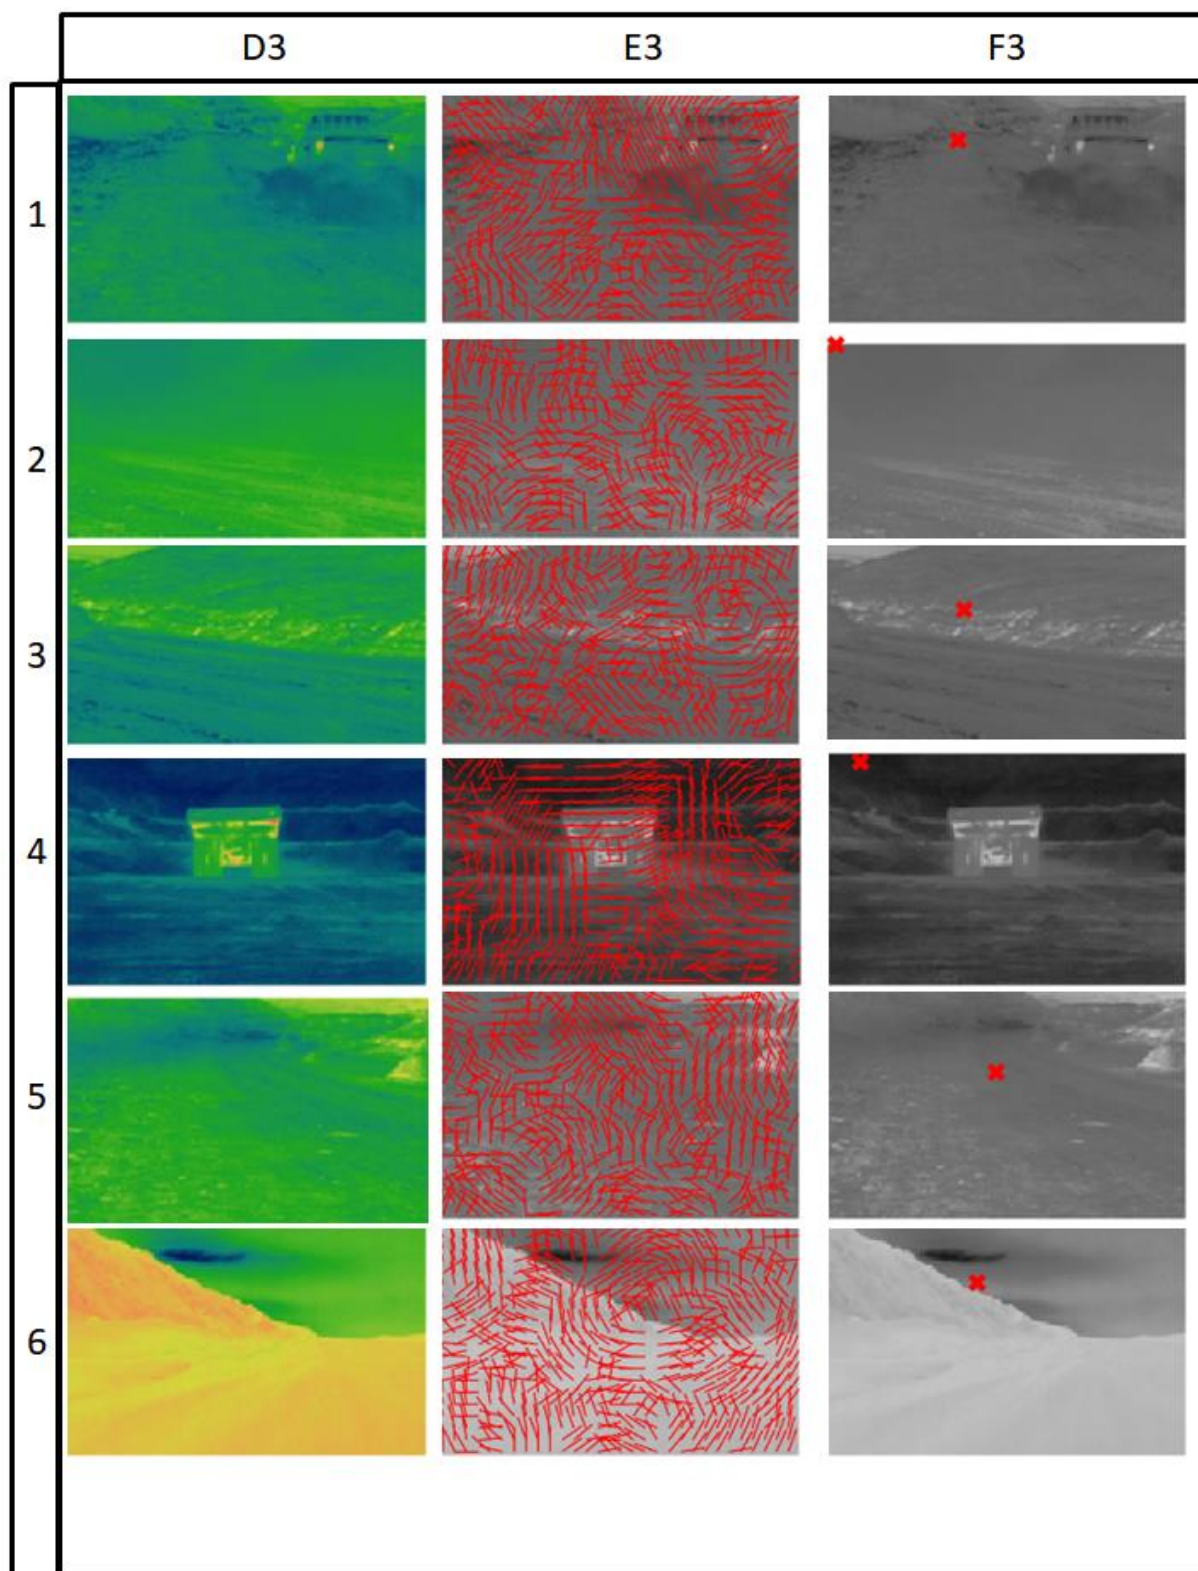


**Figura 62** - Resultado localização ponto de fuga algoritmo LASV (D1;E1;F1)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)



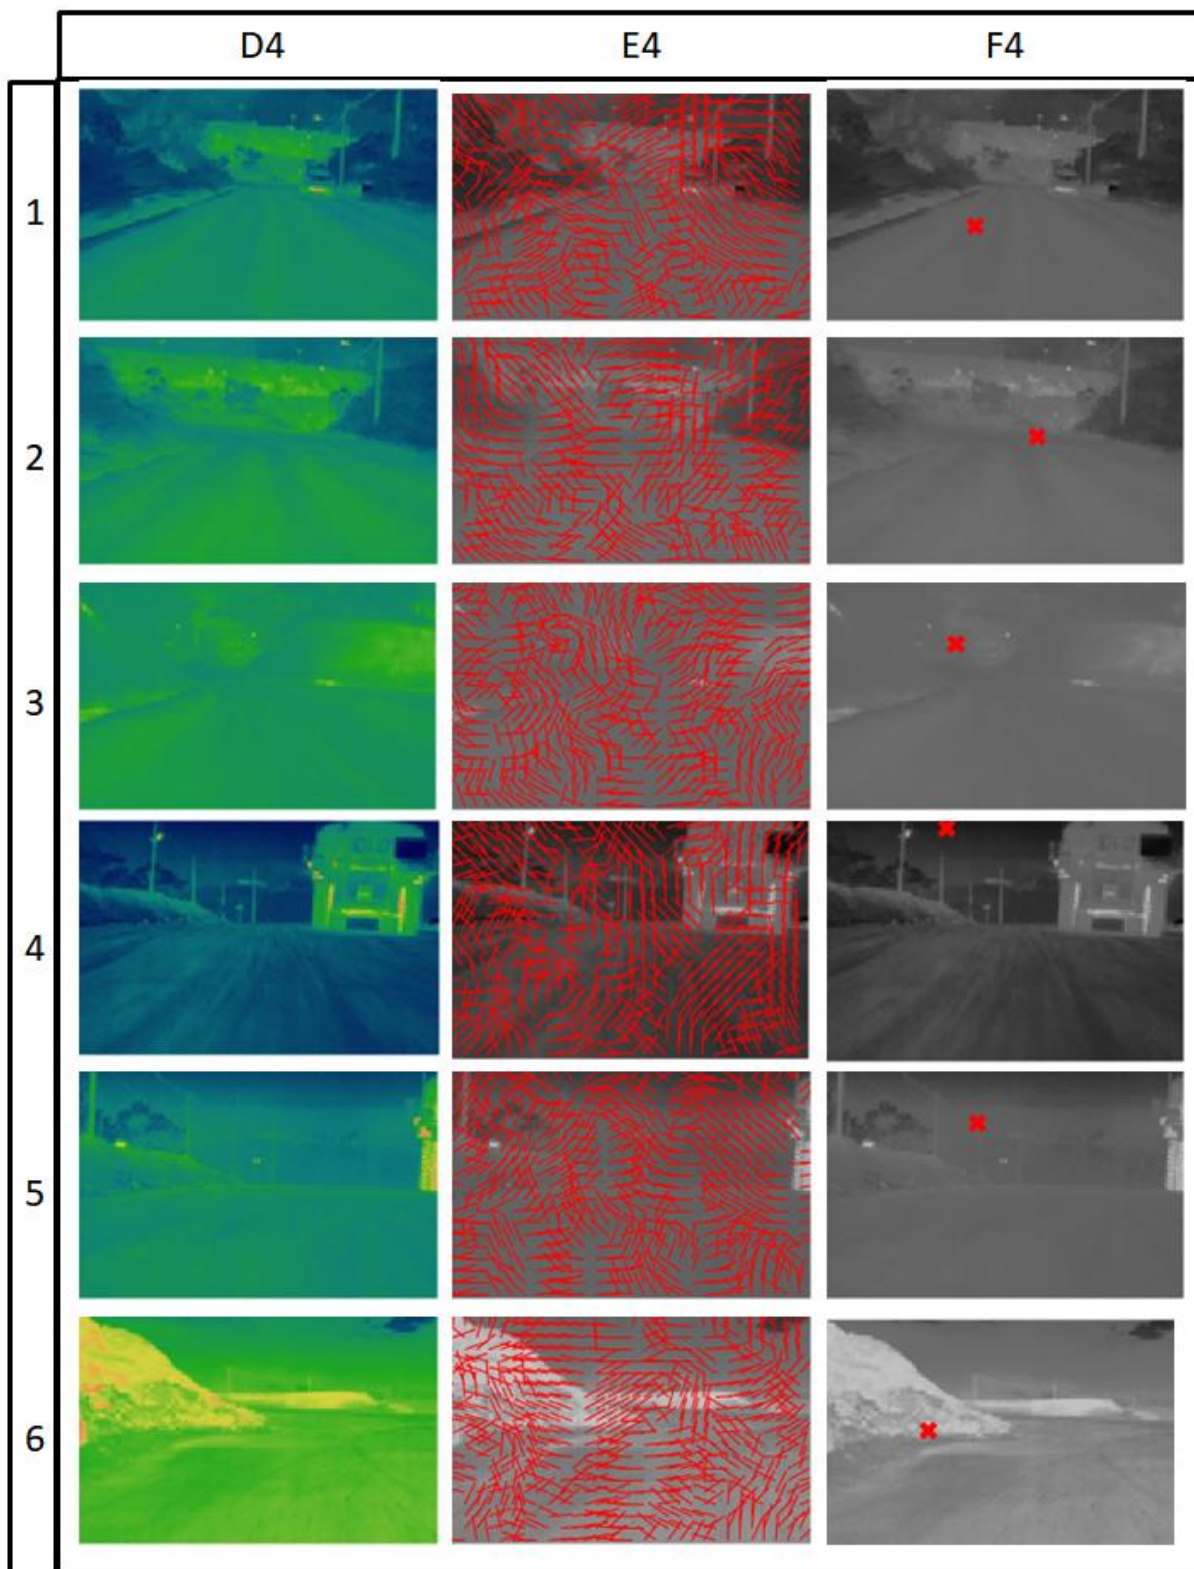
**Figura 63** - Resultado localização ponto de fuga algoritmo LASV (D2;E2;F2)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)





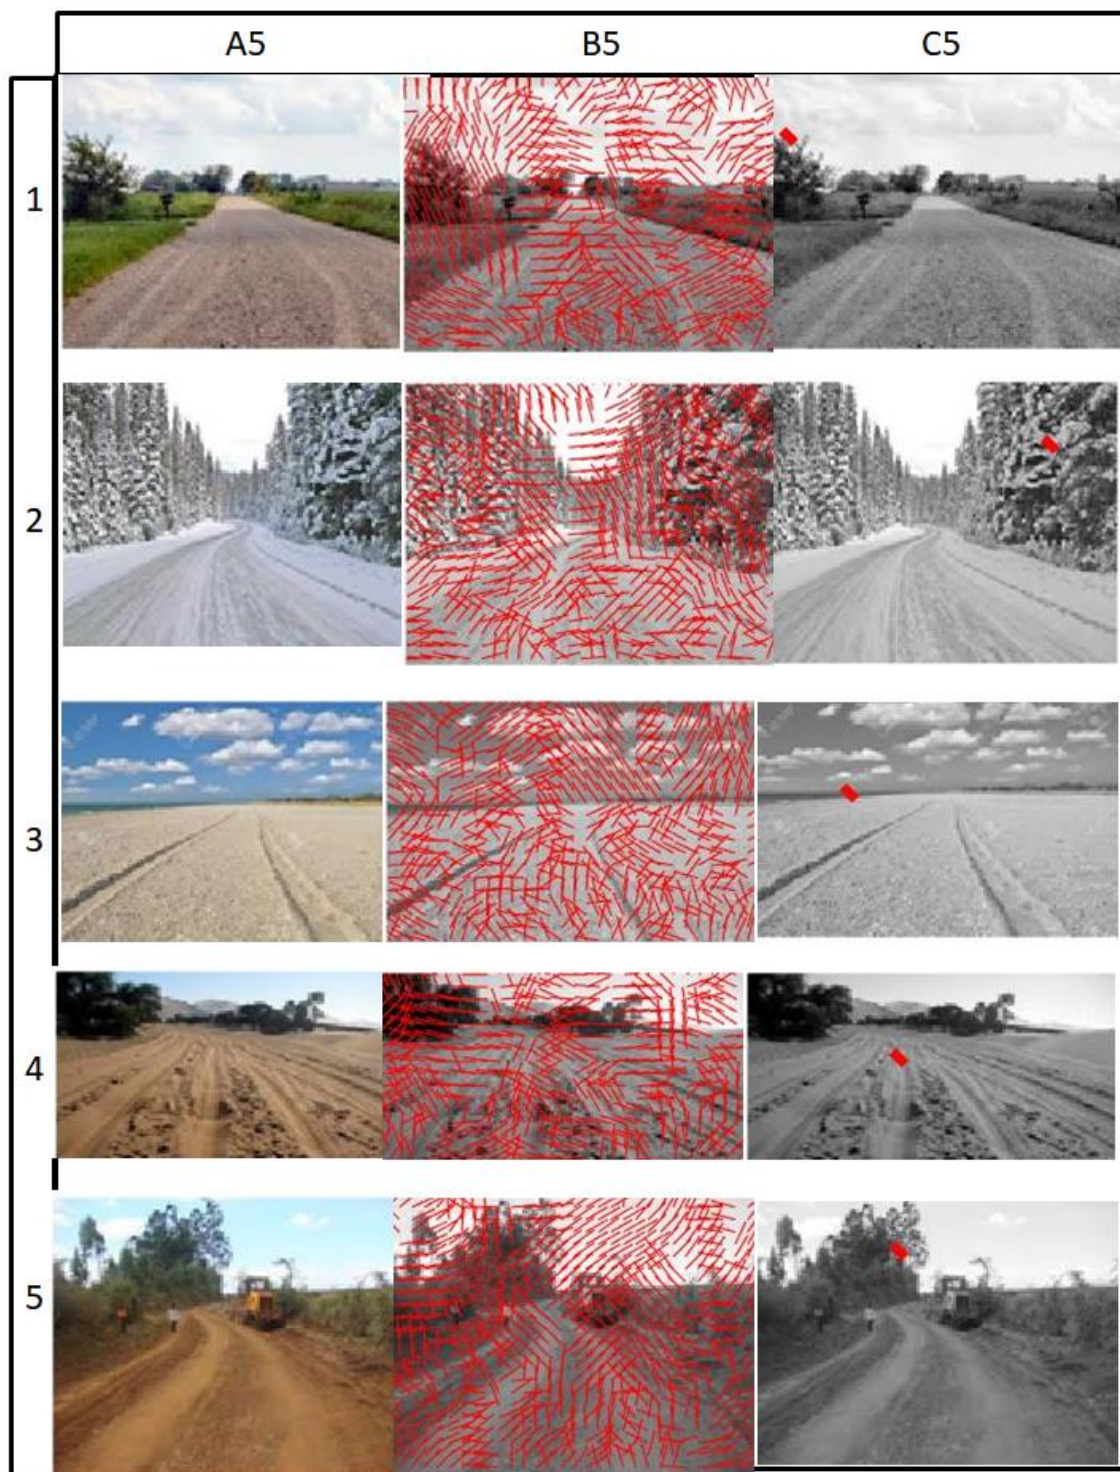
**Figura 64** - Resultado localização ponto de fuga algoritmo LASV (D3;E3;F3)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)





**Figura 65** - Resultado localização ponto de fuga algoritmo LASV (D4;E4;F4)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)

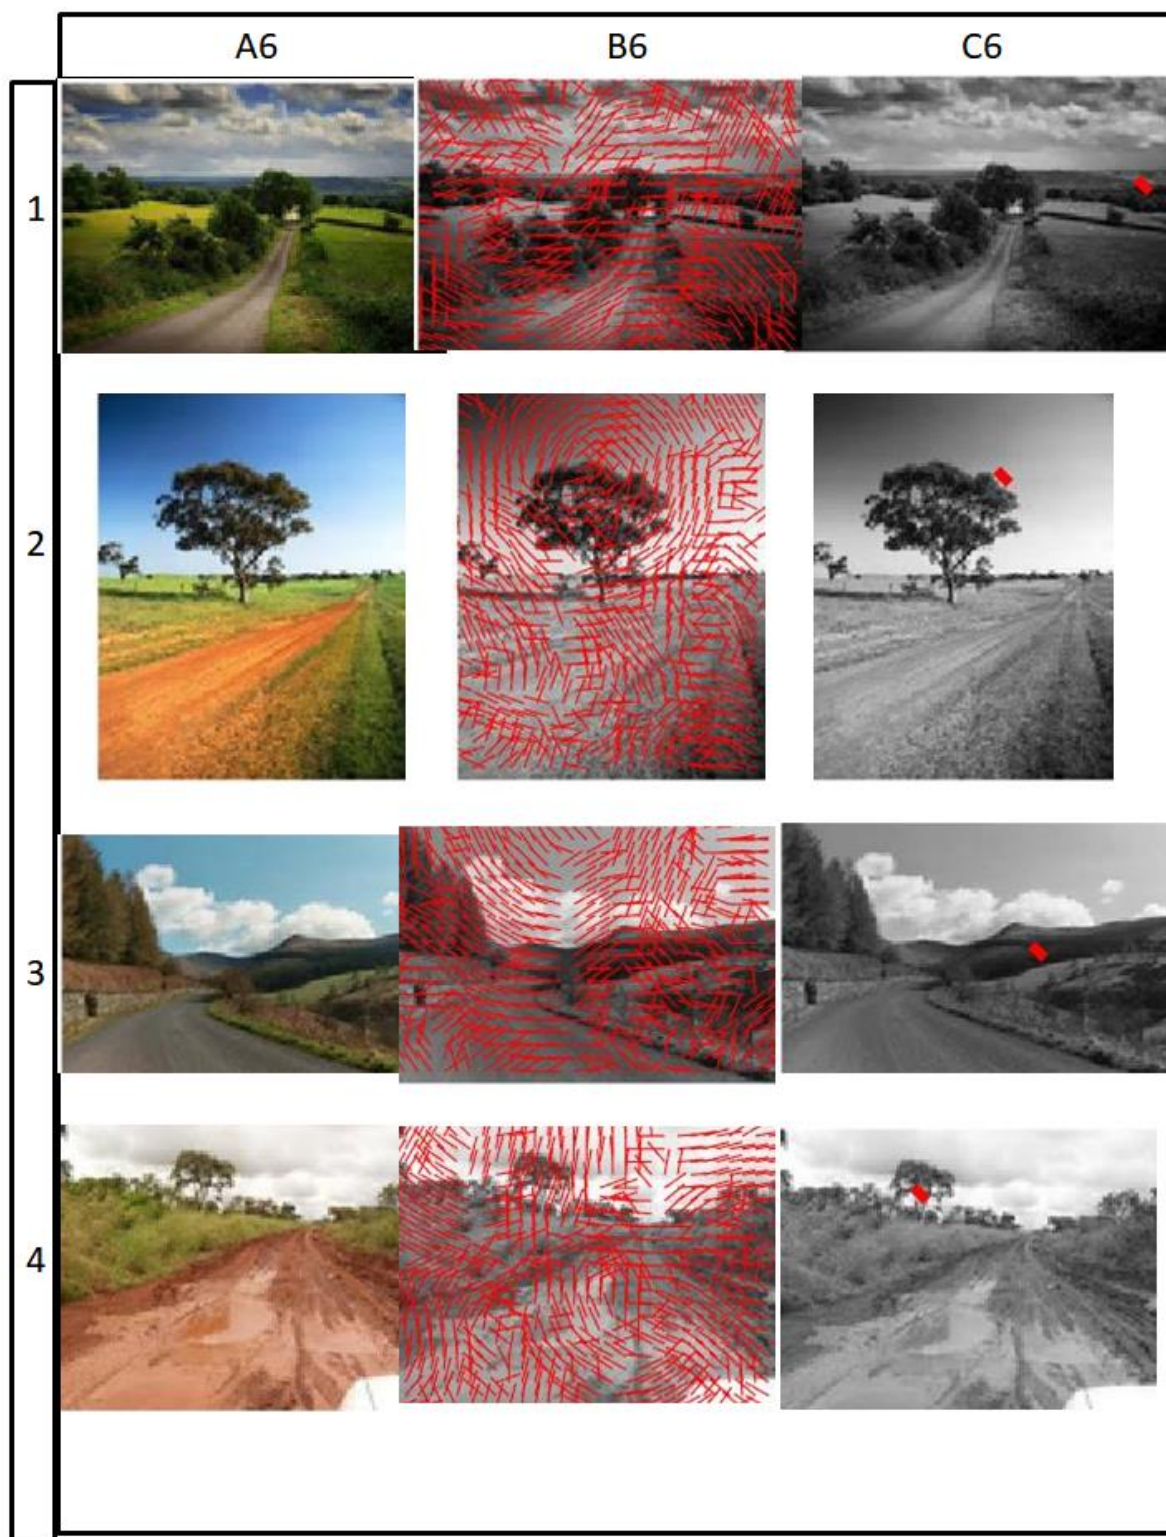
## ANEXO C – Resultados algoritmo *Fast Vanishing Point Detection*



**Figura 66** - Resultado localização ponto de fuga algoritmo FAVP (A5;B5C5)

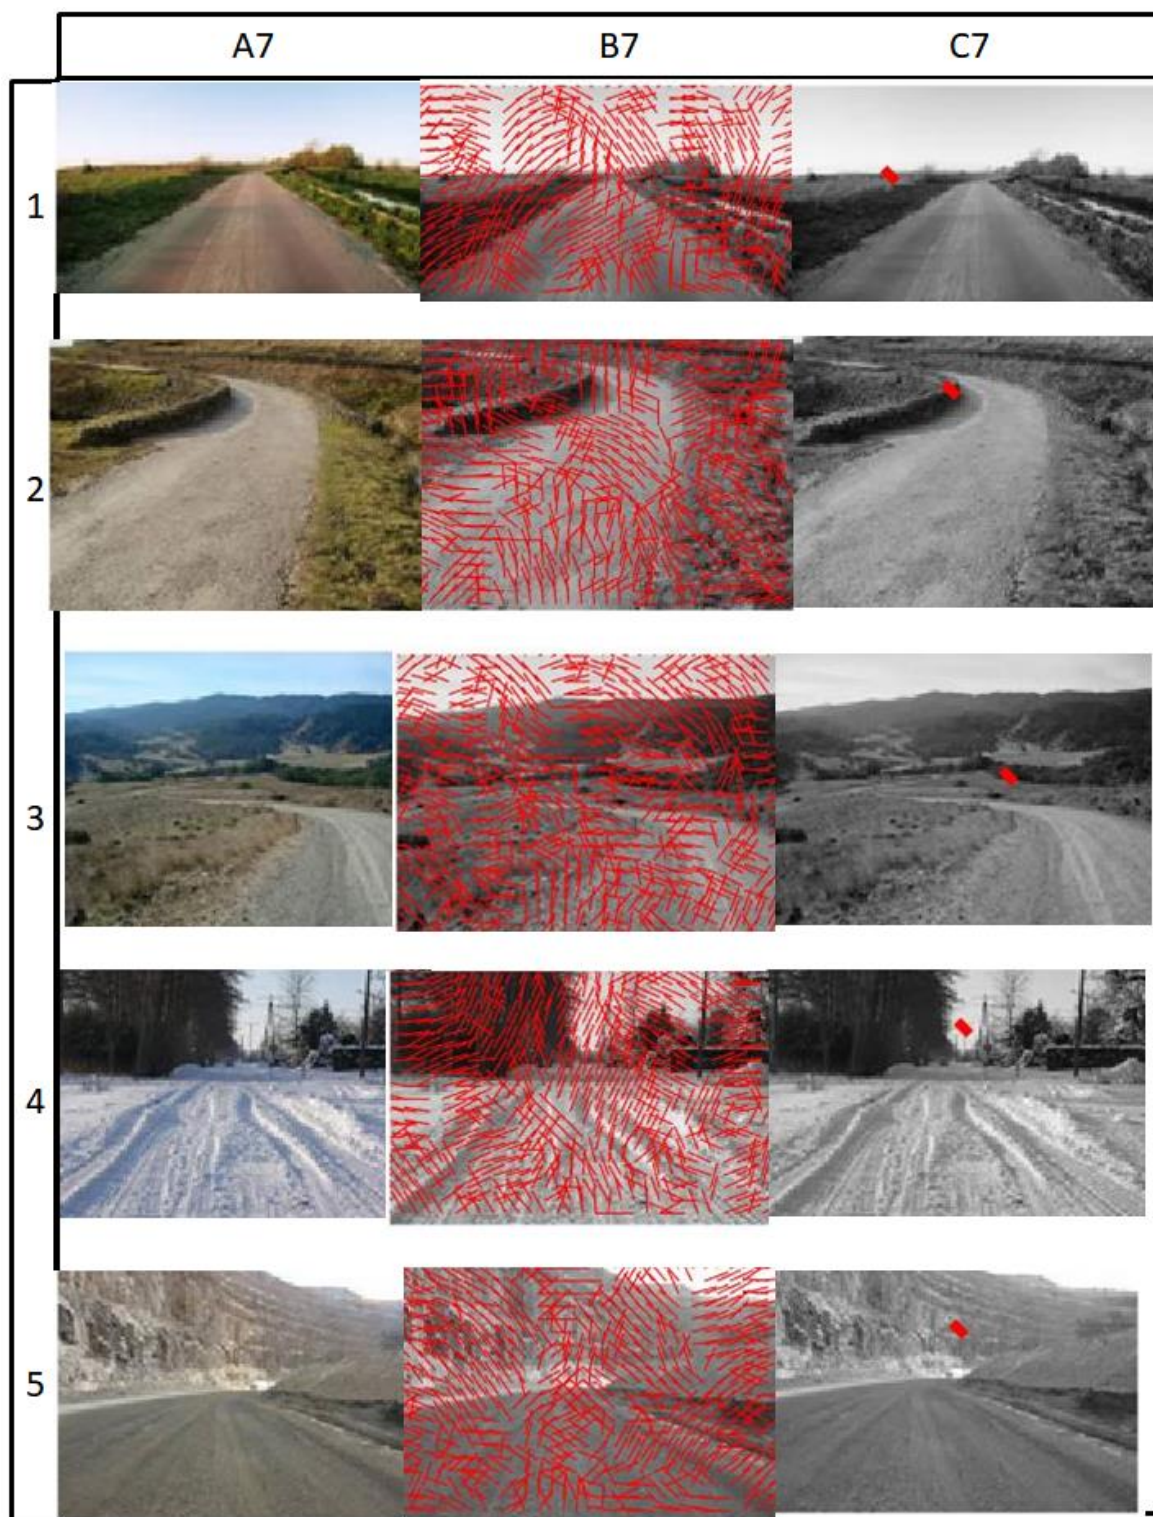
Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road dataset” no Google Imagens





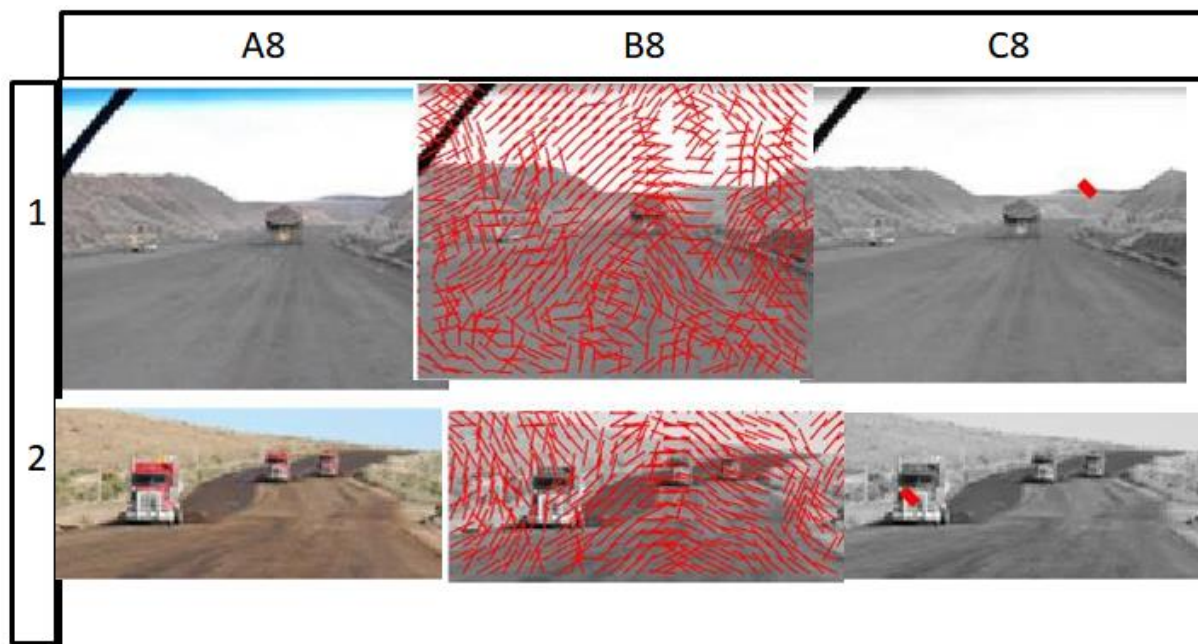
**Figura 67** - Resultado localização ponto de fuga algoritmo FAVP (A6;B6;C6)

Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road dataset” no Google Imagens




**Figura 68** - Resultado localização ponto de fuga algoritmo FAVP (A7;B7;C7)  
 Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road dataset” no Google Imagens






**Figura 69** - Resultado localização ponto de fuga algoritmo FAVP (A8;B8;C8)

Fonte: imagens retiradas da internet por pesquisa de "unstrucutre road dataset" no Google Imagens

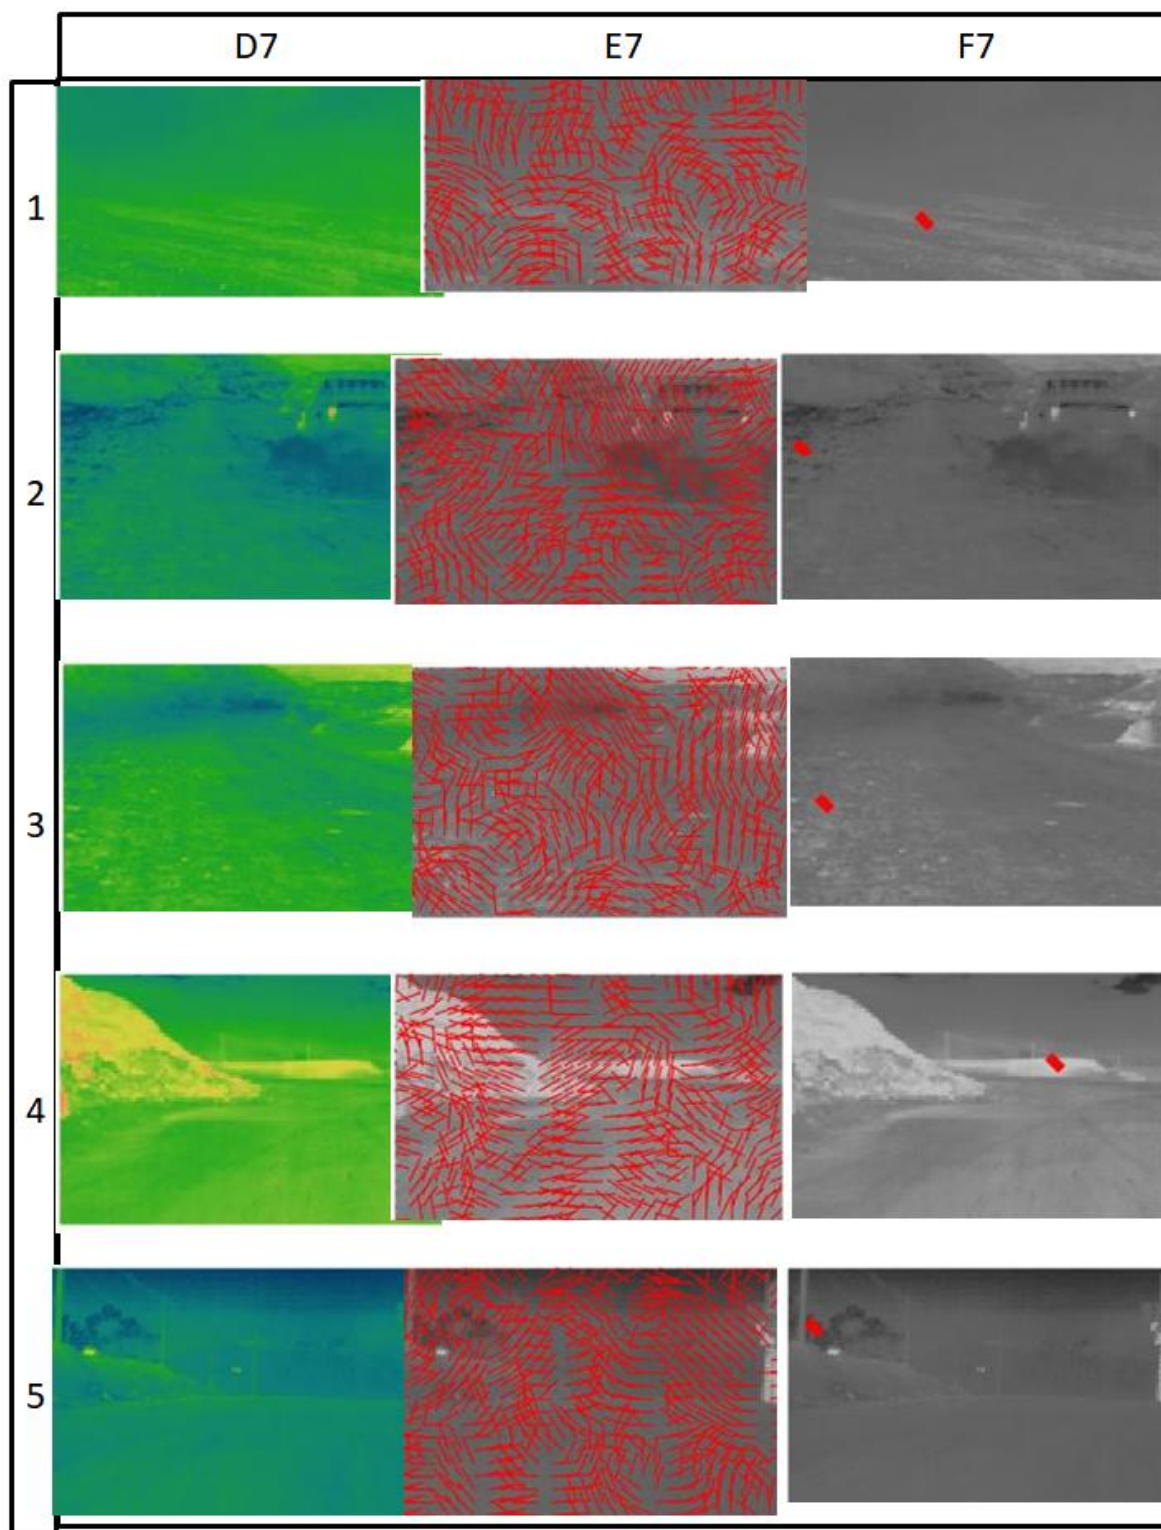


**Figura 70** - Resultado localização ponto de fuga algoritmo FAVP (D5;E5;F5)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)



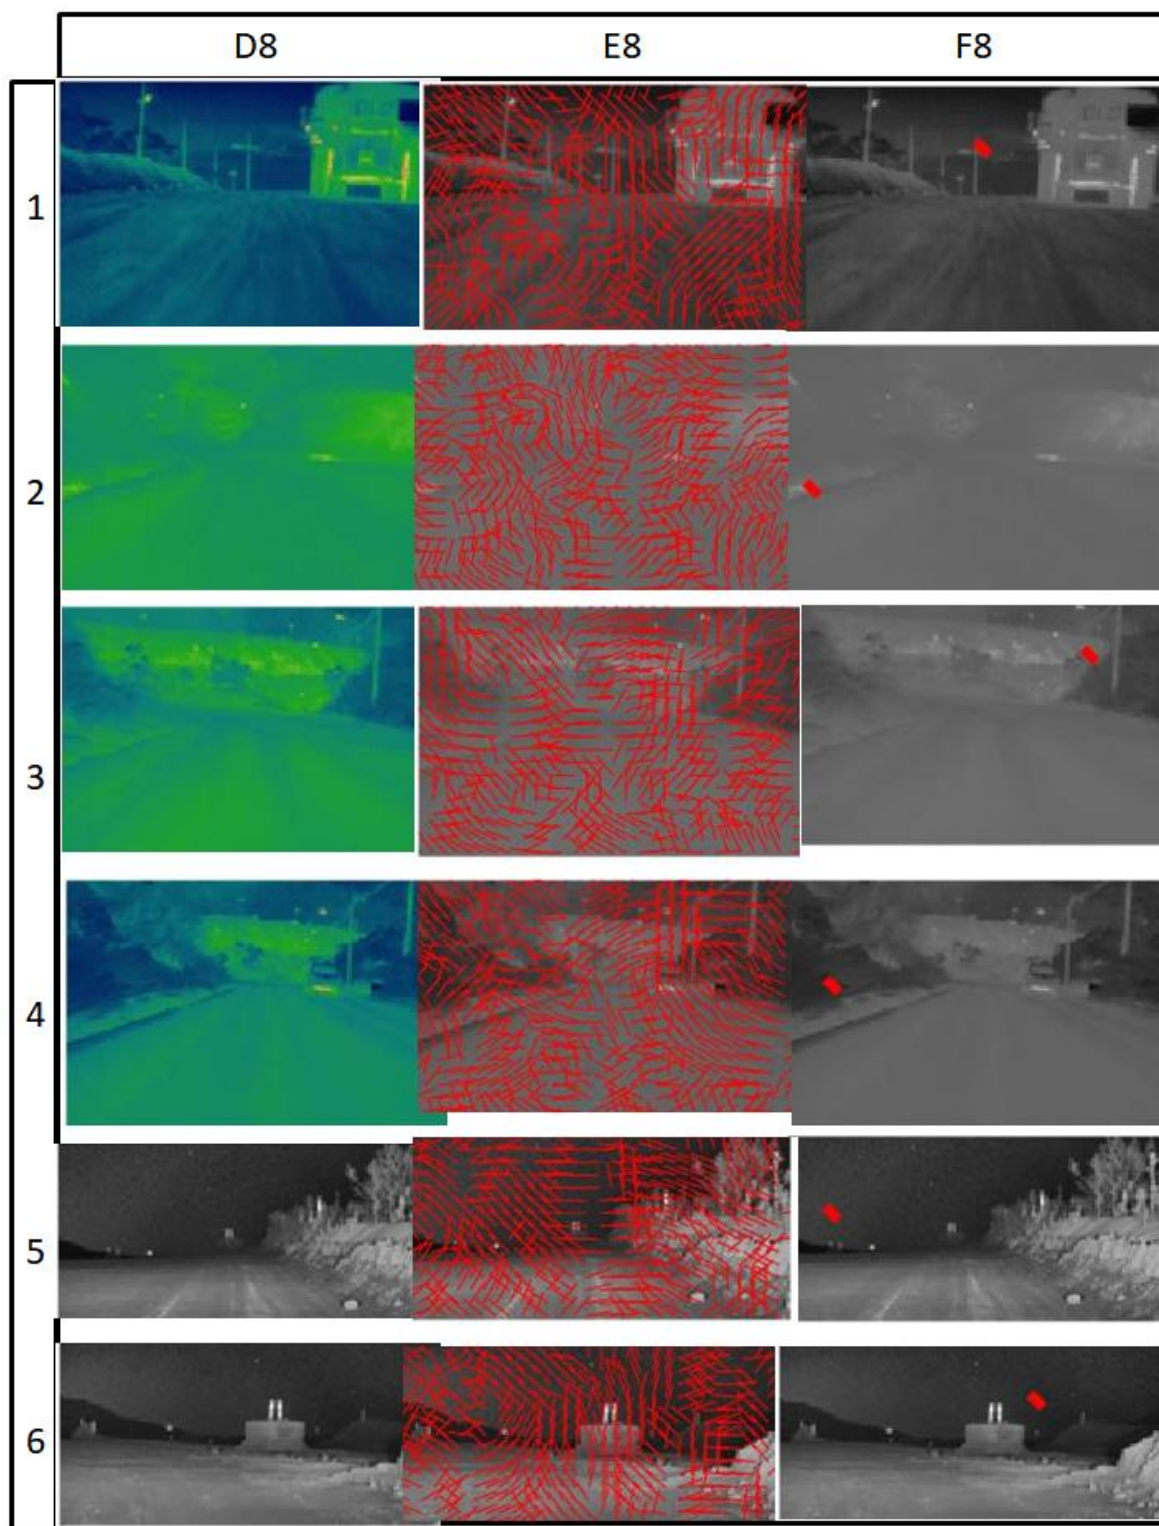
**Figura 71** - Resultado localização ponto de fuga algoritmo FAVP (D6;E6;F6)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)





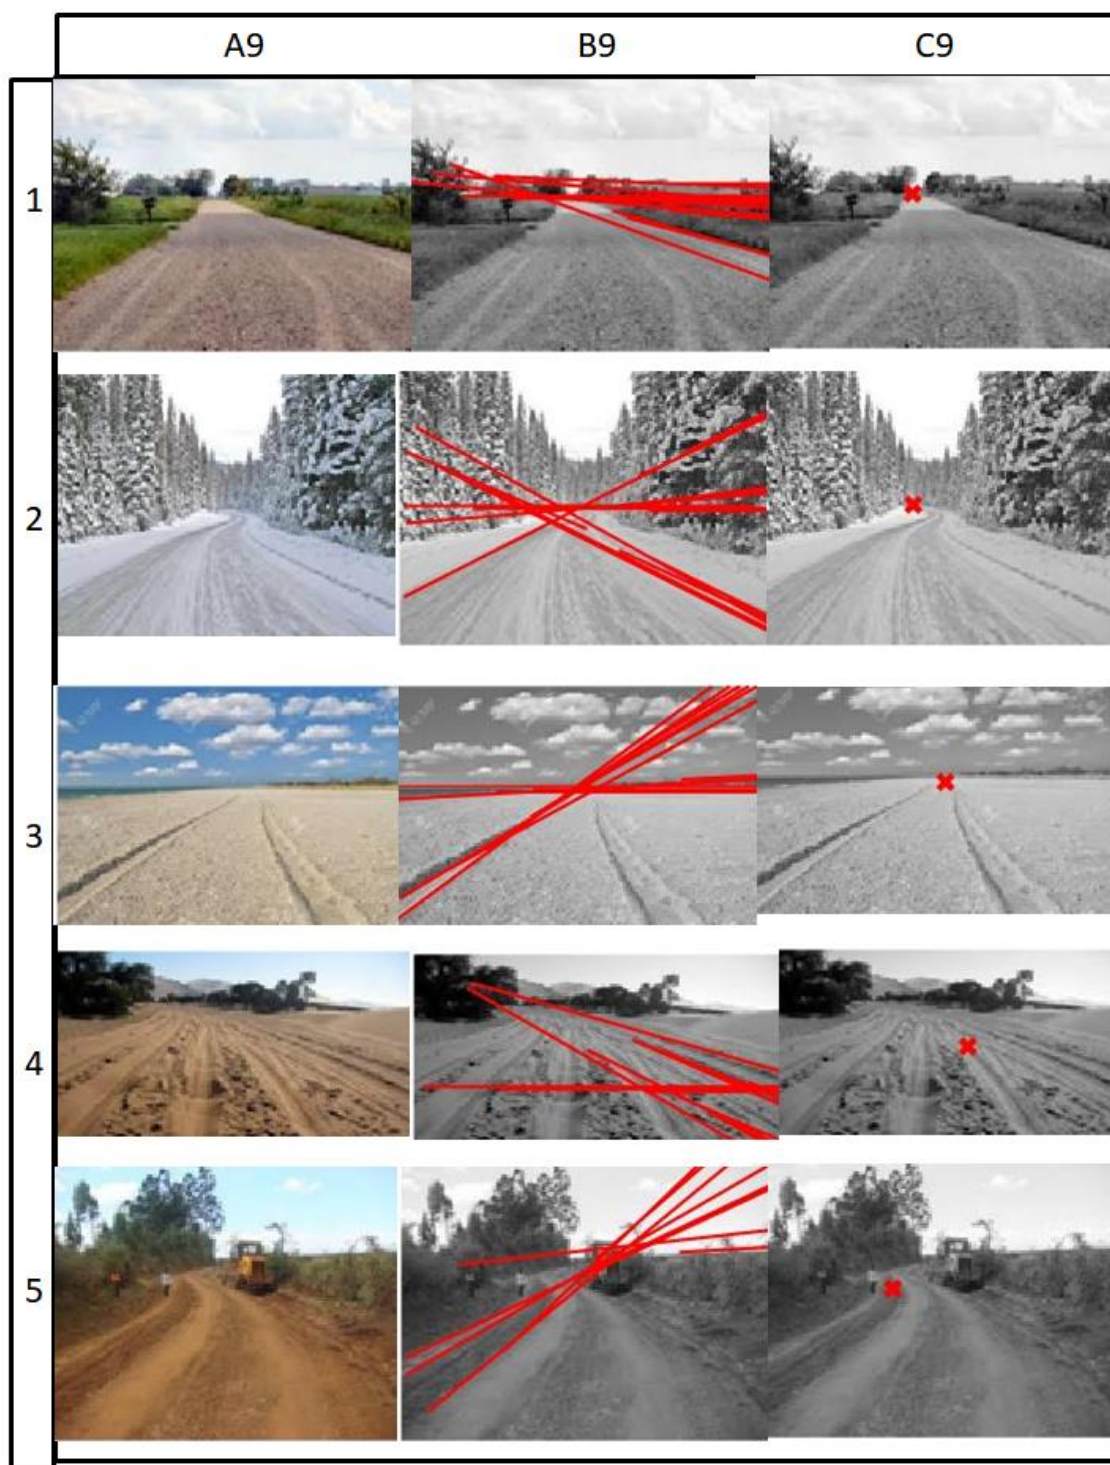
**Figura 72** - Resultado localização ponto de fuga algoritmo FAVP (D7;E7;F7)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)





**Figura 73** - Resultado localização ponto de fuga algoritmo FAVP (D8;E8;F8)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)

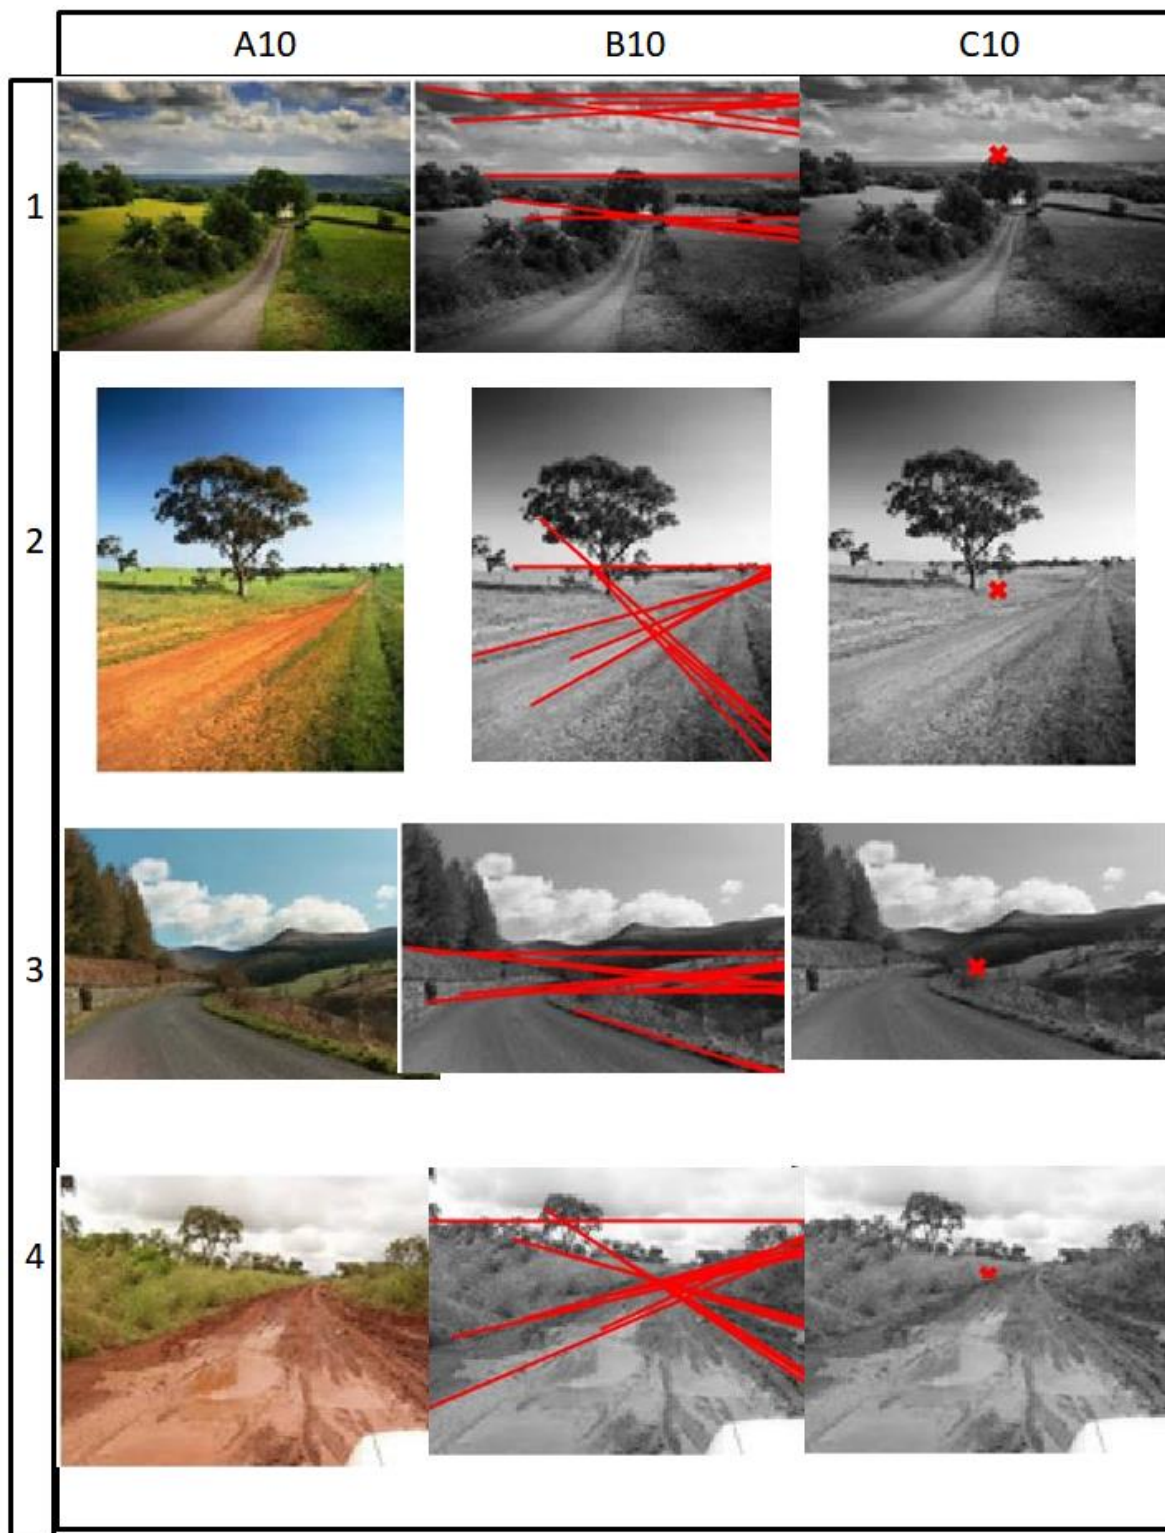
## ANEXO D – Resultados algoritmo EBMO



**Figura 74** - Resultados EBMO (A9;B9;C9)

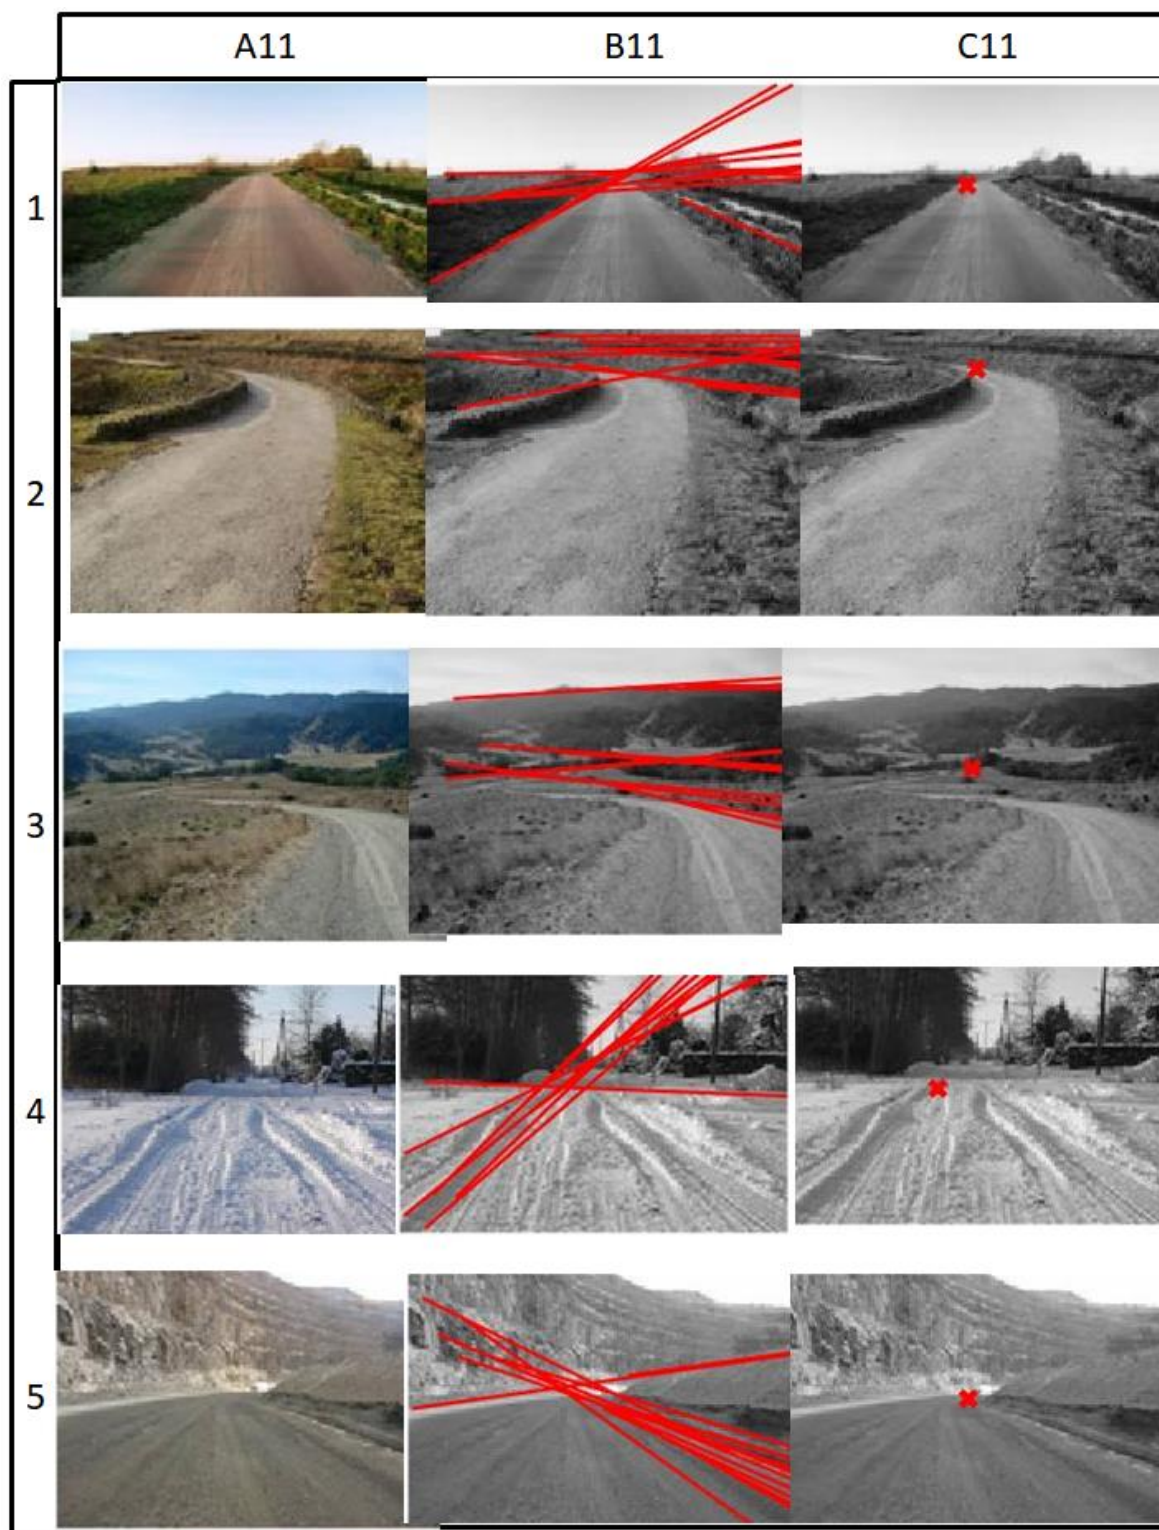
Fonte: imagens retiradas da internet por pesquisa de "unstrucutre road dataset" no Google Imagens





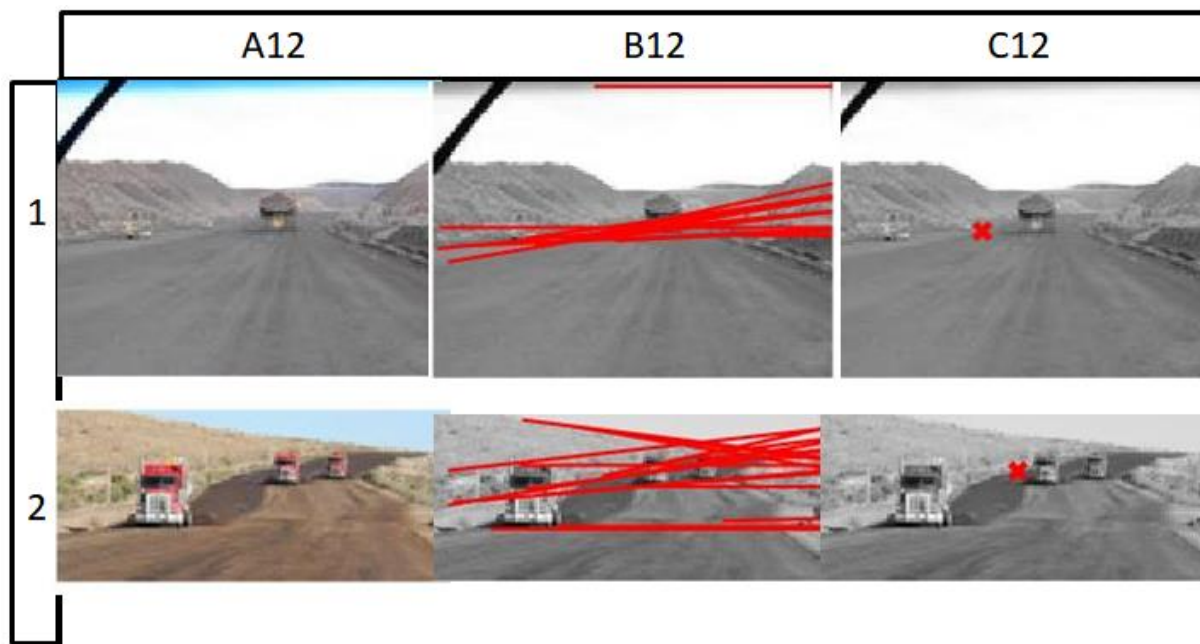
**Figura 75** - Resultados EBMO (A10;B10;C10)

Fonte: imagens retiradas da internet por pesquisa de "unstrucutre road dataset" no Google Imagens



**Figura 76** - Resultados EBMO (A11;B11;C11)


Fonte: imagens retiradas da internet por pesquisa de "unstrucutre road dataset" no Google Imagens




**Figura 77** - Resultados EBMO (A12;B12;C12)

Fonte: imagens retiradas da internet por pesquisa de "unstrucutre road dataset" no Google Imagens






**Figura 78** - Resultados EBMO (D9;E9;F9)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)

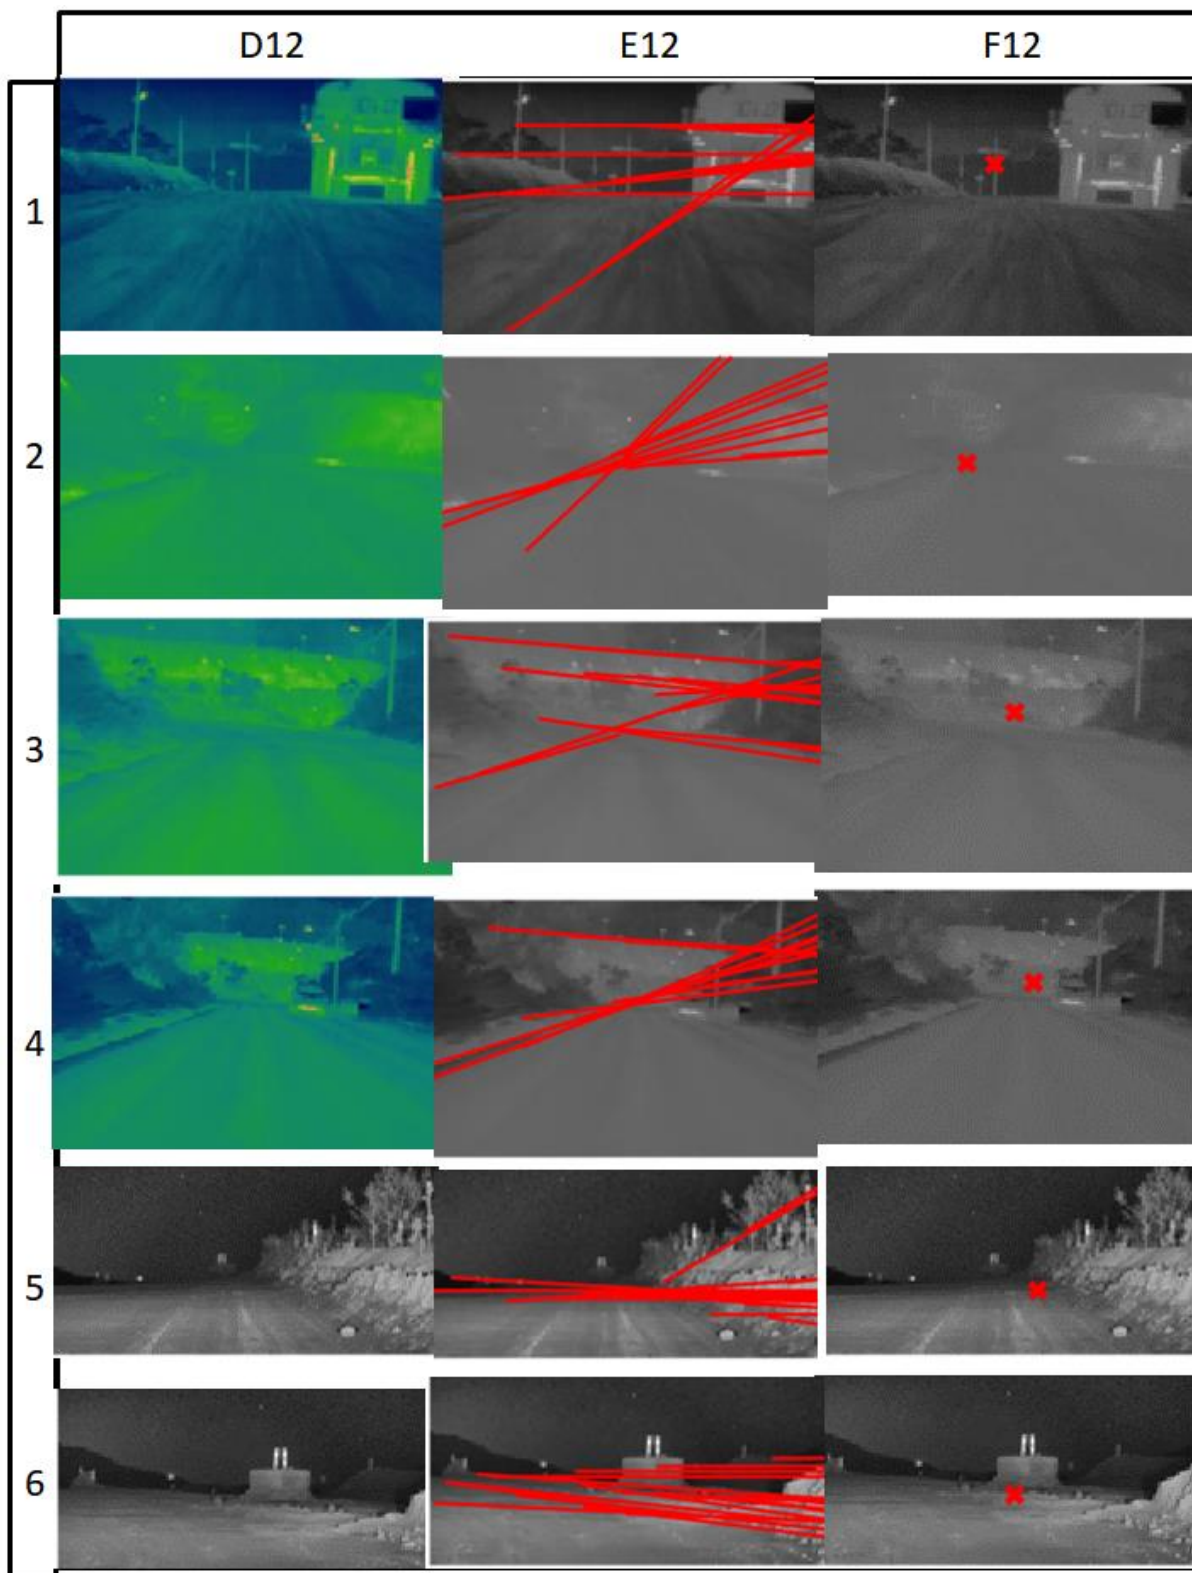


**Figura 79** - Resultados EBMO (D10;E10;F10)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)



**Figura 80** - Resultados EBMO (D11;E11;F11)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)






**Figura 81** - Resultados EBMO (D12;E12;F12)  
 Fonte: FREITAS; ZANETTI; MIOLA (2015)

## ANEXO E – Resultados detecção da área da estrada usando quatro técnicas fundamentais



**Figura 82** - Resultado de identificação de área de estrada (base de imagens internet e autores)  
 Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road base de imagens” no Google  
 Imagens e obtidas após a execução do algoritmo






**Figura 83** - Resultado de identificação de área de estrada (base de imagens internet e autores)  
 Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road base de imagens” no Google  
 Imagens e obtidas após a execução do algoritmo




**Figura 84** - Resultado de identificação de área de estrada (base de imagens internet e autores)  
 Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road base de imagens” no Google  
 Imagens e obtidas após a execução do algoritmo





**Figura 85** - Resultado de identificação de área de estrada (base de imagens internet e autores)  
Fonte: imagens retiradas da internet por pesquisa de “unstrucutre road base de imagens” no Google  
Imagens e obtidas após a execução do algoritmo



**Figura 86** - Resultado de identificação de área de estrada (base de imagens minas Vale)  
Fonte: FREITAS; ZANETTI; MIOLA (2015) imagens obtidas após a execução do algoritmo