



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de São José do Rio Preto

Victor de Assis Rodrigues

Análise De Regiões Em Cenários Agrícolas Utilizando Um
Sistema De Visão Catadióptrico

São José do Rio Preto - SP

2014

Victor de Assis Rodrigues

Análise De Regiões Em Cenários Agrícolas Utilizando Um
Sistema De Visão Catadióptrico

Dissertação apresentada como parte dos requisitos para obtenção do título de Mestre em Ciência da Computação, junto ao Programa de Pós-Graduação em Ciência da Computação, Área de Concentração - Sistemas de Computação, do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, câmpus de São José do Rio Preto.

Orientador: Prof. Associado Mário Luiz Tronco

São José do Rio Preto - SP

2014

Rodrigues, Victor de Assis.

Análise de regiões em cenários agrícolas utilizando um sistema de visão catadióptrico / Victor de Assis Rodrigues. -- São José do Rio Preto, 2014

148 f. : il., tabs.

Orientador: Mário Luiz Tronco

Trabalho de conclusão de curso (Bacharelado – Ciência da Computação) – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Instituto de Biociências, Letras e Ciências Exatas

1. Computação. 2. Processamento de imagens - Técnicas digitais. 3. Sistemas catadióptricos. 4. Robôs móveis. 5. Agricultura de precisão. I. Tronco, Mário Luiz. II. Universidade Estadual Paulista "Júlio de Mesquita Filho". Instituto de Biociências, Letras e Ciências Exatas. III. Título.

CDU – 518.72:76

Ficha catalográfica elaborada pela Biblioteca do IBILCE
UNESP - Câmpus de São José do Rio Preto

Victor de Assis Rodrigues

Análise De Regiões Em Cenários Agrícolas Utilizando Um Sistema De Visão Catadióptrico

Dissertação apresentada como parte dos requisitos para obtenção do título de Mestre em Ciência da Computação, junto ao Programa de Pós-Graduação em Ciência da Computação, Área de Concentração - Sistemas de Computação, do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, câmpus de São José do Rio Preto.

Comissão Examinadora

Prof. Ass. Mário Luiz Tronco (orientador)
UNESP – São José do Rio Preto

Prof. Dr. João Eduardo Machado Perea Martins
UNESP – Bauru

Prof. Dr. Edilson Reis Rodrigues Kato
UFSCAR – São Carlos

São José do Rio Preto - SP

2014

DEDICATÓRIA

*À todas as pessoas que me apoiaram nesses últimos anos,
principalmente a minha namorada e a minha família.*

AGRADECIMENTOS

Primeiramente agradeço a Deus, por possibilitar a vivência de várias oportunidades e ser um ícone de motivação nessa caminhada tão difícil. Muito obrigado Pai!

A meus pais, Oswaldo e Priscila, pela educação e base que vocês me deram. Sou muito grato por ser filho de vocês. Obrigado pelo amor e confiança que vocês depositam em mim.

A minha namorada, Renata, por cada momento de carinho, afeto e sorriso. Obrigado por ser meu berço de inspiração e motivação. Obrigado por todo companheirismo e paciência em todos esses anos, que apesar de não serem poucos, parece que passou tudo muito rápido.

Aos meus irmãos, Gustavo e Tales, que conseguem extrair dos meus dias difíceis momentos felizes. Tenho certeza que serão grandes pessoas um dia.

Ao Prof. Associado Mário Luiz Tronco, pelos ensinamentos, dedicação e amizade. Cada orientação que foi dada é um aprendizado a ser preservado daqui para frente. Obrigado pela oportunidade e por toda a paciência.

Aos amigos Luciano Cássio Lúlio e Vinicius Bergoli Trentini, agradeço pela amizade e vivência nesses anos de pesquisa. Foram muitos dias difíceis, mas existem muitas lições que podemos tirar dessas dificuldades. Eu lhes desejo todo o sucesso e felicidade nesses anos que estão por vir.

Ao Núcleo de Ensino e Pesquisa em Automação e Simulação da Escola de Engenharia de São Carlos (NEPAS - EESC/USP), pela oportunidade de realizar o mestrado em um ambiente agradável e por toda a infraestrutura disponibilizada.

A CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), pelo auxílio e oportunidade de realizar uma pesquisa de alto nível com bolsa de estudos.

Aos professores da Faculdade de Ciências da UNESP de Bauru. Gostaria de agradecer especialmente ao Prof. Adj. Aparecido Nilceu Marana, por toda a paciência com seus alunos e também a Profa. Adj. Roberta Spolon, pela amizade e também por aceitar supervisionar o meu estágio de docência.

A todos os amigos da Faculdade de Ciências da UNESP de Bauru, pela amizade e momentos de desconcentração. Aproveito para agradecer também aos funcionários do LEPEC (Laboratório de Ensino, Pesquisa e Extensão em Computação – FC/UNESP) pela paciência e oportunidade de estudo. Muito obrigado a todos!

*“Que os vossos esforços desafiem as impossibilidades,
lembrai-vos de que as grandes coisas do homem foram
conquistadas do que parecia impossível.”*

Charles Chaplin

RESUMO

RODRIGUES, V. A. **Análise de Regiões em Cenários Agrícolas Utilizando um Sistema de Visão Catadióptrico**. Dissertação (Mestrado), Instituto de Biociências, Letras e Ciências Exatas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, São José do Rio Preto, 2014.

Sistemas de Visão são amplamente empregados em aplicações relacionadas à Agricultura de Precisão. A capacidade de extrair grandes conjuntos de dados do ambiente e seus baixos custos de aquisição torna-os populares entre os diversos tipos de sensores existentes. Em algumas atividades, torna-se necessário aumentar o campo de visão da aplicação para aumentar o conhecimento sobre o ambiente. Sistemas Omnidirecionais Catadióptricos fornecem técnicas capazes de capturar imagens completas do ambiente utilizando a combinação de lentes e espelhos. Nesse trabalho, foi proposta a aplicação de um sistema catadióptrico, utilizando espelho hiperbólico, para realização do levantamento de informações de cenários naturais agrícolas. A imagem omnidirecional é tratada com técnicas de processamento de imagens e retificada, gerando uma nova imagem panorâmica. Então, seus quadrantes são extraídos, originando quatro novas imagens que representam lados de visão do veículo. Uma etapa de segmentação por cor foi proposta utilizando como base o algoritmo Otsu Threshold. Filtros foram aplicados para otimização dos resultados obtidos. No final do processo, foi possível visualizar as regiões de interesse de cada quadrante.

Palavras chave: Visão Omnidirecional, Segmentação de Imagens, Ambientes Agrícolas, Robôs Móveis Agrícolas.

ABSTRACT

RODRIGUES, V. A. **Analysis of Regions in Agricultural Scenes Using a Catadioptric Vision System.** Dissertation (Master of Science), Instituto de Biociências, Letras e Ciências Exatas, São Paulo State University, Bauru, 2014.

Vision System is widely used in applications related to Precision Agriculture. The ability to extract large sets of data from the environment and its low acquisition costs makes them popular among different types of existing sensors. In some activities, becomes necessary to increase the field of view of the application to increase the knowledge about the environment. Omnidirectional Catadioptric System provide techniques to capture complete images of the environment using a combination of lenses and mirrors. This work aimed the application of a catadioptric system using hyperbolic mirror, to perform the survey information of agricultural natural scenery. The omnidirectional image is treated with techniques of image processing and rectified, creating a new panoramic image. Then, its quadrants are extracted, yielding four new images that represent the side view of the vehicle. A Step by color segmentation was proposed using as a basis the Otsu Threshold algorithm. Filters are applied to optimize the results. At the end of the process, it was possible to view the regions of interest in each quadrant.

Keywords: *Omnidirectional Vision, Image Segmentation, Agricultural Environments, Agricultural Mobile Robots.*

LISTA DE FIGURAS

Figura 2.1 - Ilustração de um sistema omnidirecional catadióptrico. Fonte: Souza (2009).....	31
Figura 2.2 – Ângulo de visão de cada tipo de espelho em sistemas catadióptricos. Fonte: Adaptado de Ishiguro (1998).....	33
Figura 2.3 - Ilustração do ângulo de incidência gerado por um espelho esférico. Fonte: Adaptado de Souza e Motta (2008).....	35
Figura 2.4 - Centro Único de Projeção. Em (a) espelho parabólico e em (b) espelho hiperbólico. Fonte: Souza e Motta (2008).....	36
Figura 2.5 – Processo para criação da imagem panorâmica utilizando mapeamento de coordenadas polares. Fonte: Adaptado de Grassi Jr. e Okamoto Jr. (2002).....	38
Figura 2.6 – Projeção do plano cilíndrico para retificação utilizando centro único de projeção. Fonte: Adaptado de Grassi Jr. e Okamoto Jr. (2002).....	40
Figura 2.7 – Plano de projeção perspectiva. Fonte: Grassi Jr. e Okamoto Jr., 2002.....	42
Figura 2.8 – Composição da hipérbole. Fonte: Souza e Motta (2008).....	44
Figura 2.9 – Relação matemática entre câmera e espelho hiperbólico.....	45
Figura 3.1 – Rastreamento das linhas dos corredores utilizando <i>Bouding Boxes</i> (a) e marcadores artificiais (b). Fonte: Adaptado de Winters et al., 2000.....	49
Figura 3.2 – Resultados obtidos com lentes olho-de-peixe (a) e catadióptrico (b). As linhas vermelhas são os resultados com a transformada de Hough, enquanto as linhas azuis com o de detecção de borda. Fonte: Ericson e Åstrand, 2010.....	52
Figura 3.3 – Ilustração do sistema de visão omnidirecional construído por Li. Fonte: Adaptado de LI et al., 2011.....	53
Figura 3.4 – Alocação do sistema omnidirecional no veículo (a) e cálculos de distância obtidos pelo sistema durante a navegação do veículo (b). Fonte: Adaptado de Yang e Noguchi, 2012.....	56
Figura 3.5 – Imagem original (a), transformação do espaço de cores (b), Otsu Thresholding (c), aprimoramento dos resultados (d) e calculo do caminho navegável (e).....	58
Figura 3.6 – Imagem original (a), binarização (b), cálculo das extremidades das linhas de plantio (c) Fonte: Xue, Zhang e Grift, 2012.....	60
Figura 3.7 – Imagem original em escala de cinza (a), binarização (b), execução das operações morfológicas (c) linhas central da área resultante (d).....	61

Figura 3.8 – Pontos de rastreamento encontrados na área de interesse (a), arestas verticais simbolizando elementos na imagem (b)	64
Figura 4.1 – Cenários encontrados no ambiente natural. Em (a) ruas que não possuem vegetação, em (b) ruas com vegetação baixa ou rala, em (c) ruas com vegetação alta e em (d) ruas com quantidade aleatória de vegetação.....	71
Figura 4.2 – Representação geral do sistema de visão omnidirecional proposto	72
Figura 4.3 – Sistema de Visão Omnidirecional alocado no quadriciclo	74
Figura 4.4 – Sistema de Visão Omnidirecional alocado na caminhonete	75
Figura 4.5 – Processo de calibração. Em (a) a imagem original obtida, em (b) as coordenadas inseridas na imagem para comparação posterior, e em (c) a aplicação do algoritmo de retificação na imagem.....	76
Figura 4.6 – Exemplos da máscara para extração da área do veículo. Em (a) e (d) é possível observar dois momentos de diferentes coletas, em (b) e (e) as máscaras utilizadas para eliminar a região do veículo, em (c) e (f) a aplicação das máscaras	78
Figura 4.7 – Exemplos de retificação da imagem omnidirecional	79
Figura 4.8 – Etapa de Extração do céu da imagem, sendo em (a) uma imagem retificada, em (b) o resultado do primeiro <i>threshold</i> para extração da área azul, em (c) o resultado do segundo <i>threshold</i> para extração da área branca, e em (d) o resultado final da etapa.....	81
Figura 4.9 – Extração de Quadrantes da Imagem.....	82
Figura 4.10 – Aplicação do Otsu <i>Threshold</i> no canal <i>Hue</i> . Sendo que em (a) é ilustrado o quadrante analisado e em (b) a aplicação da técnica.....	86
Figura 4.11 – Aplicação do Otsu <i>Threshold</i> para o canal de iluminação. Sendo que em (a) é ilustrado o quadrante analisado e em (b) a aplicação da técnica.....	87
Figura 4.12 – Exemplo de máscara de corte.....	88
Figura 4.13 – Aplicação da máscara de corte no resultado da segmentação. Sendo que em (a) é ilustrado o quadrante analisado e em (b) o resultado do algoritmo Otsu e em (c) a aplicação da máscara	88
Figura 4.14 – Eficiência do algoritmo para otimização dos resultados. Sendo que em (a) é ilustrado um resultado da etapa de segmentação, em (b) o resultado da aplicação da máscara e em (c) o resultado do algoritmo de limpeza de área.....	90
Figura 5.1 – Imagem global da situação analisada.....	93
Figura 5.2 – Imagem omnidirecional obtida pelo sistema de visão	93
Figura 5.3 – Resultado da Etapa de Retificação da Imagem	94
Figura 5.4 – Resultado da Etapa de Extração do Céu das Imagens	94

Figura 5.5 – Resultados da Etapa de Extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	94
Figura 5.6 – Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Para os quadrantes (b) e (c) foi aplicada a técnica Otsu Adaptada para o canal de iluminação, enquanto que para os quadrantes (a) e (d) foi aplicada a técnica Otsu Adaptada para o canal de cor.	95
Figura 5.7 – Resultados da Etapa de Inserção de Máscara para Detecção de Caminhos, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	96
Figura 5.8 – Imagem global da situação analisada.....	98
Figura 5.9 – Imagem omnidirecional obtida pelo sistema de visão	98
Figura 5.10 –Resultado da Etapa de Extração do Céu das Imagens	99
Figura 5.11 – Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	99
Figura 5.12 – Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica Otsu Adaptada para o canal de iluminação.	100
Figura 5.13 – Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	101
Figura 5.14 – Imagem global da situação analisada.....	101
Figura 5.15 – Imagem omnidirecional obtida pelo sistema de visão	102
Figura 5.16 – Resultado da Etapa de Retificação da Imagem.....	102
Figura 5.17 – Resultados da Etapa de Extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	103
Figura 5.18 – Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Para os quadrantes (b) e (d) foram aplicadas as técnicas do Otsu Threshold para o canal de iluminação, e para os quadrantes (a) e (c) foram aplicadas as técnicas do Otsu Threshold para o canal <i>Hue</i>	103
Figura 5.19 – Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	104

Figura 5.20 – Imagem global da situação analisada.....	105
Figura 5.21 – Imagem omnidirecional obtida pelo sistema de visão	105
Figura 5.22 – Resultado da Etapa de Retificação da Imagem.....	106
Figura 5.23 – Resultado da Etapa de Extração do Céu das Imagens, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.....	106
Figura 5.24 – Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica Otsu Thresholding para o canal de iluminação ...	107
Figura 5.25 – Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	107
Figura 5.26 – Imagem global da situação analisada.....	108
Figura 5.27 – Imagem omnidirecional obtida pelo sistema de visão	109
Figura 5.28 – Resultado da Etapa de Retificação da Imagem.....	109
Figura 5.29 – Resultados da Etapa de Extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	110
Figura 5.30 – Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica para o canal de iluminação.	110
Figura 5.31 – Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	111
Figura A.1 - Imagem global da situação analisada.....	126
Figura A.2 - Imagem omnidirecional obtida pelo sistema de visão	126
Figura A.3 - Resultado da Etapa de Extração do Céu das Imagens	127
Figura A.4 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	127
Figura A.5 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. No quadrante (a), (b) e (d) foi aplicada a técnica para o canal de iluminação, e no quadrante (c) foi aplicada a técnica para o canal <i>Hue</i>	127
Figura A.6 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	128

Figura A.7 - Imagem global da situação analisada.....	128
Figura A.8 - Imagem omnidirecional obtida pelo sistema de visão	129
Figura A.9 - Resultado da Etapa de Extração do Céu das Imagens	129
Figura A.10 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	129
Figura A.11 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. No quadrante (a) foi aplicada a técnica no canal <i>Hue</i> da imagem, e em (b), (c) e (d) foi aplicada a técnica no canal de Iluminação da imagem.	130
Figura A.12 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	130
Figura A.13 - Imagem global da situação analisada.....	131
Figura A.14 - Imagem omnidirecional obtida pelo sistema de visão	131
Figura A.15 - Resultado da Etapa de Extração do Céu das Imagens	131
Figura A.16 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	132
Figura A.17 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica de Iluminação da imagem.	132
Figura A.18 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	132
Figura A.19 - Imagem global da situação analisada.....	133
Figura A.20 - Imagem omnidirecional obtida pelo sistema de visão	133
Figura A.21 - Resultado da Etapa de Extração do Céu das Imagens	133
Figura A.22 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	134
Figura A.23 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica de Iluminação da imagem.	134
Figura A.24 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	134

Figura A.25 - Imagem global da situação analisada.....	135
Figura A.26 - Imagem omnidirecional obtida pelo sistema de visão	135
Figura A.27 - Resultado da Etapa de Extração do Céu das Imagens	136
Figura A.28 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	136
Figura A.29 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Nos quadrantes (a), (b) e (c) a técnica foi aplicada no canal <i>Hue</i> , e em (d) a técnica foi aplicada no canal de iluminação.	136
Figura A.30 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	137
Figura A.31 - Imagem global da situação analisada.....	137
Figura A.32 - Imagem omnidirecional obtida pelo sistema de visão	138
Figura A.33 - Resultado da Etapa de Extração do Céu das Imagens	138
Figura A.34 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	138
Figura A.35 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Nos quadrantes (a), (b) e (c) foi aplicada a técnica no canal <i>Hue</i> , e em (d) foi aplicada a técnica no canal de iluminação.	139
Figura A.36 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	139
Figura A.37 - Imagem global da situação analisada.....	140
Figura A.38 - Imagem omnidirecional obtida pelo sistema de visão	140
Figura A.39 - Resultado da Etapa de Extração do Céu das Imagens	140
Figura A.40 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	141
Figura A.41 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes a técnica foi aplicada no canal de iluminação.....	141

Figura A.42 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	142
Figura A.43 - Imagem global da situação analisada.....	142
Figura A.44 - Imagem omnidirecional obtida pelo sistema de visão	142
Figura A.45 - Resultado da Etapa de Extração do Céu das Imagens	142
Figura A.46 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	143
Figura A.47 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes a técnica foi aplicada no canal de iluminação.....	143
Figura A.48 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	143
Figura A.49 - Imagem global da situação analisada.....	144
Figura A.50 - Imagem omnidirecional obtida pelo sistema de visão	144
Figura A.51 - Resultado da Etapa de Extração do Céu das Imagens	145
Figura A.52 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	145
Figura A.53 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica de Iluminação da imagem.	145
Figura A.54 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	146
Figura A.55 - Imagem global da situação analisada.....	146
Figura A.56 - Imagem omnidirecional obtida pelo sistema de visão	147
Figura A.57 - Resultado da Etapa de Extração do Céu das Imagens	147
Figura A.58 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.	147
Figura A.59 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica de Iluminação da imagem.	148

Figura A.60 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo. 148

LISTA DE SIGLAS

AP	Agricultura de Precisão
CCD	Dispositivo de Carga Acoplada
CUDA	Arquitetura de Dispositivo de Computação Unificada
CUP	Centro Único de Projeção
EESC	Escola de Engenharia de São Carlos
FINEP	Financiadora de Estudos e Projetos
GPS	Sistema de Posicionamento Global
GPU	Unidade de Processamento Gráfico
ODSV	Sistema de Visão Omnidirecional
RANSAC	<i>Random Sample Consensus</i>
RTK	<i>Real Time Kinematic</i>
USP	Universidade de São Paulo

SUMÁRIO

1. INTRODUÇÃO	19
1.1. Considerações Iniciais	19
1.1.1. Formação de Imagens e Espaço de Cores.....	20
1.2. Considerações sobre o Projeto.....	23
1.3. Objetivo do Trabalho.....	24
1.4. Organização da Dissertação.....	26
2. SISTEMAS DE VISÃO OMNIDIRECIONAIS E CATADIÓPTICOS.....	27
2.1. Introdução aos Sistemas Omnidirecionais.....	27
2.2. Tipos de Espelhos em Sistemas Catadióptricos	31
2.3. Centro Único de Projeção.....	35
2.4. Retificação de Imagens Omnidirecionais	37
2.4.1. Mapeamento direto de coordenadas polares	37
2.4.2. Retificação utilizando centro único de projeção.....	39
2.4.3. Geração de Imagens Perspectivas.....	41
2.4.4. Equações do espelho hiperbólico.....	43
2.4.4.1. Equação da hipérbole	43
2.4.4.2. Equação do espelho hiperbólico.....	44
2.5. Considerações finais	46
3. REVISÃO BIBLIOGRÁFICA.....	47
3.1. Introdução	47
3.1.1. Aplicações de Visão Omnidirecional para ambientes fechados	48
3.1.2. Sistemas de Visão Omnidirecional para cenários naturais	51
3.1.3. Sistemas de Visão Monocular.....	57
3.2. Considerações do Capítulo	64
4. METODOLOGIA PROPOSTA	65
4.1. Introdução.....	65
4.2. Considerações sobre o projeto.....	66
4.2.1. Veículos utilizados para os testes	67
4.2.2. Suporte para o Sistema de Visão Omnidirecional	68
4.2.3. Captura de Imagens	69
4.3. Descrição da Aplicação	72
4.3.1. Etapa de Aquisição de Imagens	73

4.3.2.	Calibração da câmera.....	74
4.3.3.	Etapa de Recorte das Imagens	77
4.3.4.	Etapa de Retificação das Imagens	78
4.3.5.	Etapa de Extração do Céu das Imagens	79
4.3.6.	Etapa de Extração de Quadrantes das Imagens.....	80
4.3.7.	Etapa de Verificação de Regiões Verdes nas Imagens	82
4.3.8.	Método Otsu <i>Thresholding</i>	83
4.3.8.1.	Otsu Threshold Adaptado no canal Hue	85
4.3.8.2.	Otsu Threshold Adaptado no canal de iluminação.....	86
4.3.9.	Etapa de Otimização de Resultados.....	87
4.4.	Considerações do Capítulo	91
5.	RESULTADOS	92
5.1.	Resultados do Processamento de Imagens	92
5.1.1.	Situação 1.....	92
5.1.2.	Situação 2.....	97
5.1.3.	Situação 3.....	101
5.1.4.	Situação 4.....	105
5.1.5.	Situação 5.....	108
5.2.	Valor para Participação de Verde nas Imagens	111
5.3.	Considerações do Capítulo	113
6.	CONCLUSÕES	114
6.1.	Considerações Finais e Discussões.....	114
6.2.	Propostas de Trabalhos Futuros.....	115
	REFERÊNCIAS	117
	APÊNDICE A – ANÁLISE DE SITUAÇÕES ENCONTRADAS	126

1.INTRODUÇÃO

Nesse capítulo é apresentada uma introdução sobre os problemas encontrados na Agricultura de Precisão como também a importância de técnicas que proporcionam a ampliação do campo de visão. São abordadas as principais motivações desse trabalho e um resumo sobre os assuntos tratados em cada parte desse documento.

1.1.Considerações Iniciais

A quantidade de inovações tecnológicas ligadas à Agricultura de Precisão (AP) aumentou consideravelmente nas últimas décadas. A informática contribuiu tecnicamente aumentando a produtividade dos processos e diminuindo o impacto ambiental. Além disso, a cada ano vem diminuindo o interesse das pessoas em trabalhar em ambientes agrícolas, assim a população rural está envelhecendo sem que exista uma perspectiva de renovação de mão-de-obra. Outro fator importante são os riscos físicos que muitas atividades dessa área exercem. A segurança e a falta de pessoal especializado aquecem o setor para a criação de novas soluções inteligentes na área (LULIO, 2011; PEREIRA, 2008).

Os avanços da Robótica Móvel dos últimos anos possibilitam realizações de tarefas cada vez mais complexas e que necessitam de uma alta quantidade de informações do ambiente. As aplicações abrangem desde classificação e seleção de sementes, até mesmo a seleção de frutos, controle de veículos autônomos, identificação de plantas invasoras, contagem e colheita de frutos e diversos outros problemas.

Nesse contexto, os sensores de visão são equipamentos que permitem explorar o ambiente sem a necessidade de contato físico, além de possuir custos de aquisição bastante acessíveis. Em muitos problemas, torna-se necessário a ampliação do campo de visão, uma vez que os sistemas convencionais de imagens são limitados e podem não ser adequados em tarefas como vigilância de ambientes, teleconferência, rastreamento, navegação e mapeamento de ambientes (BONARINI; ALIVERTI; LUCIONI, 2000; BAKER e NAYAR, 1999).

Os Sistemas de Visão Omnidirecional podem ser uma alternativa para aumentar a capacidade de captura de informações, uma vez que as técnicas utilizadas possibilitam a expansão do campo de visão e assim capturar uma imagem em 360° do ambiente (NAYAR; BAKER, 1997). Esse tipo de sistema pode ser implementado por meio do sistema tradicional de imagens, rotação do sistema de imagens, utilização de lentes especiais olho de peixe e através de um conjunto catadióptrico, que consiste na utilização de lentes e espelhos.

Os Sistemas Omnidirecionais são comumente utilizados em ambientes controlados, com obstáculos estáticos e conhecidos, o que quando submetidos em aplicações de exploração em ambientes rurais fomentam várias questões arbitrárias que podem prejudicar o processamento das imagens adquiridas.

1.1.1. Formação de Imagens e Espaço de Cores

Uma imagem pode ser definida como uma função bidimensional $f(x,y)$, onde x e y são coordenadas espaciais do plano. Assim, o resultado de $f(x,y)$ é a intensidade de luz no ponto. A digitalização da imagem pode ser feita através do processo de amostragem espacial, ou também pela quantização da amplitude (FORSYTH; PONCE, 2002; GONZALES; WOODS, 2007; FAIRHURST, 1988; GONZALES; WINTZ, 1987).

Na amostragem espacial, os pontos que compõem o plano (x, y) são representados na forma de uma estrutura bidimensional uniformemente distribuída, sendo que, quanto mais pontos, maior a quantidade de informação espacial. Esses pontos são denominados *pixels*.

Uma imagem discreta é composta de $M \times N$ *pixels*, onde M representa a largura e N o comprimento da imagem. Quando a imagem é monocromática, cada pixel consegue armazenar 2^l tons de cinza, onde l representa o domínio da escala de tons em cinza. Na Eq. 1.1 é definido o número de bits necessários para armazenar todas as informações da imagem.

$$b = N \cdot M \cdot 2^l \quad (1.1)$$

onde M representa a largura, N o comprimento da imagem e 2^l o domínio de cores em RGB.

As imagens monocromáticas são bem mais rápidas de serem analisadas por dependerem de apenas um comprimento de onda. Contudo, quando o problema envolve imagens coloridas, é necessário analisar a intensidade específica de luz de cada componente. Os seres humanos possuem três receptores de cores, chamados cones, onde os comprimentos de onda são: 650nm para vermelho (R - *red*), 530nm para verde (G - *green*) e 430 nm para azul (B - *blue*) (RUSSEL; NORVIG, 2004). Assim, a intensidade da luz nos comprimentos de ondas podem ser obtidos através de filtros, representados pelas Eq. 1.2, Eq. 1.3 e Eq. 1.4:

$$R = \int_{\lambda} E(\lambda)S_R(\lambda)d\lambda \quad (1.2)$$

$$G = \int_{\lambda} E(\lambda)S_G(\lambda)d\lambda \quad (1.3)$$

$$B = \int_{\lambda} E(\lambda)S_B(\lambda)d\lambda \quad (1.4)$$

Os valores S_R , S_G e S_B representam respectivamente os filtros vermelho, verde e azul, relacionando-se diretamente aos pigmentos presentes nos cones do olho humano. $E(\lambda)$ representa a energia luminosa e λ é o comprimento de onda (LEVINE, 1985).

O RGB é um sistema de cor inspirado no primeiro estágio da percepção visual humana. Existem outros tipos de sistemas que representam estágios posteriores da visão humana. O Padrão HSI é amplamente utilizado em sistemas de visão computacional pois proporciona a separação cromática e acromática da luz, dividindo o espaço em canais separados para o espaço de cores e para a intensidade da luz, diminuindo a influência da intensidade de luz nas cores (CHENG et al., 2001).

O HSI pode ser definido a partir do espaço RGB com as Eq. 1.5, Eq. 1.6 e Eq. 1.7:

$$H = \arctan\left(\frac{\sqrt{3}(G-B)}{(R-G)(R-B)}\right) \quad (1.5)$$

$$I = \frac{(R+G+B)}{3} \quad (1.6)$$

$$S = 1 - \frac{\min(R,G,B)}{I} \quad (1.7)$$

onde R , G e B são os valores respectivos para os canais de cores vermelho, verde e azul e H , S e I são respectivamente os canais matiz (*hue*), saturação e intensidade.

Existem outras variações do HSI, como o HSV (matiz (*hue*), saturação e valor), HSB (matiz (*hue*), saturação e brilho) e o HSL (matiz (*hue*), saturação e luminosidade) (CHENG et al., 2001; LULIO, 2011). Todas essas variações possuem a mesma vantagem de permitir a extração da luminosidade no modelo da imagem e reduzir a dependência dos efeitos de iluminação nas cores dos *pixels*.

A separação cromática da luz no padrão HSI permite facilitar a separação de cores em muitas imagens (LULIO, 2011; SEMARY; HADHOUD; ABBAS, 2011). O canal Hue (matiz) permite relacionar intervalor de valores com cores conhecidas, como vermelho, verde, amarelo e entre outras. É importante notar também que esse intervalo de valores está entre 0° e 360° , iniciando e terminando assim com a cor vermelha. O canal de Saturação representa a pureza da cor no espectro. Esse canal permite definir um valor espectral que representa a reflexão ou transmissão de energia. Assim, quanto menor o valor, mais as cores formadas terão aspecto de tons apagados (tons pastéis). O canal de Iluminação representa a quantidade de luz ou brilho de uma cor. Ela permite separar tons próximos a cor preta e tons próximos a cor branca.

A transformação do espaço de cores RGB em HSV pode ser obtida seguindo as Eq. 1.8, Eq. 1.9, Eq. 1.10, Eq. 1.11 e Eq. 1.12 (BANCHEV, GEORGIEVA, 2012):

$$R' = \frac{R}{255}, G' = \frac{G}{255}, B' = \frac{B}{255} \quad (1.8)$$

$$C_{min} = \min(R', G', B'), C_{max} = \max(R', G', B'), \Delta = C_{max} - C_{min} \quad (1.9)$$

$$H = \begin{cases} 60^\circ * \left(\frac{G' - B'}{\Delta} \text{ mod } 6 \right), C_{max} = R' \\ 60^\circ * \left(\frac{B' - R'}{\Delta} + 2 \right), C_{max} = G' \\ 60^\circ * \left(\frac{R' - G'}{\Delta} + 4 \right), C_{max} = B' \end{cases} \quad (1.10)$$

$$S = \begin{cases} 0, & \Delta = 0 \\ \frac{\Delta}{C_{max}}, & \Delta <> 0 \end{cases} \quad (1.11)$$

$$V = C_{max} \quad (1.12)$$

onde R, G e B são os valores do pixel atual nos canais correspondentes e H, S e V são os valores calculados durante a transformação do espaço de cor para os canais correspondentes.

Com essas definições, é possível definir as seguintes regras para encontrar as cores na imagem. Nessas regras, o intervalo de valores estabelecido variam entre 0 (zero) e 255 para os canais de saturação e iluminação e 0° à 360° para o canal da matiz (SEMARY; HADHOUD; ABBAS, 2011):

- **Regiões cinzas:** necessário apenas filtrar os valores iguais a 0 (zero) no canal de saturação;
- **Regiões pretas:** no canal de iluminação, filtrar os valores iguais a 0 (zero), não importando os valores dos outros canais;
- **Regiões brancas:** no canal de iluminação, filtrar os valores iguais a 255 e filtrar também no canal de saturação os valores iguais a 0 (zero), não importando os valores do canal matiz;
- **Regiões vermelhas:** filtrar os valores próximos a 0° (zero) ou 360° do canal Hue (matiz).

1.2. Considerações sobre o Projeto

Esse trabalho pertence ao módulo de visão computacional do projeto AgriBOT. O AgriBOT é uma plataforma robótica modular com o objetivo de locomoção em ambientes típicos da área agrícola, possuindo como finalidade a aquisição de dados e pesquisa de novas tecnologias para o sensoriamento remoto para a área agrícola (NEPAS, 2014). O veículo foi construído para dar suporte em atividades de âmbito agrícola, também servindo como protótipo que permite pesquisas em diversas áreas do conhecimento acadêmico (DIAZ et al., 2013).

O projeto teve a atuação de professores e estudantes de graduação e pós-graduação da EESC/USP (Escola de Engenharia de São Carlos da Universidade de São Paulo). Além disso, diversas entidades brasileiras importantes participaram do projeto, como a FINEP (“Financiadora de Estudos e Projetos”), Embrapa (“Empresa Brasileira de Pesquisa Agropecuária”) e Jacto S.A. *company* (DIAZ et al., 2013).

O AgriBOT tem como um de seus objetivos a localização e navegação no ambiente agrícola de forma autônoma. Para propiciar essa habilidade, diversos equipamentos como RTK-GPS, sensores inerciais, sensores de escaneamento e laser de ambientes são utilizados. As culturas estudadas são milho, cana-de-açúcar e laranja (DIAZ et al., 2013; TABILE, 2012; NEPAS, 2014).

Esse trabalho consiste na captura e identificação de regiões em imagens omnidirecionais relacionadas ao percurso efetuado pela plataforma robótica em cenários agrícolas. A identificação de regiões presentes no ambiente permite a precipitação de situações que possam ocorrer durante a navegação. Essas informações resgatadas do ambiente servem de base para outros módulos do veículo, sendo este intimamente ligado ao sistema de controle de navegação da plataforma robótica base (NEPAS, 2014).

Entretanto, durante o desenvolvimento desse trabalho foi possível identificar que a solução poderia se tornar uma aplicação modular, auxiliando outros sistemas da Agricultura de Precisão a alcançarem seus objetivos, tanto de forma total como parcial. Com essas considerações os objetivos do trabalho são apresentados na seção 1.3.

1.3. Objetivo do Trabalho

A proposta deste trabalho é um estudo de aplicação de um sistema omnidirecional catadióptrico capaz de realizar o levantamento de informações de regiões em ambientes agrícolas. O perfil hiperbólico do espelho foi escolhido pela característica de equilíbrio de resolução em toda sua superfície e também por apresentar a propriedade de centro único de projeção, capaz de gerar imagens panorâmicas ou perspectivas sem distorções verticais (SVOBODA; PADJLA; HLAVAC, 1998).

Com uma visão completa do ambiente, o Sistema Omnidirecional Catadióptrico (ODVS, ou *Omni-Directional Vision System*) é capaz de procurar novas rotas agrícolas e auxiliar outros sistemas de navegação em situações que os sensores utilizados são ineficientes. As imagens adquiridas são pré-processadas e depois segmentadas utilizando a dupla execução do algoritmo Otsu Threshold. As regiões das imagens são otimizadas com algoritmos de processamento de imagens. As informações obtidas podem ser utilizadas em diversas aplicações como navegação de robôs móveis, mapeamento de ambientes e também para cálculos de estimativa de produção. Os testes foram realizados em plantações de pomares de laranja.

Analisando esse contexto, pode-se listar os objetivos específicos desse trabalho:

- Montagem de um Sistema Omnidirecional Catadióptrico que enalteça a importância da ampliação do campo de visão para a resolução do problema proposto, além de explorar as vantagens que o espelho de perfil hiperbólico pode proporcionar;
- Aquisição de Imagens Omnidirecionais de boa qualidade e significativo equilíbrio de resolução, buscando um melhor desempenho na etapa de segmentação e que superem problemas encontrados no ambiente;
- Implementação de uma etapa de retificação que usufrua da propriedade de Centro Único de Projeção do espelho hiperbólico, atentando em manter a qualidade da imagem para que ela não sofra distorções causadas pela repetição dos *pixels* durante a criação da imagem panorâmica;
- Aplicação de métodos de segmentação de imagens baseados em cores que permitam obter eficiência para os mais variados cenários encontrados em um ambiente natural agrícola;
- Avaliar se os resultados gerados possam servir como solução total ou parcial para outras aplicações relacionadas à área da Agricultura de Precisão.

1.4. Organização da Dissertação

Abaixo os capítulos contidos nesse trabalho.

No Capítulo 2 é apresentada uma introdução sobre os Sistemas Omnidirecionais. Serão relatadas as técnicas possíveis para criação de imagens completas do ambiente, além das características de cada espelho, propriedade de centro único de projeção, retificação das imagens.

No Capítulo 3 é apresentada uma revisão bibliográfica com trabalhos relacionados ao problema tratado.

No Capítulo 4 é apresentada a metodologia do trabalho, contendo todas as técnicas de processamento de imagens, segmentação, classificação de regiões e construção do Sistema de Visão Omnidirecional Catadióptrico.

No Capítulo 5 é apresentado os resultados e problemas encontrados durante a aquisição e processamento das imagens adquiridas pelo sistema de visão.

No Capítulo 6 é apresentada a conclusão do trabalho.

No Apêndice é possível encontrar informações detalhadas sobre os resultados obtidos para situações presentes no cenário estudado.

2. SISTEMAS DE VISÃO OMNIDIRECIONAIS E CATADIÓPTRICOS

Este capítulo é dedicado a uma introdução sobre Sistemas de Visão Omnidirecionais. São retratados suas principais abordagens, problemas usualmente encontrados, tipos de espelhos e aplicações na robótica móvel, com exemplos em ambientes fechados e também em ambientes abertos, como é o caso da robótica móvel agrícola.

2.1. Introdução aos Sistemas Omnidirecionais

Segundo Nayar e Baker (1997), os sistemas de visão omnidirecionais são capazes de obter uma imagem 360° do ambiente e podem ser uma boa alternativa em sistemas que necessitam capturar um maior volume de informações. Como a visão é o sentido que consegue fornecer uma maior quantidade de dados do ambiente de uma vez, a expansão do campo de visão consegue trazer resultados satisfatórios para diversos tipos de aplicações.

Os sensores de visão são amplamente populares em sistemas que exigem alto grau de autonomia, como na área da Robótica Móvel. Esses equipamentos permitem capturar uma grande quantidade de informações do ambiente sem a necessidade de contato físico, além de possuírem custos bastante acessíveis se comparados a outros tipos de sensores. Além disso, a grande quantidade de informações capturadas fornece uma maior segurança sobre os dados que o sistema já possui. Entretanto, em alguns problemas da área da Visão Computacional é necessário ampliar o campo de visão para aumentar a eficiência dessas aplicações, uma vez que a utilização isolada de uma câmera não é suficiente para obter uma visão completa do ambiente.

As limitações das câmeras tradicionais tornam-se evidentes em algumas tarefas ligadas a vigilância de ambientes, teleconferência, rastreamento, navegação e mapeamento de ambientes (BAKER; NAYAR, 1999; GEYER; DANILIDIS, 2001; BONARINI; ALIVERTI; LUCIONI, 2000). Na área da robótica móvel agrícola, por exemplo, muitos acidentes ocorrem nas regiões laterais e traseira do robô móvel, onde os sistemas de visão convencionais não são aptos para monitorarem as informações dessas regiões (YANG; NOGUCHI, 2012).

O conceito de Visão Omnidirecional foi em boa parte inspirado por exemplos biológicos, principalmente pelo sistema visual de insetos voadores (SRINIVASAN; WEBER; VENKATESH, 1997). Os artrópodes possuem dois olhos constituídos por pequenas lentes hexagonais dispostas no padrão de um favo de mel, sendo que cada lente é responsável pela imagem de uma pequena parte do ambiente. Quando essas imagens são combinadas pelo sistema central, cada olho consegue gerar uma imagem de 90° do ambiente, formando assim uma ampla visão estereoscópica.

A construção de câmeras omnidirecionais (ODVSs, *Omni-Directional Vision Sensors*) foi inicialmente proposta e patenteada por Rees (1970) na U. S. Patent No. 3, 505, 465 no ano de 1970. O autor sugeriu a utilização de refletores ópticos hiperbólicos e elípticos, podendo até mesmo atuar conjuntamente com periscópios, para auxiliar motoristas a obter uma visão mais ampla do ambiente. Na proposta, Rees destacou a importância da utilização desse sistema em um tanque de guerra, onde o motorista estaria protegido dentro do veículo e, tendo a necessidade de obter um campo de visão amplo do ambiente, ele poderia se orientar com auxílio de uma TV que apresentaria a ele a imagem panorâmica obtida pelo equipamento.

Deering (1998) investigou paridades entre visão humana e os dispositivos destinados a exibição de imagens, como televisores, e concluiu que o sistema de visão humano possui um campo de visão do ambiente de aproximadamente 170° x 125° devido a visão estereoscópica e o formato das regiões oculares. Nas câmeras comuns, por sua vez, a abrangência do campo de visão está diretamente relacionado ao tamanho e formato do sensor óptico da câmera, configuração dos limites de projeção, tamanho dos *pixels* e outras características intrínsecas dos equipamentos (BALLARD; BROWN, 1982).

Um sistema de visão omnidirecional pode ser construído de quatro formas: utilizando o sistema tradicional de imagens, rotacionando o sistema de imagens, utilizando lentes especiais olho-de-peixe (*fish-eye*) e através dos sistemas catadióptricos. No trabalho de Yagi (1999) é possível encontrar uma ampla revisão bibliográfica sobre as formas de se obter as imagens omnidirecionais.

Para conseguir uma visão de 360° do ambiente apenas utilizando o sistema tradicional de imagens é necessário a implementação de múltiplas câmeras. Cada câmera é apontada para uma determinada direção do ambiente e as imagens são combinadas por meio da relação espacial entre elas. A vantagem desse tipo de sistema são as altas resoluções das imagens capturadas sem prejudicar a análise do fluxo óptico (CUTLER et. al. 2002; NAYAR, 1997; YAGI, 1999). Outra vantagem é a possibilidade de realizar algoritmos de disparidade entre as câmeras, possibilitando encontrar medidas de profundidade dos objetos na cena.

Apesar de obter imagens em alta resolução, a montagem desse tipo de sistema pode ser complexa devido as dificuldades para calibração das câmeras, a possível latência apresentada pelo sistema na etapa de combinação das imagens e também ao tamanho físico do equipamento, que muitas vezes impossibilita sua utilização em um robô móvel. Outro ponto crítico surge na hora de adquirir os equipamentos, sendo que a quantidade de câmeras muitas vezes encarece o custo do sistema.

A rotação do sistema tradicional de imagens consiste na obtenção de múltiplas imagens utilizando apenas uma câmera que é rotacionada em apenas um eixo vertical com velocidade angular constante. Ao finalizar a volta, é possível obter uma imagem omnidirecional a partir das imagens capturadas. Apesar das imagens obtidas serem em alta resolução e o custo de fabricação ser baixo, esse tipo de sistema perde informação temporal, uma vez que a câmera obtém as imagens de cada direção em instantes de tempo diferentes. Assim, esse tipo de sistema não é recomendável em ambientes altamente dinâmicos ou situações em que todas as informações da imagem omnidirecional devam ser obtidas simultaneamente (SHUM; SZELISKI, 2000).

As lentes especiais olho-de-peixe permitem ampliar a visão da câmera que a utiliza e é uma técnica bastante utilizada na área da fotografia e também na visão computacional, principalmente em vigilância de ambientes (SHAH; AGGARWAL, 1996). As imagens obtidas por meio desse equipamento apresentam uma maior nitidez na região central, enquanto as áreas que sofrem mais distorções são as regiões periféricas. Isso pode ser um problema para a adaptação do sistema em um robô móvel, pois a câmera deve ter sua lente voltada ou para cima, em direção ao céu, ou para baixo, em direção ao robô, e em ambas ocasiões os objetos de interesse do ambiente ficam localizados na periferia da imagem, onde a resolução é menor. Para contornar esse problema pode ser utilizado um braço mecânico suspenso ao robô, como Ericson e Åstrand (2010) utilizou em seu trabalho. Mesmo assim, a característica de visão de médio a longo alcance obtida com a criação do sistema de visão omnidirecional pode ser prejudicada graças a baixa resolução das imagens obtidas.

Sistemas omnidirecionais catadióptricos são criados a partir a combinação de lentes e espelhos com o objetivo de obter uma imagem completa do ambiente (BAKER; NAYAR, 1999; FIALA; BASU, 2002; YI; AHUJA, 2006). O termo catadióptrico é a junção de dois outros termos: dióptrico, a ciência que estuda os elementos de refração (lentes) e catóptrico, ciência que estuda as superfícies de reflexão (espelhos) (HECHT, 1997).

Os sistemas de visão omnidirecional catadióptrico mais utilizados são os que utilizam um espelho convexo que é alocado com precisão em frente a uma câmera, mantendo-se fixa com sua lente apontada para cima (SOUZA, 2009), conforme ilustrado na Figura 2.1. Para obter imagens com maior qualidade, é importante alinhar os pontos focais do espelho e da câmera. Um suporte cilíndrico transparente pode ser utilizado tanto para proteger o espelho de sujeira, como também para aproveitar ao máximo a ampliação do campo de visão.

A visão omnidirecional catadióptrica providencia um campo de visão em 360° livre de movimentos de câmera e mantém os elementos de interesse no campo de visão da aplicação a todo instante, independente da posição desses elementos no ambiente (GRASSI JR.; OKAMOTO JR., 2002).

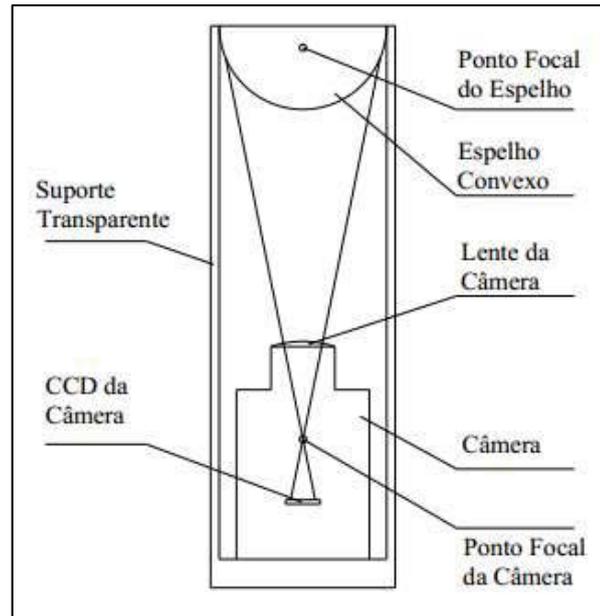


Figura 2.1 - Ilustração de um sistema omnidirecional catadióptrico. Fonte: Souza (2009)

2.2. Tipos de Espelhos em Sistemas Catadióptricos

A aquisição do espelho em sistemas catadióptricos é uma das partes mais críticas do projeto, devido a sua raridade no setor comercial. Muitas vezes é preciso realizar um processo de usinagem para confecção do material, sendo que este deve possuir medidas e características exatas para o sucesso do projeto, levando em conta também a qualidade do material e capacidade reflexiva da superfície.

Em geral, os espelhos utilizados nos sistemas catadióptricos podem ser classificados como centralizados e descentralizados (GEYER; DANIILIDIS, 2001). Sistemas catadióptricos descentralizados são baseados em espelhos esféricos e cônicos, pois violam a restrição de centro único de projeção. Existem outros sistemas catadióptricos descentralizados como os que utilizam espelhos onde a superfície preserva os raios de elevação de pontos com o plano do solo ou espelhos que retificam perpendicularmente os planos com relação ao eixo óptico.

Por sua vez, os sistemas catadióptricos centralizados correspondem aos espelhos de perfil hiperbólico e parabólico. Existem outras variações de espelhos em que também é possível obter a propriedade de centro único de projeção, mas é preciso realizar um estudo para comprovar a existência em cada caso. Os autores Ishiguro (1998), Nayar (1997) e Yamazawa, Yagi e Yachida (1993) abordam extensivamente as propriedades e características de cada perfil de espelho em seus trabalhos.

De acordo com Winters et al. (2000), Vassalo (2004) e Bonarini, Aliverti e Lucioni (2000), o espelho esférico, quando utilizado em sistemas omnidirecionais, é o que consegue obter um maior campo de visão do ambiente. O problema desse tipo de abordagem é que os resultados são bem próximos das imagens capturadas utilizando lentes olho-de-peixe, ou seja, a resolução no centro da imagem é bem superior à resolução encontrada nas extremidades. Um ponto positivo é o fator astigmático, uma vez que não é necessário que se tenha uma profundidade focal longa da câmera para obter imagens com boa qualidade.

Os espelhos cônicos apresentam uma maior resolução na periferia na imagem do que no centro, tendo um ângulo de visão de tamanho mediano (YAGI, 1999). Os espelhos de perfil cônico estão entre aqueles que possuem uma maior facilidade em sua etapa de fabricação, perdendo apenas para os espelhos de perfil esférico. A principal vantagem nesse tipo de espelho é que ele possui uma reflexão normal para a direção vertical, ou seja, a imagem refletida possui fatores de projeção semelhantes com a imagem obtida por uma câmera perspectiva comum. Isso permite uma fácil combinação desse tipo de espelho com outros espelhos, tornando-o largamente utilizado. Um problema encontrado nesse tipo de espelho, conforme descrito em Ishiguro (1998), é o fator astigmático, existindo uma maior complexidade de adquirir imagens com foco quando a câmera está a uma curta distância do espelho, considerando a utilização de lentes comuns. A Figura 2.2 mostra o ângulo de visão de cada tipo de espelho utilizados em sistemas de visão catadióptricos.

Os espelhos parabólicos (PERI; NAYAR, 1997; GRASSI JR.; OKAMOTO JR., 2002; ISHIGURO, 1998), são ideais para atuar em conjunto com câmeras de perfil ortogonal ou lentes telocêntricas. O perfil parabólico é considerado o que tem maior equilíbrio para adquirir uma imagem com foco, uma vez que a projeção ortogonal viabiliza a utilização de diferentes distâncias entre câmera e espelho. Além disso, seu fator astigmático é pequeno quando o espelho possui pouca curvatura e a utilização desse tipo de lente reduz as reflexões internas caso o sistema for alocado em um cilindro de vidro ou esfera.

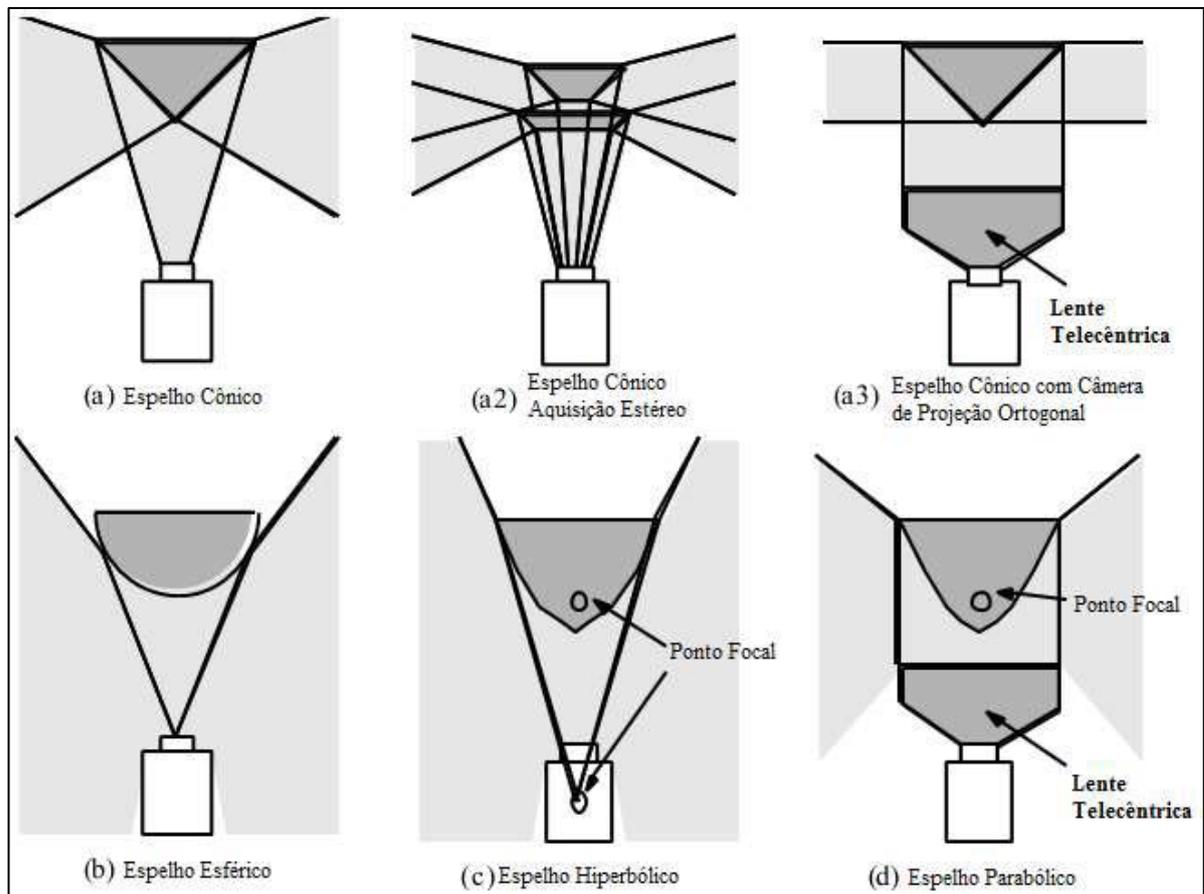


Figura 2.2 – Ângulo de visão de cada tipo de espelho em sistemas catadióptricos. Fonte: Adaptado de Ishiguro (1998)

Alguns autores descrevem o uso dos espelhos hiperbólicos (GRASSI JR.; OKAMOTO JR., 2002; PONS et al., 2007; SHMITS; VISSER, 2008). A fabricação desse tipo de espelho é complexa, porém sua superfície garante uma resolução equilibrada em toda área do espelho e é possível obter um centro único de projeção, sendo essa sua principal vantagem. Segundo Ishiguro (1998), esse perfil de superfície é a melhor para ser utilizada em conjunto com câmeras comuns. Entretanto, as vantagens de ter um centro único de projeção só irão funcionar de fato quando o centro focal do espelho estiver alinhado com o centro da câmera.

A Tabela 2.1, extraída do trabalho de Ishiguro (1998), apresenta os tipos tradicionais de espelho com suas respectivas propriedades.

Tipo de Espelho	Fator Astigmático	Distância focal	Visão Vertical	Centro Único de Projeção	Tipo de Lente
Esférico	Pequeno	Curta	-90...10	Não	Comum
Cônico	Grande	Longa	-45...45	Não	Comum
Hiperbólico com pouca curvatura	Pequeno	Curta	-90...10	Sim	Comum
Hiperbólico com muita curvatura	Grande	Longa	-90...45	Sim	Comum
Parabólico com pouca curvatura	Pequeno	Curta	-90...10	Sim	Ortogonal
Parabólico com muita curvatura	Grande	Curta	-90...45	Sim	Ortogonal

Tabela 2.1: Comparação entre os perfis de espelho. Fonte: Adaptado de Ishiguro (1998)

Cabral, Souza Jr. e Hunold (2004) apresentaram um estudo sobre um espelho hiperbólico de lobo duplo. Esse perfil de espelho, que foi apresentado também por Souza e Motta (2008), foi obtido pela associação de dois espelhos convexos de perfil hiperbólico e realização do alinhamento vertical dos pontos focais entre eles. As imagens obtidas possuíam características semelhantes com a de um sistema catadióptrico estéreo, porém com algumas vantagens como o tamanho compacto do equipamento e facilidade para calibração do sistema de visão, uma vez que o alinhamento entre os pontos focais de cada lobo é uma característica natural do espelho. Além disso, cada lobo foi projetado para que o campo de visão seja igual um do outro, característica essa alcançada deslocando os pontos focais dos espelhos de modo que os ângulos de visão de ambos fossem iguais.

Chaumont, Marhic e Delahoche (2004) projetaram um espelho para obter imagens omnidirecionais do ambiente. Com intuito de analisar um ambiente fechado para tarefas de rastreamento de objetos e detecção de obstáculos, o autor verificou que ao utilizar espelhos de perfil parabólico, cônico ou hiperbólico, as imagens apresentavam várias áreas de informações sem significância para o problema tratado, como o teto do ambiente. Assim, o novo espelho foi projetado para obter informações mais nítidas do chão do ambiente e outras regiões mais baixas. Como resultado foi possível obter um novo perfil de espelho que permite uma resolução linear radial e uma fácil detecção de elementos importantes para o problema. Um aplicativo também foi criado para facilitar o desenvolvimento de novos projetos de espelhos e simulações.

2.3. Centro Único de Projeção

Quando o sistema catadióptrico captura uma imagem omnidirecional do campo de visão, é possível construir imagens panorâmicas e perspectivas utilizando o centro único de projeção (NAYAR; BAKER, 1997, YING; HU, 2004; BOGNER, 1995; HONG et al., 1991; CHAHL; SRINIVASAN, 1997; HICKS; BAJCSY, 2000).

Imaginando um espelho imerso em um ambiente controlado, quando um raio de luz F gerado a partir de um ponto P do ambiente incide na superfície S do espelho, é gerado um ângulo de incidência em função do raio de luz, denominado por i . É preferível que esse ângulo gerado seja inferior a 10 graus pois, caso contrário, pode ocorrer a criação de vários pontos de projeção do mesmo raio de luz, gerando uma superposição de feixes. Isso pode causar distorções ou borrões na imagem gerada (SOUZA; MOTTA, 2008).

O centro único de projeção garante uma imagem nítida capturada a partir do espelho, pois existe a garantia que um determinado ponto no espaço tridimensional do ambiente só possuirá um ponto de projeção na imagem refletida. Assim ela permite a geração de imagens perspectivas geometricamente corretas (BAKER; NAYAR, 1999; REES 1970; YAMAZAWA; YAGI; YACHIDA, 1993). Na Figura 2.3 esse mecanismo é ilustrado.

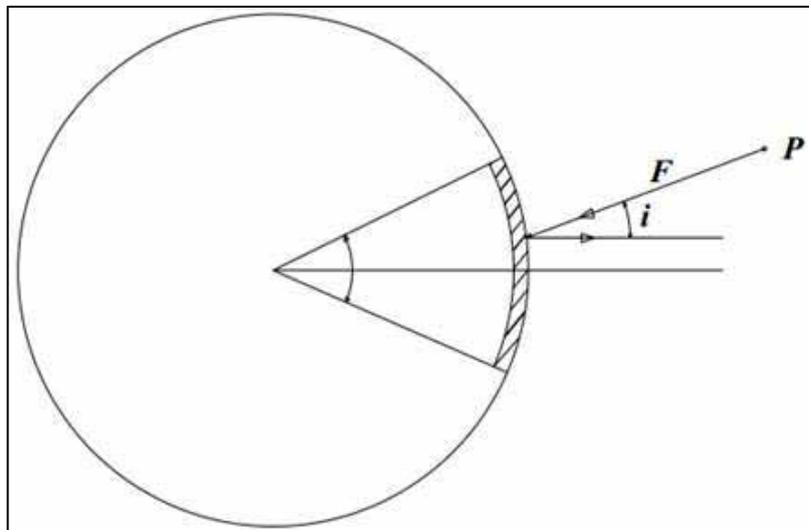


Figura 2.3 - Ilustração do ângulo de incidência gerado por um espelho esférico. Fonte: Adaptado de Souza e Motta (2008)

Existem dois caminhos para se alcançar o centro único de projeção em um sistema omnidirecional catadióptrico. Como pode ser observado na Figura 2.4 (a), o primeiro caminho é utilizar um espelho parabólico S_p juntamente com uma câmera de projeção ortográfica (NAYAR, 1997). Nesse caso, os feixes de luz originados pelos pontos a_1 e b_1 são refletidos pela superfície do espelho S_p nos pontos a_2 e b_2 em direção ao CCD da câmera, gerando os pontos a_3 e b_3 . Devido a forma parábola da superfície, os raios incididos serão paralelos, e assim a câmera de projeção ortográfica captará os feixes gerando coordenadas únicas sem superposição.

O segundo caminho, como pode ser observado na Figura 2.4 (b), é através do uso de um espelho hiperbólico com uma câmera perspectiva. A superfície do espelho é capaz de refletir os pontos pertencentes as coordenadas a_1 e b_1 nas coordenadas do espelho a_2 e b_2 diretamente ao sensor CCD da câmera, originando os valores para as coordenadas cartesianas a_3 e b_3 . Por ser um espelho hiperbólico os raios gerados devem refletir no ponto focal F_2 e no centro da câmera de projeção perspectiva (GRASSI JR.; OKAMOTO JR., 2002; WINTERS, 2001; SOUZA; MOTTA, 2008). A Figura 2.4 ilustra os dois tipos de espelhos citados são representados.

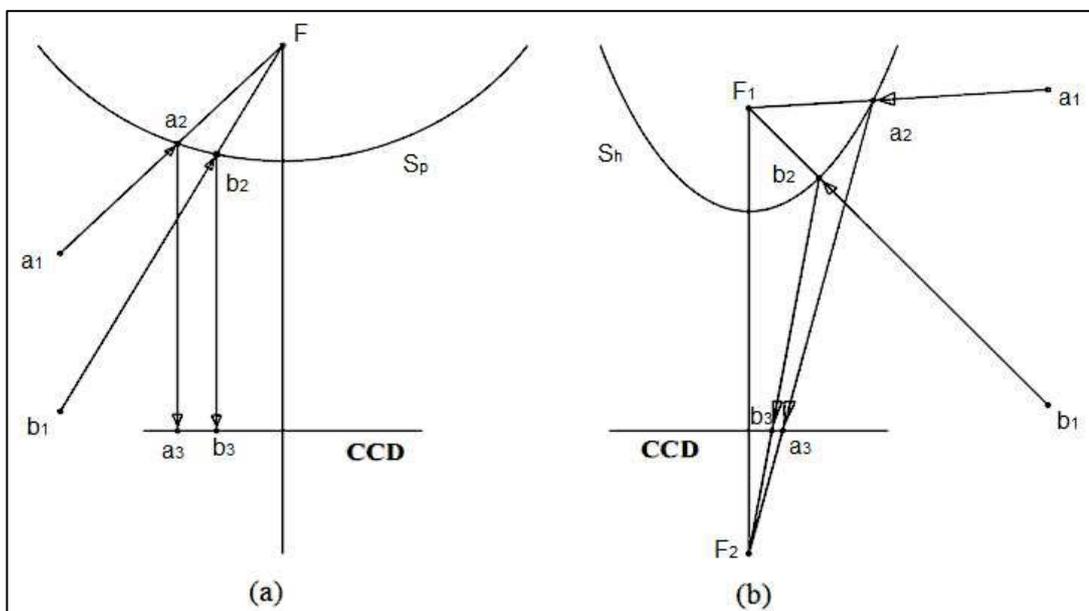


Figura 2.4 - Centro Único de Projeção. Em (a) espelho parabólico e em (b) espelho hiperbólico. Fonte: Souza e Motta (2008)

2.4. Retificação de Imagens Omnidirecionais

No trabalho de Grassi Jr. e Okamoto Jr. (GRASSI JR.; OKAMOTO JR., 2007) são apresentados três métodos que podem ser utilizados para a criação de imagens panorâmicas ou perspectivas a partir das imagens omnidirecionais coletadas. Em algumas aplicações, é necessária a realização desse procedimento uma vez que as imagens omnidirecionais podem apresentar maior complexidade de interpretação pelos seres humanos e alguns algoritmos de navegação e rastreamento exigem como entrada uma imagem planificada (PERI; NAYAR, 1997; BAKER; NAYAR, 1999). Essas exigências podem tornar necessária a criação de uma nova etapa após a aquisição de imagens denominada etapa de retificação.

Tal processo pode ser realizado através do mapeamento direto de coordenadas polares para cartesianas, através da retificação utilizando centro único de projeção e também pelo método de geração de imagens perspectivas utilizando o centro único de projeção. Esses métodos serão melhor abordados nas próximas sessões.

2.4.1. Mapeamento direto de coordenadas polares

Uma imagem panorâmica pode ser obtida quando a imagem omnidirecional adquirida pelo sistema de visão catadióptrico tiver suas coordenadas polares mapeadas para coordenadas cartesianas. Para isso, o ângulo azimute da imagem original é mapeado no eixo horizontal da imagem panorâmica, e a coordenada radial da imagem original é mapeada no eixo vertical da imagem panorâmica, como pode ser observado na Figura 2.5.

Para a implementação desse método, as Equações 2.1 e 2.2 podem ser utilizadas:

$$u = \frac{v_{pn} \cdot r_{pixel}}{V_{pn}} \cos\left(\frac{2\pi \cdot u_{pn}}{H_{pn}}\right) \quad (2.1)$$

$$v = \frac{v_{pn} \cdot r_{pixel}}{V_{pn}} \sin\left(\frac{2\pi \cdot u_{pn}}{H_{pn}}\right) \quad (2.2)$$

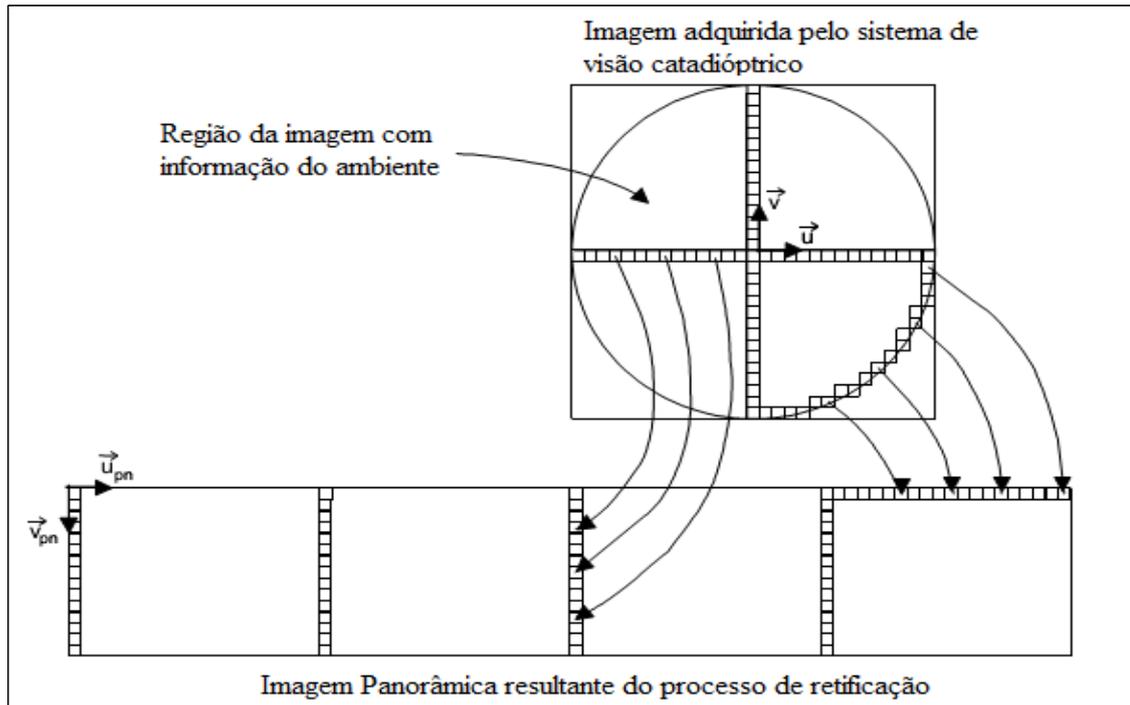


Figura 2.5 – Processo para criação da imagem panorâmica utilizando mapeamento de coordenadas polares. Fonte: Adaptado de Grassi Jr. e Okamoto Jr. (2002)

em que u e v são coordenadas de um pixel da imagem original, u_{pn} e v_{pn} correspondem às coordenadas da imagem panorâmica. O tamanho vertical da imagem panorâmica é representado por V_{pn} e o tamanho horizontal por H_{pn} . Por fim, r_{pixel} representa o tamanho do raio de retificação a partir do centro da imagem omnidirecional.

Considera-se que o centro da imagem omnidirecional seja $(0,0)$ e por isso esse parâmetro deve ser adaptado pelo sistema de coordenadas da imagem original. Como um pixel da imagem omnidirecional pode ser mapeado mais de uma vez na imagem panorâmica, um mapeamento inverso é realizado para que todos os *pixels* da imagem resultante sejam preenchidos corretamente. O mapeamento inverso permite que para cada pixel da imagem panorâmica seja possível encontrar um pixel na imagem omnidirecional, por meio das equações aqui demonstradas.

É importante notar que é possível otimizar o processo de retificação com a utilização de *lookup tables*. As *lookup tables* são estruturas que armazenam a correspondência entre os *pixels* da imagem original com os *pixels* da imagem resultante, assim não é necessário calcular essa relação para cada imagem adquirida. Esse mecanismo torna praticável a etapa de retificação em sistemas de tempo real (GRASSI JR.; OKAMOTO JR., 2007).

2.4.2. Retificação utilizando centro único de projeção

Conforme discutido em sessões anteriores, a utilização conjunta de espelhos com perfil hiperbólico e câmeras perspectivas ou espelhos com perfil panorâmico e câmeras ortogonais apresentam um centro único de projeção. Essa propriedade garante que a retificação utilize um mapeamento polar linear, gerando uma imagem livre de distorções verticais. No método anterior, é possível notar distorções na imagem resultante que podem ser eliminadas utilizando a propriedade de centro único de projeção do espelho.

Como o centro único de projeção permite observar o ambiente em todas as direções por meio de um único ponto, é possível projetar um cilindro em torno do sistema de visão e, por meio de equações, construir uma imagem panorâmica. Na Figura 2.6 é apresentada a geometria que relaciona o espelho do sistema de visão com a câmera, e também a projeção cilíndrica para formar a imagem planificada.

Na Figura 2.6, v_{pn} representa a coordenada de um pixel da coluna da imagem panorâmica, DV_{pn} a altura da imagem panorâmica medida em *pixels* que tem como referência a margem do espelho quando $v_{pn} = 0$ e r_i é a variação radial do pixel referenciado na imagem omnidirecional. O parâmetro $2e$ representa a distância entre o centro do espelho e o ponto focal do espelho e φ representa a elevação do ângulo correspondente ao ponto (x, y) no espelho. Outras variáveis como f , representando a distância entre o plano de projeção e o centro focal da câmera, y_{top} representando a coordenada do topo do espelho e também ψ , representando a distância angular entre os feixes representados, também estão presentes na imagem. Com base nessas relações trigonométricas, é possível extrair as Equações 2.3 e 2.4 que auxiliam a encontrar as coordenadas dos *pixels* de correspondência na etapa de retificação:

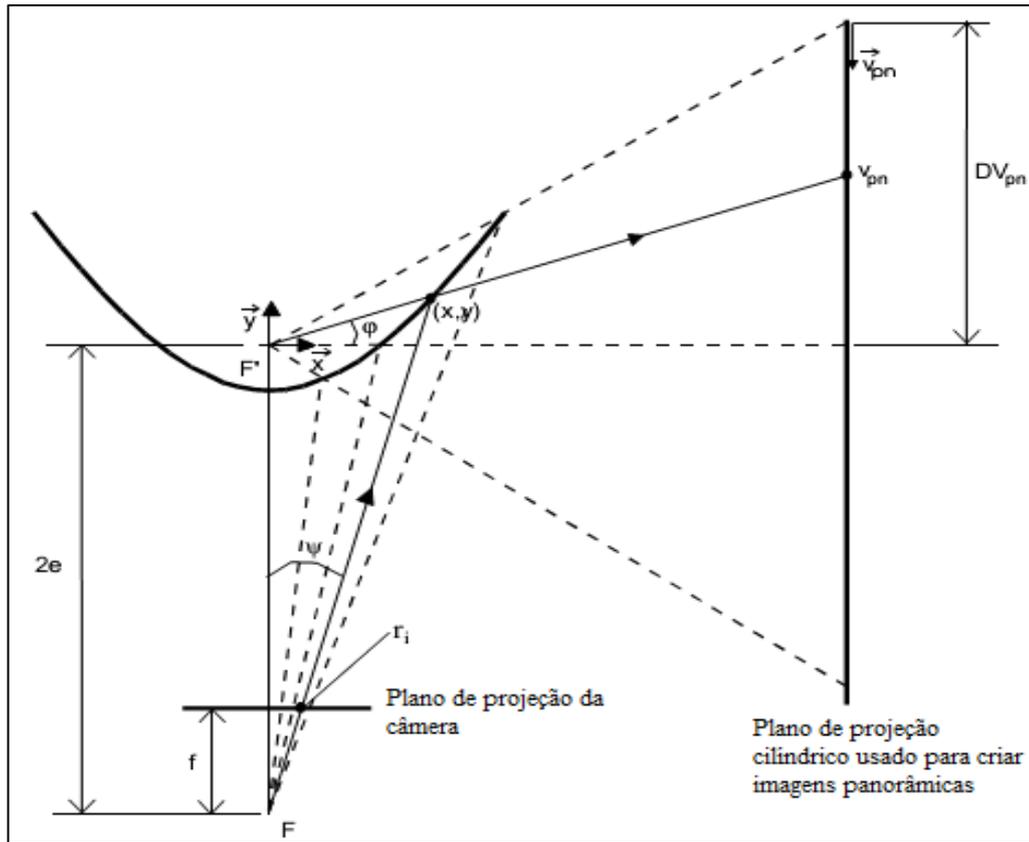


Figura 2.6 – Projeção do plano cilíndrico para retificação utilizando centro único de projeção. Fonte: Adaptado de Grassi Jr. e Okamoto Jr. (2002)

$$y = \frac{x \cdot (DV_{pn} - v_{pn}) \cdot y_{top}}{DV_{pn} \cdot r_{top}} \quad (2.3)$$

$$r_i = \frac{x \cdot DV_{pn} \cdot r_{pixel} \cdot (2e + y_{top})}{(DV_{pn} - v_{pn}) \cdot x \cdot y_{top} + DV_{pn} \cdot 2e \cdot r_{top}} \quad (2.4)$$

Na Equação 2.3 é apresentada uma maneira para encontrar a linha que passa consecutivamente pelo ponto v_{pn} e pelo ponto focal do espelho. Nessa equação, r_{top} representa a distância radial (ou coordenada x) de um ponto encontrado na borda do espelho e y_{top} a coordenada y desse ponto. Os parâmetros r_{pixel} , $2e$ e r_{top} são conhecidos a priori. A Equação 2.4 é utilizada para encontrarmos a variação radial do pixel capturado pelo plano de projeção da câmera, valor fundamental para encontrarmos as coordenadas de correspondência no plano de projeção cilíndrico como observado nas Equações 2.5 e 2.6:

$$u = r_i \cdot \cos\left(\frac{2\pi \cdot u_{pn}}{H_{pn}}\right) \quad (2.5)$$

$$v = r_i \cdot \sin\left(\frac{2\pi \cdot u_{pn}}{H_{pn}}\right) \quad (2.6)$$

em que u e v representam, respectivamente, as coordenadas de um pixel na imagem omnidirecional, u_{pn} e v_{pn} representam as coordenadas de um pixel da imagem panorâmica, H_{pn} representa o comprimento da imagem panorâmica e r_i é a distancia radial calculada na Equação 2.4.

Assim como o método descrito na sessão 2.4.1, para otimizar o processamento e tornar a retificação da imagem com centro único de projeção adaptável em aplicações de tempo real pode-se também utilizar o mecanismo de *lookup tables*, colocando as coordenadas calculadas em estruturas de armazenamento para facilitar o resgate dessas informações.

2.4.3. Geração de Imagens Perspectivas

Além da criação de imagens panorâmicas, é possível utilizar a propriedade de centro único de projeção para criação de imagens perspectivas. Para isso, projeta-se um plano no espaço que seja perpendicular a uma linha que passe pelo centro focal do espelho. Na Figura 2.7 é apresentada a geometria que relaciona o espelho do sistema de visão com a projeção do plano para construção da imagem perspectiva.

Na Figura 2.7, o plano de projeção pode ser definido por $(f_p, \theta_0, \varphi_0)$ em que f_p é a distância entre ponto focal da hipérbole e o plano, θ_0 representa o ângulo vertical ou azimute do sistema de visão e φ_0 representa o ângulo de projeção do plano. Da mesma forma que os métodos das sessões 2.4.1 e 2.4.2, é realizado um mapeamento inverso, em que as coordenadas (u_p, v_p) do plano perspectivo são encontrados pela direção (θ, φ) a partir do ponto (x, y) na superfície do espelho. Essa relação é dada pelas Equações 2.7 e 2.8:

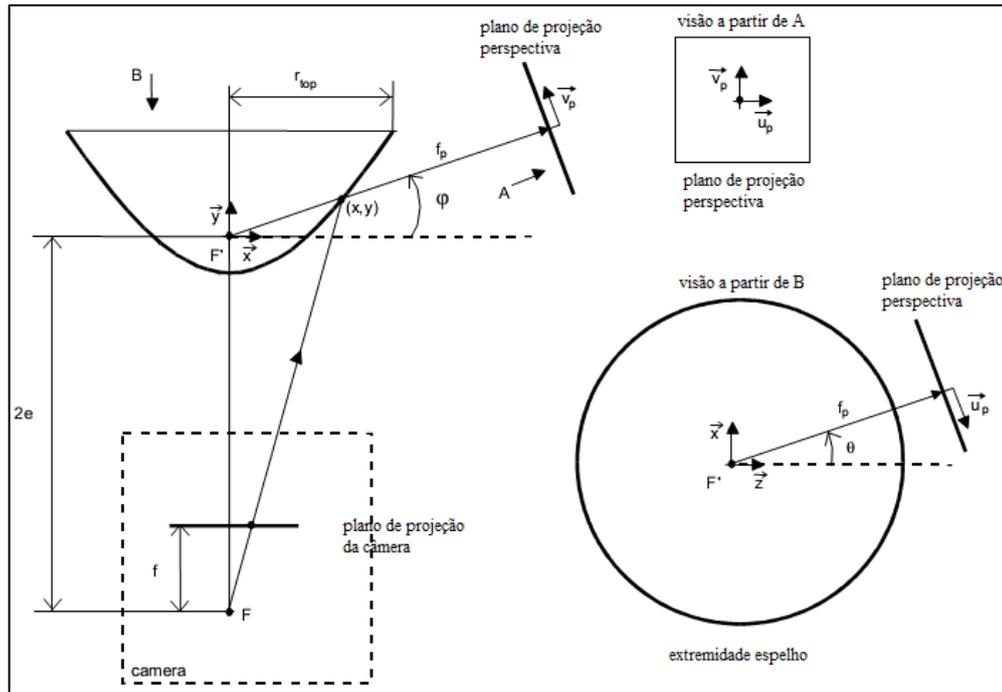


Figura 2.7 – Plano de projeção perspectiva. Fonte: Grassi Jr. e Okamoto Jr., 2002

$$\tan \varphi = \frac{f_p \sin \varphi_0 + v_p \cos \varphi_0}{f_p \cos \varphi_0} \quad (2.7)$$

$$\tan \theta = \frac{(f_p \cos \varphi_0 - v_p \sin \varphi_0) \cdot \sin \theta_0 - u_p \cos \theta_0}{(f_p \cos \varphi_0 - v_p \sin \varphi_0) \cdot \cos \theta_0 + u_p \sin \theta_0} \quad (2.8)$$

Encontrando a reta que origina a tangente do ângulo de deslocamento e consequentemente definindo o plano de projeção perspectiva, é possível obter as coordenadas da imagem adquirida pelo sistema de visão com a relação trigonométrica descrita na Equações 2.9 e 2.10:

$$u = \frac{x \cdot (2e + y_{top}) \cdot r_{pixel}}{(x \cdot \tan \varphi + 2e)} \cos \theta \quad (2.9)$$

$$v = \frac{x \cdot (2e + y_{top}) \cdot r_{pixel}}{(x \cdot \tan \varphi + 2e)} \sin \theta \quad (2.10)$$

em que x e y representam as coordenadas do pixel no espelho, r_{pixel} define o raio de retificação e os demais parâmetros já foram abordados anteriormente. Para aumentar a eficiência de processamento em tempo real, o algoritmo pode ser adaptado para utilizar *lookup tables*, do mesmo modo dos métodos descritos nas sessões 2.4.1 e 2.4.2.

2.4.4. Equações do espelho hiperbólico

Essa sessão é destinada às equações geométricas e variáveis de configuração responsáveis por definir o perfil de espelho hiperbólico. Um estudo com base nos trabalhos de Grassi Jr. e Okamoto Jr. (2007), Svoboda, Padjla e Hlavac (1998) e Souza (2009) será detalhado a seguir.

2.4.4.1. Equação da hipérbole

Uma hipérbole é o lugar geométrico dos pontos cujo módulo da diferença das distâncias a dois pontos dados é constante e menor que a distância entre F_1 e F_2 (AVRITZER, 2009). A curva gerada pela intersecção é o conjunto de todos os pontos C_n , em que a distância entre os dois centros F_1 e F_2 é constante, conforme a Figura 2.8. Os parâmetros a e b representam consecutivamente distâncias horizontais e verticais da linha perpendicular à superfície do espelho que passa pelo ponto focal.

Com base na Figura 2.8, a equação da hipérbole pode ser definida conforme a Eq. 2.11:

$$\frac{(y-k)^2}{a^2} - \frac{(x-j)^2}{b^2} = 1 \quad (2.11)$$

onde os parâmetros j e k representam as coordenadas (j, k) do centro da hipérbole e os parâmetros a e b são os semi-eixos.

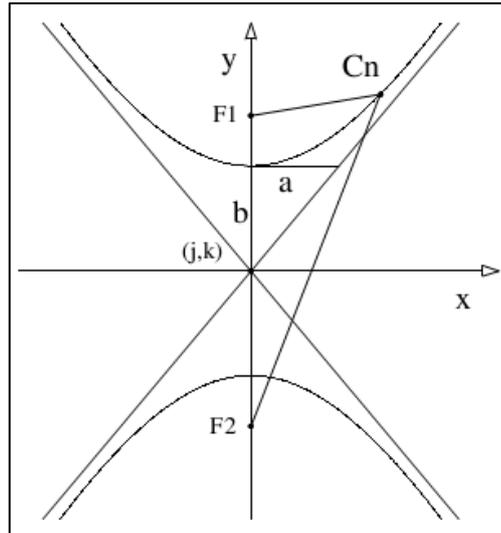


Figura 2.8 – Composição da hipérbole. Fonte: Souza e Motta (2008)

É possível também simplificar essa equação considerando o centro da hipérbole, em que $j = 0$ e $k = 0$, conforme a Equação. 2.12.

$$\frac{y^2}{a^2} - \frac{x^2}{b^2} = 1 \quad (2.12)$$

2.4.4.2. Equação do espelho hiperbólico

Podemos mover a coordenada (j, k) para o ponto central F_1 do espelho e, caso o centro da câmera coincidir com o foco F_2 , existirá uma associação geométrica entre o espelho hiperbólico com a câmera de projeção perspectiva, conforme ilustrado na Figura 2.9. Nessa imagem, f representa o comprimento focal da câmera, h a distância entre a superfície do espelho e o centro da câmera, R_{topo} é a coordenada x do topo do espelho e α é o ângulo de visão (SOUZA; MOTTA, 2008). Podemos definir os parâmetros e , y e a conforme as Equações 2.13, 2.14 e 2.15:

$$e = \sqrt{a^2 + b^2} \quad (2.13)$$

$$y = \sqrt{a^2 \cdot \left(1 + \frac{x^2}{b^2}\right)} - e \quad (2.14)$$

$$\alpha = \frac{\pi}{2} + a \tan\left(\frac{h-2e}{R_{topo}}\right) \quad (2.15)$$

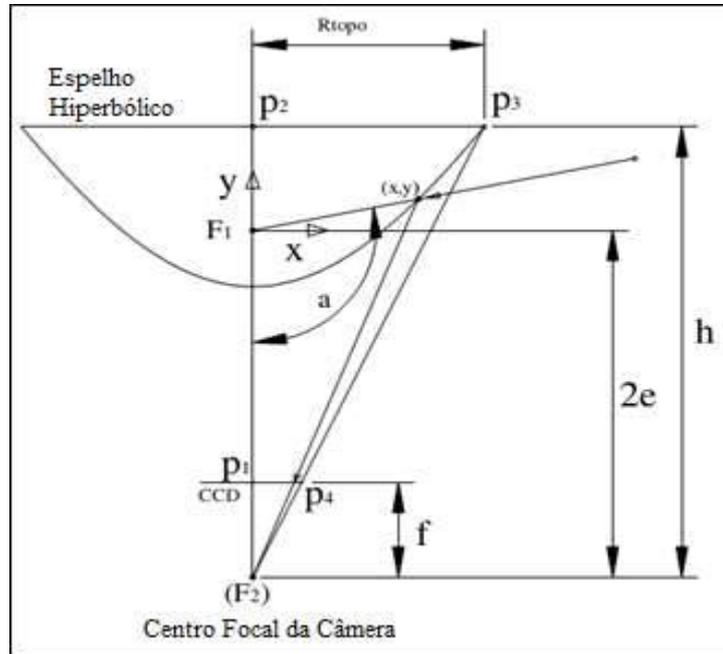


Figura 2.9 – Relação matemática entre câmera e espelho hiperbólico
Fonte: Adaptado de Souza e Motta (2008)

Para obtermos a equação final do espelho, é necessária uma relação entre os parâmetros a e b . Podemos substituir as coordenadas do topo do espelho para expressar b em função da relação a/b , conforme a Equação 2.16.

$$b = h \cdot \sqrt{\left(1 + \frac{a^2}{b^2}\right)} - \frac{a}{b} \cdot \sqrt{h^2 + R_{topo}^2} \quad (2.16)$$

Fixando os valores adequados para R_{topo} referem-se aos valores da lente e da imagem adquirida pelo sistema. Ao final é possível calcular o parâmetro do espelho com base na relação a/b . O trabalho de Svoboda, Padjla e Hlavac (1998) traz alguns resultados variando os valores fornecidos pelos parâmetros dessa relação.

2.5. Considerações finais

Nesse capítulo foram fundamentados os principais conceitos a respeito dos Sistemas de Visão Omnidirecional. Além de apresentar os caminhos para a construção desse tipo de sistema, também foram discutidos os tipos de espelhos mais comuns utilizados em Sistemas Omnidirecionais Catadióptricos e suas principais características, além das maneiras de transformar uma imagem originalmente omnidirecional em imagens panorâmicas e perspectivas, processo esse conhecido como Etapa de Retificação da imagem omnidirecional. Outro processo apresentado foi o equacionamento dos espelhos hiperbólicos e suas relações com a câmera perspectiva em um sistema de visão omnidirecional.

3. REVISÃO BIBLIOGRÁFICA

Esse capítulo é dedicado a uma revisão bibliográfica sobre o tema proposto. Os trabalhos foram divididos em três grupos: sistemas de visão omnidirecional para ambientes fechados, sistemas de visão omnidirecional para ambientes agrícolas e sistemas de visão monocular para ambientes agrícolas.

3.1.Introdução

Grande parte dos trabalhos encontrados na literatura para sistemas de visão omnidirecional são aplicados em ambientes fechados. Essas pesquisas englobam desde a confecção dos sistemas de visão até soluções para problemas de calibração, rastreamento de objetos, segurança, vídeo conferência, navegação, entre outros.

Alguns trabalhos na área da navegação em robótica móvel em ambientes fechados utilizando sistemas omnidirecionais catadióptricos são mencionados, uma vez que existem várias contribuições para a área realizadas nesse ambiente.

Após, são apresentados os trabalhos encontrados na área de visão omnidirecional em cenários agrícolas. Esses trabalhos, mesmos que alguns deles não sejam destinados à navegação, possuem em comum várias dificuldades encontradas em ambientes desestruturados e muitas das técnicas utilizadas auxiliaram esse trabalho.

A ultima sessão desse capítulo é dedicada aos trabalhos de visão monocular em ambientes agrícolas. Essa sessão tem como objetivo apresentar as técnicas de pré-processamento e segmentação utilizadas, possibilitando o estudo e inserção desse conhecimento dentro do escopo do projeto.

3.1.1. Aplicações de Visão Omnidirecional para ambientes fechados

Winters et al. (2000) propôs um sistema de estimativa de posição de um robô móvel em ambiente fechado utilizando apenas um sistema catadióptrico composto por uma câmera CCD e um espelho esférico. As imagens originalmente adquiridas pelo sistema foram retificadas utilizando a técnica Visão Olho de Pássaro (*Bird's Eye View*). Essa técnica permitiu transformar imagens omnidirecionais de perfil perspectivo em imagens omnidirecionais de perfil ortogonal, alterando os formatos do chão e regiões mais baixas do ambiente. Para realizar a navegação, uma técnica para criação de mapa topológico foi utilizado. Essa técnica permitiu que o robô navegasse no ambiente sem precisar conhecer as medidas físicas de comprimento e distância de cada local. O mapa é representado por um grafo em que cada local do ambiente em que ações são executadas é representado por um nó. Como a quantidade de imagens adquiridas durante a navegação é bastante grande e por sua vez o número de informações também é alto, foi utilizada a técnica de representação *low dimensional eigenspace* construída usando Análise de Componentes Principais, formando uma imagem *eigenspace*. O conjunto dessas imagens com o mapa topológico formam as relações que são utilizadas para navegação. A imagem *eigenspace* é utilizada para estimar a posição do robô no ambiente. Para as bordas presentes nas imagens são calculadas a distância Hausdorff, permitindo obter a distância entre duas arestas na imagem. Sabendo que o corredor é composto por duas arestas paralelas, é possível explorar essa informação para realizar a navegação do robô. *Bounding boxes* pré-definidos foram utilizados como facilitadores para encontrar as linhas do corredor. Essa técnica delimita regiões na imagem para rastrear as linhas dos corredores, refinando a região de interesse, e suas coordenadas são atualizadas constantemente durante o fluxo de vídeo. Outra técnica estudada foi a navegação por meio da inserção de marcadores artificiais no ambiente. A partir da detecção dos marcadores foi possível o cálculo de coordenadas de navegação feito pelo sistema. O robô móvel se move no ambiente de acordo com a disposição dos marcadores. Vários testes foram realizados em missões de pequena, média e longa distância. A solução de ambas as técnicas em conjunto do sistema de visão catadióptrico se mostrou robusta e possível de se aplicar em ambientes mais complexos. Na Figura 3.1 (a) é possível observar a aplicação do método de *Bouding Boxes* para rastrear as linhas formadas pelos corredores e na Figura 3.1 (b) a utilização de marcadores artificiais para auxiliar nas orientações da navegação.

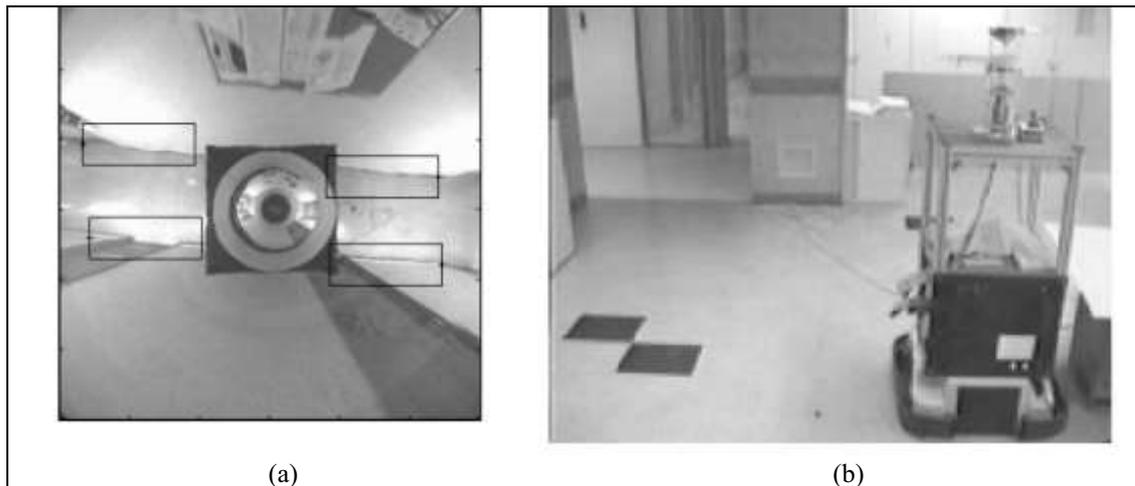


Figura 3.1 – Rastreamento das linhas dos corredores utilizando *Bouding Boxes* (a) e marcadores artificiais (b). Fonte: Adaptado de Winters et al., 2000

Boney, Cazorla e Escolano (2007) criou um sistema para navegação de um robô móvel em corredores e avenidas combinando duas técnicas básicas de comportamento. A primeira técnica tem como objetivo estimar a direção do corredor e possibilitar a movimentação do robô. O segundo comportamento é a verificação de obstáculos inspirado em um algoritmo de navegação para anéis de sonares. Para executar a primeira técnica, uma imagem omnidirecional de uma dimensão foi gerada. Para isso, foi calculada a média dos valores de todas as linhas para determinada coluna e esses valores compõem uma sequência que definem a retificação da imagem original. Com a obtenção da nova imagem 1D, foi possível calcular uma mapa de entropia de acordo com a distância de cada característica presente na imagem. Os corredores apresentavam característica bem distribuídas, com distâncias maiores, enquanto que nos outros locais existiam mais características em um espaço menor. Ao final, um filtro passa baixa foi aplicado no mapa de entropia. Isso permite atenuar os dois principais picos no domínio da função. Com a transformação discreta de Fourier, foi possível encontrar a aproximação entrópica dos valores, uma vez que a máxima está relacionada ao ângulo da imagem omnidirecional retificada. Em outras palavras, os picos da função de transformação estão associados com o ângulo da imagem omnidirecional, assim é possível encontrar a direção dos corredores dentro da imagem retificada.

O segundo método de comportamento projeta raios virtuais que passam pelo centro da imagem omnidirecional e foi calculada a medida de gradiente de cada radial. Quanto maior esse valor mais reflexão existe na área analisada na imagem. Com esses valores e a identificação dos dois picos de gradiente, é possível identificar onde estão os obstáculos. Apesar de não ser tão precisa como sonares e outros sensores, a combinação das duas técnicas que são aplicadas exclusivamente em imagens omnidirecionais mostrou-se eficientes nos experimentos realizados.

Grassi Jr. e Okamoto Jr. (2007) apresentaram o processo completo de construção de um sistema omnidirecional catadióptrico e também três métodos para retificação de imagens omnidirecionais catadióptricas em imagens panorâmicas e perspectivas: geração de imagens panorâmicas utilizando o mapeamento direto de coordenadas polares para coordenadas cartesianas, geração de imagens panorâmicas utilizando o centro único de projeção e geração de imagens perspectivas usando o centro único de projeção.

Dois tipos de espelhos foram utilizados sendo eles os perfis hiperbólico e parabólico. O processo de fabricação dos espelhos também foi detalhado, no qual foi utilizado um torno convencional para juntar o alumínio com o espelho, e também uma máquina de ultra precisão CNC para dar a forma ao material. Os métodos de retificação apresentados foram descritos detalhadamente no trabalho.

Maohai et al. (2013) apresentou uma topologia de navegação para um sistema que utiliza visão omnidirecional. Primeiramente, o robô foi levado para recolher imagens de todo ambiente em modo *off-line*. Nesse momento, a sequência de imagens obtida foi dividida em pequenas sessões onde cada uma representa um nó do mapa topológico e o conjunto de nós denominam-se áreas. Para compactar a representação de cada área, algumas imagens da sequência são selecionadas e características invariantes de cada imagem são encontradas.

O segundo passo foi realizar a auto localização do robô. Para isso, o robô foi inserido no ambiente e uma imagem foi obtida. Com a análise das características intrínsecas da imagem capturada foi possível relacionar a imagem capturada com as armazenadas anteriormente pelo sistema de visão. Para a comparação entre as características invariantes, o método Affine-SIFT foi utilizado (MOREL; YU, 2009). Como algoritmos de comparação utilizam muito tempo de processamento, a realização dos algoritmos com GPU utilizando o framework CUDA foi a escolha para diminuir esse custo. Assim, foi possível a construção de um mapa topológico para navegação. Com o reconhecimento das características, foi possível medir a posição no nó e estabelecer uma regra de controle adaptativo para que o robô possa seguir o caminho visual.

3.1.2. Sistemas de Visão Omnidirecional para cenários naturais

O objetivo do trabalho de Ericson e Åstrand (2010) era encontrar linhas de plantio paralelas de uma determinada plantação. Para isso um sistema de visão omnidirecional catadióptrico e uma lente especial olho-de-peixe foram utilizados.

Para a calibração da câmera foi escolhido o modelo de Taylor uma vez que esse método possibilita a calibração de ambos os sistemas de visão citados. Nas imagens capturadas, as linhas de plantio que estão localizadas longe da câmera são vistas na imagem como linhas sólidas. Assim, a primeira etapa de processamento foi a aplicação do método Canny (1986) para detecção de borda. Nesse processo, uma máscara foi aplicada para remover informações irrelevantes. Dividindo as linhas em partes e calculando as normais de cada parte em relação a uma esfera, foi possível eliminar pontos que não estão na mesma direção. Além disso, as linhas que possuem comprimento menor que um limiar pré-definido também são eliminadas. Após, foi necessário agregar as linhas que representam uma mesma linha de plantação. Para isso, a distância ortogonal entre todas as normais foram calculadas e caso a diferença do valor de uma normal com outra for menor que um determinado limiar pré-definido, considera-se que as linhas possuem a mesma normal.

Outro método utilizado foi baseado na transformada de Hough (DUDA; HART, 1972). Primeiramente uma máscara de corte foi aplicada para separar a área de interesse na imagem. Após, um filtro Gaussiano (SHAPIRO; STOCKMAN, 2001) foi utilizado para diminuir o ruído da imagem e um *thresholding* adaptativo foi aplicado para produzir uma imagem binária. Para cada ponto foi calculado um vetor unitário correspondente e o *threshold* foi preparado para selecionar um número pré-definido de pontos. Ao final, a transformada de Hough baseada em coordenadas esféricas foi executada. O terceiro método foi criado a partir da combinação dos dois métodos anteriores. Como nos dois métodos anteriores a agregação foi feita a partir do tamanho das linhas encontradas, nesse método foi aplicado um peso para balancear o desempenho. Com o resultado obtido, conforme ilustrado na Figura 3.2, foi possível perceber que ambos os métodos tiveram eficiência de reconhecer as linhas de plantio, porém essa eficiência é variável. O método de detecção de borda trabalhou melhor quando as linhas de plantio consistiam em linhas sólidas, enquanto que a transformada de Hough trabalhou melhor quando consistiam em plantas individuais. Porém, o método combinado apresentou uma melhor detecção do que os métodos usados separadamente em ambos os casos.

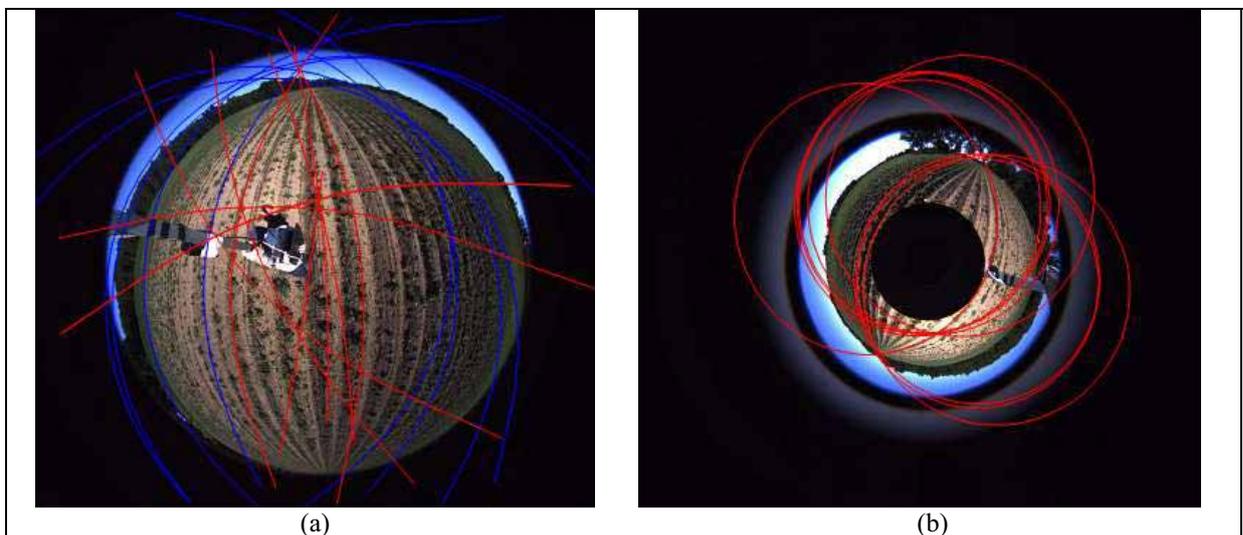


Figura 3.2 – Resultados obtidos com lentes olho-de-peixe (a) e catadióptrico (b). As linhas vermelhas são os resultados com a transformada de Hough, enquanto as linhas azuis com o de detecção de borda. Fonte: Ericson e Åstrand, 2010

Um sistema para estimativa de posição foi construído por Li et al. (2011). Para isso, foi utilizado sensor de visão omnidirecional, dois marcadores, um computador e um processador de imagens. Cada marcador foi colocado em lados opostos do campo em que o robô iria operar e serviu de referências para a estimativa de posição. A Figura 3.3 é ilustrada a alocação do sistema de visão no veículo como também a posição dos marcadores no ambiente. Como o sistema de visão é omnidirecional, os marcadores sempre estão presentes na imagem, independentemente da orientação do robô. Os marcadores foram representados por cones circulares com cores vermelha e azul. Devido à complexidade dos ambientes naturais, é possível que outros elementos presentes no cenário atrapalham o reconhecimento dos marcadores pelo sistema de visão. Assim, foi calculado as intensidades de cores para vermelho e azul na imagem e tornou-se possível a aplicação do *threshold* para obter os elementos com possibilidades de serem os marcadores. Depois, a distância entre dois *pixels* adjacentes randômicos foi verificada e quando esse valor era menor que um limiar pré-definido, a coordenada da pequena área vinculada pela posição desses dois pontos era armazenada. Essa área tornou-se um candidato possível para representação dos marcadores. Após esse processo, foi possível calcular a distância de cada possível candidato do marcador vermelho com cada possível candidato do marcador azul e definir o reconhecimento para aqueles que possuem valores mais próximos da distância real no ambiente.

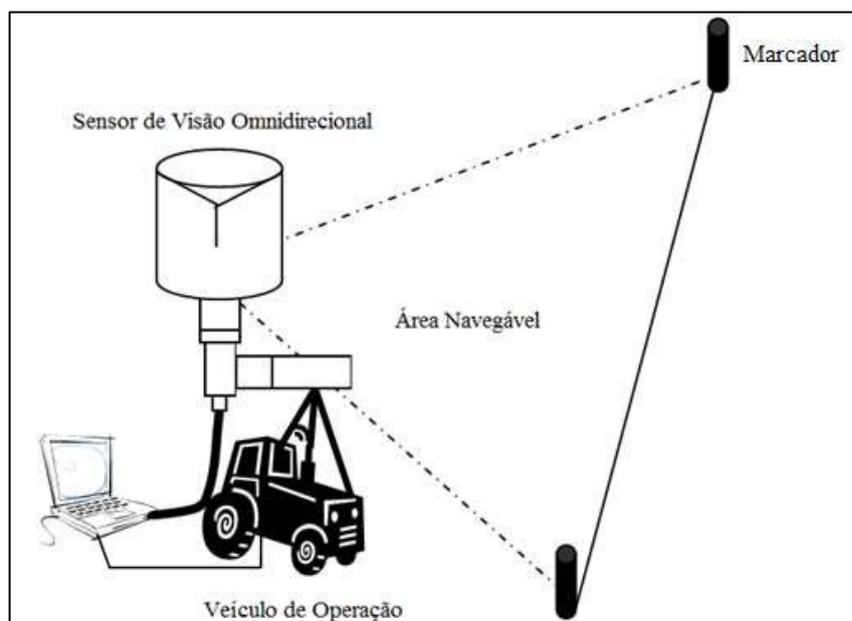


Figura 3.3 – Ilustração do sistema de visão omnidirecional construído por Li. Fonte: Adaptado de LI et al., 2011

Quando os marcadores são reconhecidos, o sistema estima a distância da câmera omnidirecional com os marcadores a partir da localização de cada marcador na imagem. Nos experimentos, cada marcador tinha 23 cm de diâmetro por 71 cm de altura e foram posicionados no ambiente mantendo a distância de vinte metros entre eles. O erro máximo obtido pelo cálculo da posição de reconhecimento dos marcadores foi de 32,19 centímetros. O método proposto mostrou-se aplicável em ambientes naturais, porém outras variáveis presentes no ambiente devem ser reavaliadas, como exposição do sol e vibração do veículo.

Li et al. (2012) apresentou uma continuação do seu trabalho anteriormente discutido. Dessa vez foram incluídos no ambiente natural quatro marcadores vermelhos. Ao capturar a imagem pelo sistema de visão omnidirecional catadióptrico, um filtro passa-baixa foi executado para suavizar a imagem e eliminar ruídos causados por altas frequências. Um *threshold* também foi executado para controlar a decomposição dos *pixels* vermelhos, uma vez que elementos no cenário natural e intensidade de luz podem também causar ruídos. A intensidade de cor vermelha de cada pixel foi calculada para destacar os marcadores na imagem.

Os *pixels* vermelhos foram divididos em grupos usando o algoritmo de varredura de linha. Contando a quantidade de números vermelhos de cada grupo foi possível verificar a área corresponde a um marcador. Para eliminar as áreas correspondentes a falsos candidatos, um *threshold* foi executado tendo como limiar a distância Euclidiana entre os elementos. Para estimar um novo ângulo de direção, foi proposto um novo método que considera a direção do ângulo obtida diretamente na imagem e o peso de cada marcador de acordo com a confiança de cada medida extraída.

O método para estimar a posição do veículo foi adaptado para utilizar os quatro marcadores. Os testes foram realizados em ambiente natural e terreno plano, onde o veículo se locomovia a uma velocidade de 5,5 km/h. Os marcadores foram dispostos no terreno formando um retângulo de 50x10 metros. A pesquisa demonstrou ser mais robusta que os trabalhos anteriores e a taxa de erro para a medida de direção calculada foi menor que dois graus. O método pode ser tanto utilizado em ambientes fechados substituindo o GPS (*Global Position System*) ou também em ambientes abertos. Nesse último caso, a utilização conjunta com o GPS pode garantir uma eficiência maior do sistema.

Yang e Noguchi (2012) construíram um sistema de visão omnidirecional para detecção de pessoas em um ambiente natural. O sensor de visão foi construído com duas câmeras omnidirecionais alocadas de forma vertical. Cada câmera omnidirecional é composta por seis câmeras comuns, onde cinco delas formam um anel horizontal e uma câmera é apontada para o céu. Apesar da câmera omnidirecional estar pré-calibrada no processo de manufatura, foi necessário encontrar a relação espacial entre as duas câmeras omnidirecionais. Uma calibração estéreo foi realizada utilizando o método de Zhang (ZHANG, 1999; ZHANG, 2000) e a retificação aplicando o algoritmo de Bouget (BRADSKI; KAEBLER, 2008). Para reduzir o tempo de processamento, a imagem panorâmica foi formada juntando as imagens de cada lente pelo método comum. O método de Lucas-Kanade (LUCAS; KANADE, 1981) foi utilizado para computar o fluxo de vídeo e encontrar áreas possíveis onde o humano possa estar. O humano é detectado através da análise de direção e magnitude calculados por este algoritmo e, utilizando um modelo de grades, é possível encontrar a posição do humano, dado a diferença da direção e magnitude do fluxo óptico com o modelo do fluxo óptico.

O modelo de fluxo óptico foi obtido no início do processo e representou no sistema o plano de fundo da imagem. O cálculo de distância Euclidiana também foi realizado entre as regiões encontradas para aumentar a eficiência do processo, uma vez que as áreas de interesse podem sofrer ruídos do ambiente. Por visão estereoscópica foi possível mensurar a distância que os humanos estavam do veículo. Nos experimentos, o sistema conseguiu detectar humanos a uma distância de 4 a 11 metros. Com auxílio de um GPS, foi possível levantar que a taxa de erro para as distâncias encontradas entre os humanos do cenário e o equipamento foi menor que 50 centímetros. A Figura 3.4(a) mostra a alocação de cada dispositivo no veículo, sendo o sistema de visão e as antenas GPS para validar a acurácia da distância obtida, e na Figura 3.4(b) tem-se uma imagem retirada com o veículo em movimento, com os cálculos obtidos pelo sistema.

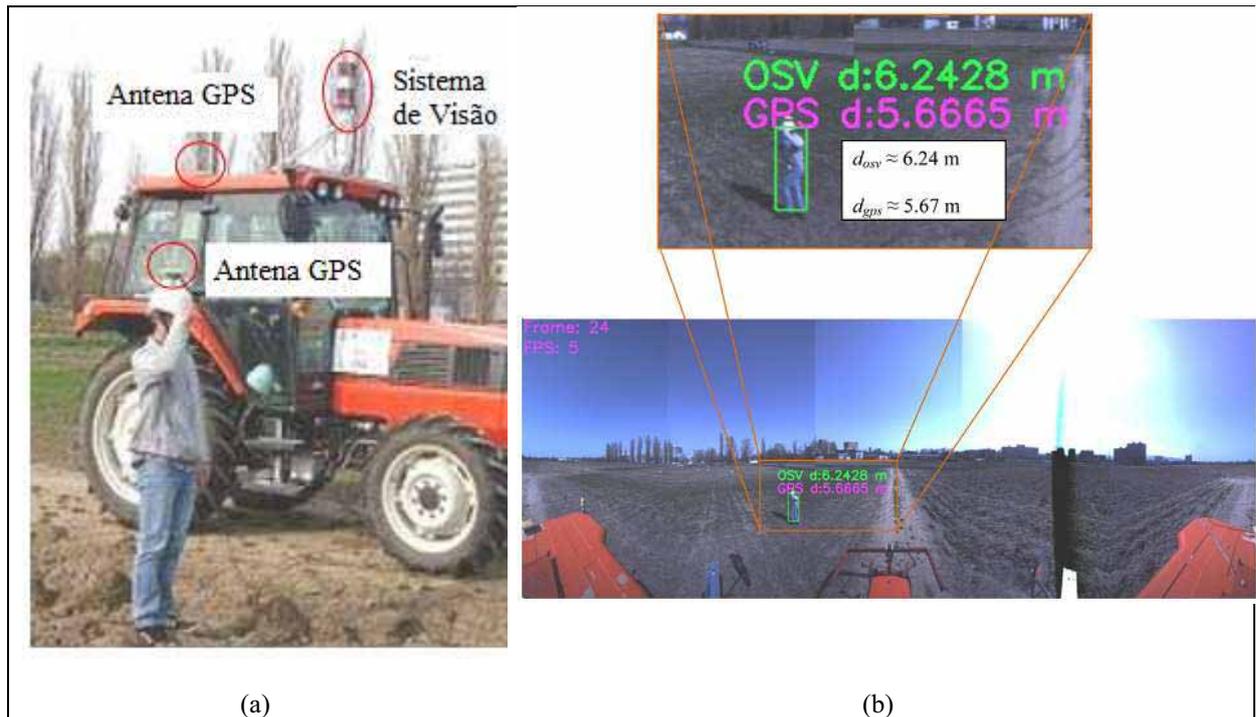


Figura 3.4 – Alocação do sistema omnidirecional no veículo (a) e cálculos de distância obtidos pelo sistema durante a navegação do veículo (b). Fonte: Adaptado de Yang e Noguchi, 2012.

Lulio, Tronco e Porto (2010) apresentou uma solução para problemas de navegação de trajetória e localização na robótica móvel agrícola. Foi utilizado o algoritmo JSEG (DENG; MANJUNATH; SHIN, 1999) para segmentação das imagens em conjunto com um *perceptron* multicamadas (MLP), para classificar regiões da imagens nas seguintes classes: área navegável, área de plantação e céu. O vetor de características foi formado de acordo com as cores dos canais representados no histograma. O MLP foi implementado através de um algoritmo para *back-propagation* customizado, o iRPROP (IGEL; HÜSKEN, 2003), sendo rápido e eficiente para classificar texturas complexa. As imagens foram classificadas no espaço HSV representando histograma de 256 categorias. Assim, foi possível realizar testes com 32, 64, 128 e 256 neurônios na camada invisível de treinamento para os canais H, HS e HSV da imagem. Assim, os resultados foram obtidos comparando as taxas de erros resultantes de cada classe em relação a quantidade de neurônios utilizados.

Para auxiliar na validação dos resultados, foram implementados dois classificadores probabilísticos: Bayes Convencional e Bayes Ingênuo. Também foi utilizado o espaço de cores RGB para averiguação da quantidade de dimensões nos vetores de características com os utilizados pelo espaço de cores HSV. Comparando as taxas de acerto obtidas com as dimensões utilizadas nos dois espaços de cores, o classificador Bayes Convencional no espaço HSV teve acurácia maior que os outros classificadores. Como conclusão, os autores verificaram que uma estratégia modular utilizando ANN e teorema de Bayes poderia ser uma boa alternativa para a classificação de segmentos com o algoritmo JSEG.

3.1.3. Sistemas de Visão Monocular

Jiang e Zhao (2010) estudaram um método para identificar linhas de plantio em plantações de vegetação baixa. Uma câmera foi alocada sobre um robô de pequeno porte de 1 metro de altura e direcionada verticalmente em 15 graus em direção ao solo. Para alcançar o objetivo esperado, as imagens obtidas passaram por cinco passos de processamento: transformação em escala de cinza, binarização Otsu, escolha da linha de plantação, detecção de borda e transformada de Hough.

Na cultura estudada, foi possível destacar facilmente as áreas verdes dos outros elementos (céu, solo, sombras e rochas). Assim, a transformação em escala de cinza foi realizada seguindo o método 2G-R-B que permite destacar as regiões verdes na imagem original, facilitando posteriormente sua separação. A etapa de binarização foi realizada utilizando o algoritmo Otsu (1979). Esse algoritmo permite dividir a imagem em dois histogramas onde o limiar é calculado dinamicamente, a partir do cálculo de máxima variância na coloração dos *pixels*. O resultado é uma imagem dividida em duas classes onde a classe clara representa a cultura estudada e a classe escura o resto da imagem. Como o robô móvel precisa apenas de uma linha de plantação para navegar corretamente, um método de projeção vertical foi utilizado para selecionar a melhor linha para navegação. Após a etapa de seleção, uma detecção de borda foi utilizada para obter o contorno. Apenas a borda de um lado da linha de plantio foi obtida para otimizar o processo da etapa seguinte. Assim, a transformada de Hough (DUDA; HART, 1972) foi aplicada. O resultado desse processo é um desenho de trajetória que pode ser utilizado para locomoção do robô móvel.

Ortiz e Olivares (2006) apresentou um trabalho cujas técnicas computacionais são bastante similares às utilizadas por Jiang e Zhao (2010). Os autores sugeriram a utilização de uma câmera como principal sensor para navegação de um robô móvel em um cenário natural. A imagem RGB capturada pela câmera foi processada com um algoritmo de balanceamento de branco, conforme a Figura 3.5(a). Após, uma imagem em escala de cinza foi gerada enaltecendo o teor de verde da imagem, processo esse realizado pelo método “ $(G-R)+(G-B)$ ”, conforme a Figura 3.5(b). Nesse método, quanto mais próximo de branco é o valor do pixel da imagem resultante, maior será o teor de verde do pixel. O processo de segmentação foi finalizado com um *threshold* especificado pelo usuário, conforme a figura 3.5(c). Para aprimorar o resultado obtido pelo *threshold* foi necessário procurar áreas de pequenas segmentos que possam prejudicar o processo de determinação do caminho navegável. Para isso, uma rotina de verificação de *pixels* correspondentes foi executada e, caso a quantidade de *pixels* consecutivos fosse inferior a um limiar pré-definido, o grupo em questão era eliminado, permanecendo na imagem apenas grandes segmentos, como demonstrado na Figura 3.5 (d). Para determinar o caminho, os autores criaram um algoritmo que, partindo do ponto central da última linha de *pixels* da imagem, procurava-se os primeiros *pixels* da classe oposta presentes na esquerda e também na direita do ponto de referência.

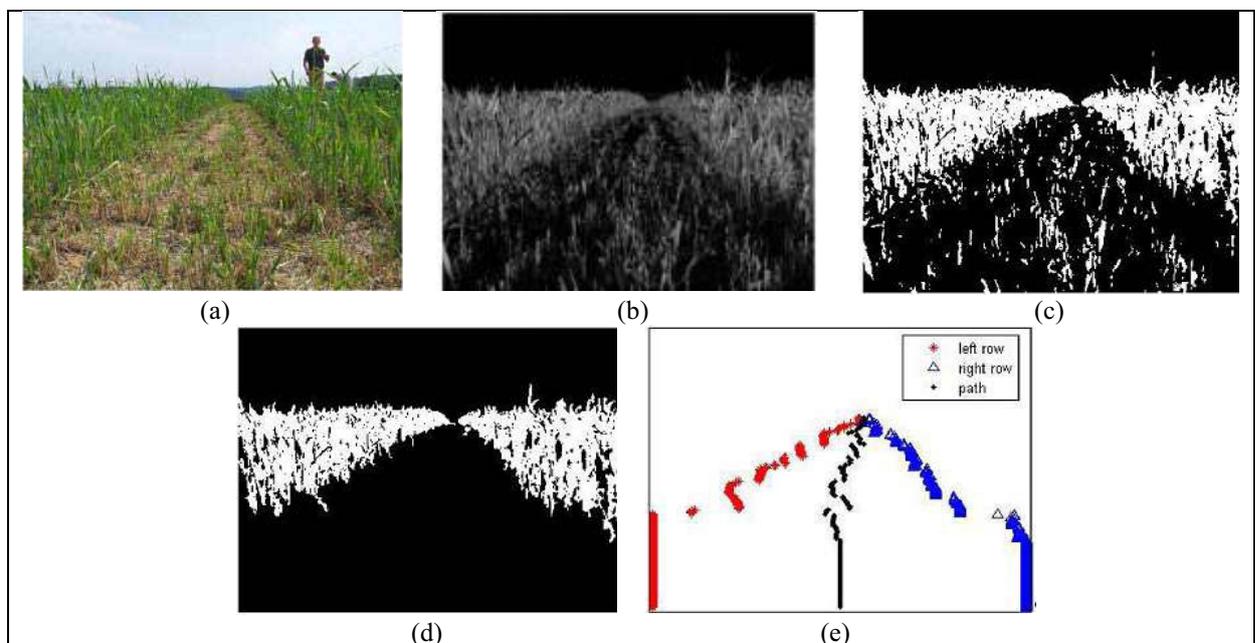


Figura 3.5 – Imagem original (a), transformação do espaço de cores (b), Otsu Thresholding (c), aprimoramento dos resultados (d) e cálculo do caminho navegável (e)
Fonte: Ortiz e Olivares (2006).

Assim que os pontos representando as bordas do caminho foram encontradas, a coordenada do ponto central foi atualizada e validada como uma coordenada do caminho. O mesmo processo foi realizado nas linhas acima. Ao final do processo, conforme ilustrado na Figura 3.5(e), foi possível encontrar pontos de navegação para o robô móvel. Os autores descreveram também o funcionamento do sistema de controle e o mecanismo de esterçamento do robô.

Xue, Zhang e Grift (2012) também apresentou uma solução para guiagem precisa de robôs agrícolas autônomos. O sistema de visão utilizado possuía um campo de visão variável, uma vez que a visão de longe propiciava uma clara segmentação das plantas em contraste com o solo. Por sua vez, a visão de perto auxiliava a captura da imagens de plantas que na visão de longe não existia clara definição. Quando o número de *pixels* na visão de longe era menor que um determinado limiar, a máquina trocava sua configuração para a visão de perto, tentando melhorar a eficiência da segmentação. Quando o número de *pixels* na visão de perto era menor que outro limiar, o sistema guinava a câmera para a direção lateral, pois a linha para navegação estava próxima do fim.

O primeiro passo para determinar a linha guia foi distinguir as plantas verdes do solo, processo feito por um algoritmo de segmentação de cor. Com a imagem binarizada, uma operação morfológica de abertura foi utilizada para determinar as duas margens e o ponto central da rua de plantação. Conforme já mencionado, ao final da linha de plantio a câmera é guinada para a lateral, onde apenas uma margem era registrada na imagem. Nesse modo, a própria margem serve de orientação para o robô, ao invés do ponto central. A Figura 3.6 ilustra o processamento do sistema para uma imagem obtida no modo longe da câmera.

No trabalho de Jiang et al. (2013) foi apresentado um sistema para guiagem de um robô autônomo em cenários naturais com elementos bem definidos. Ao capturar a imagem pelo sistema de visão, o método Otsu Threshold (OTSU, 1979) foi processado nos canais RGB, gerando uma imagem binária. Após a segmentação, uma abertura morfológica seguida por um fechamento foram executados para eliminar ruídos e pequenas regiões presentes na imagem.

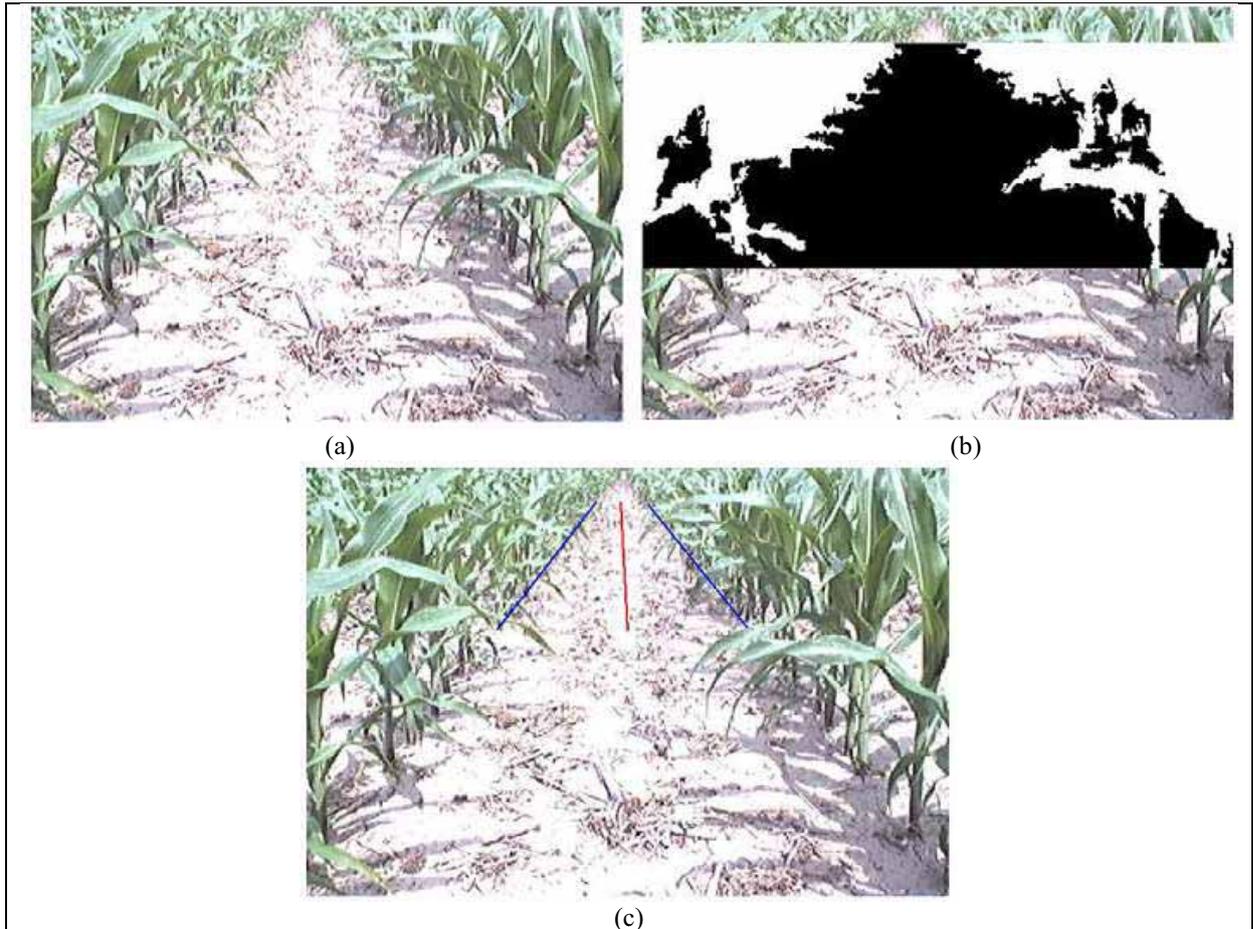


Figura 3.6 – Imagem original (a), binarização (b), cálculo das extremidades das linhas de plantio (c) Fonte: Xue, Zhang e Grift, 2012.

Para determinar a linha de navegação do robô, realizou-se uma varredura dos *pixels* da direita para a esquerda linha por linha. Ao encontrar as arestas de cada extremidade, foi possível definir um ponto central por linha. Como nem sempre os pontos centrais formam um caminho bem definido para ser aproveitado na navegação, esses pontos discretos foram registrados e o método de mínimos quadrados foi utilizado para definir a linha guia. Os erros máximos computados foram de 14,9mm quando a visão estava no modo longe, 15,8mm no modo perto e 13,9mm no modo lateral. A média de erros máxima não passou de 3,9mm para ambas os modos, sendo 1mm a menor para o modo longe.

Na Figura 3.7 é possível verificar os resultados obtidos após cada etapa de processamento: na Figura 3.7 (a), a imagem original adquirida em escala de cinza; na Figura 3.7 (b), o resultado obtido pelo Otsu Threshold; na Figura 3.7 (c), a eliminação de ruídos causados pela performance das operações de abertura e fechamento morfológicas; na Figura 3.7 (d), o cálculo do caminho para navegação.

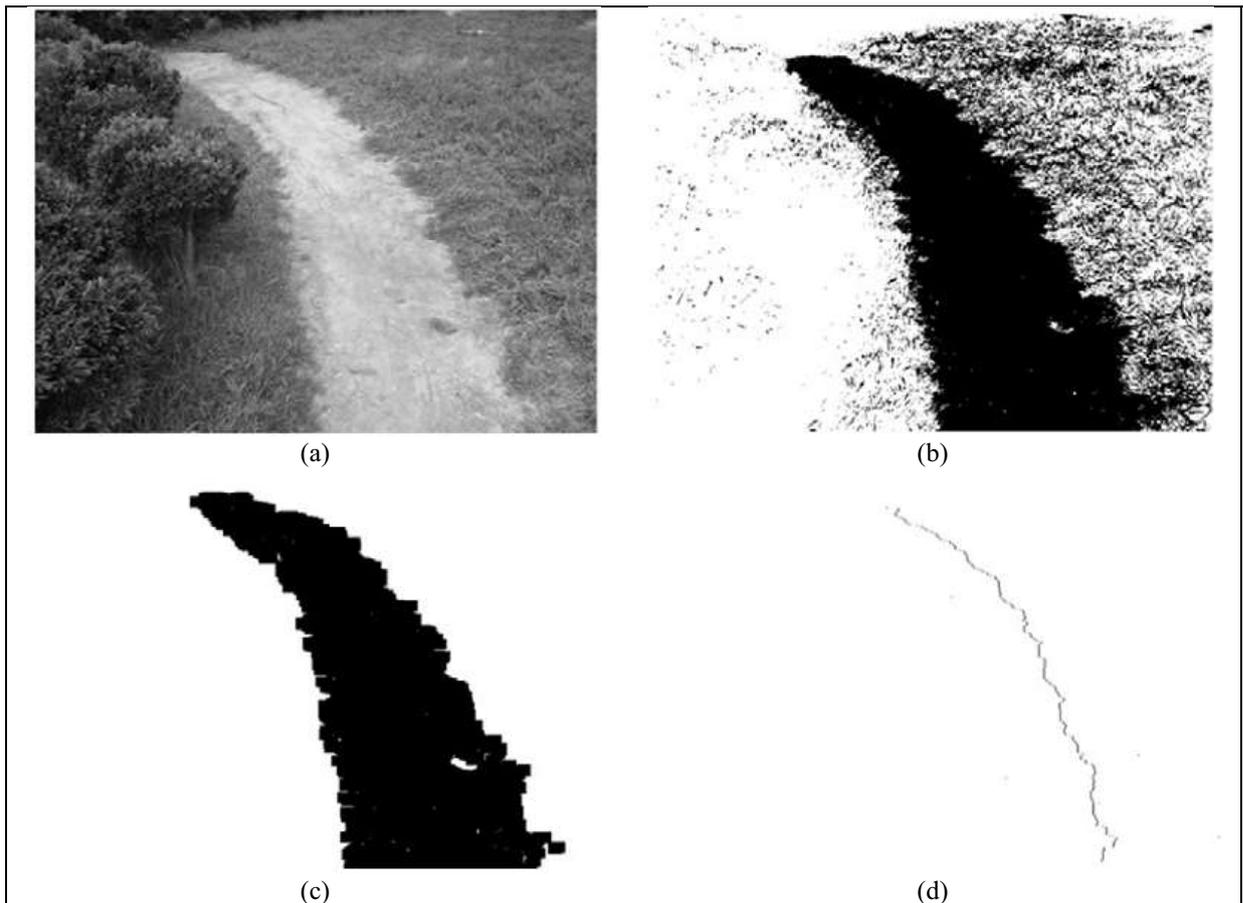


Figura 3.7 – Imagem original em escala de cinza (a), binarização (b), execução das operações morfológicas (c) linhas central da área resultante (d)

Fonte: Jiang et al., 2013.

Bakker et al. (2008) apresentou um sistema de navegação utilizando visão monocular para reconhecimento de linhas de plantio. A câmera foi alocada em um robô com distância de 1,74 metros sobre o solo. Inclinação a 40 graus, foi possível enquadrar na imagem 3 linhas de plantação completas. As imagens originalmente coloridas foram convertidas em preto e branco e notou-se diferença no contraste entre as áreas de plantas e solo. Nas imagens transformadas em tons de cinza criam-se três sessões onde cada uma delas foram combinadas em uma nova imagem, diminuindo assim o número de dados a serem processados. A transformada de Hough (DUDA; HART, 1972) foi implementada para verificar as regiões em vários estágios de crescimento, independente método utilizado para a transformação de cores. Os resultados apresentaram erros entre 5mm a 198mm. Nesses resultados, as imagens possuíam elementos não pertencentes a cultura em questão, como super exposição da câmera, presença de algas verdes em estufas, entre outras. No grupo de imagens que não possuíam esses elementos, as linhas de plantio foram processadas com erro médio entre 5mm e 11mm, desvio padrão de 6mm e 11mm.

Zhang et al. (2012) apresentou um sistema utilizando navegação monocular para navegação de um robô autônomo em pomares. A câmera foi alocada no centro do veículo orientada em direção ao solo, de modo que fosse possível capturar a rua e as duas linhas opostas formada pelos pomares. Após encontrar a relação que define a estimativa de orientação pelo robô, calculo esse efetuado sobre a relação geométrica do centro focal da câmera com o modelo de guiagem assumido pelo robô, tornou-se necessário encontrar as características na imagem adquirida que implicam nos elementos alvo. Uma máscara foi aplicada na imagem destacando apenas a regiões de interesse para o problema. Após, o filtro Sobel (GONZALES; WOODS, 2007) foi aplicado na região de interesse, atenuando as bordas verticais.

Um *threshold* foi utilizado para eliminar arestas com valores menores que um limiar pré-definido. Alguns pontos do conjunto restante foram selecionados randomicamente para serem rastreados pelo algoritmo Lucas-Kanade (LUCAS; KANADE, 1981). A cada 15 *frames* foram armazenadas 300 características analisadas (20 características por *frame*). Essas características são utilizadas por um algoritmo RANSAC (FISCHLER; BOLLES, 1981) para cálculo de guiagem do robô, desvio e ângulo de rotação. Utilizando um algoritmo adaptado para o problema proposto, com o conjunto de pontos armazenados foi possível calcular as duas linhas de pomares que compõe o cenário de navegação. Uma linha central também pode ser definida com as referências dessas duas linhas.

Para detecção de *vanishing points* ou ruídos, foi realizada uma análise por *frame*. Os *vanishing points* representam o final da linha dos pomares e correspondem a pontos de fuga presentes em uma imagem de perfil perspectivo. No caso, os pontos de fuga da imagem representam o final das duas linhas de pomares que formam o corredor em que o robô deve navegar. Intuitivamente, a abordagem mede a altura das árvores por contagem das bordas verticais sobre os troncos das árvores e galhos, analisando o ponto onde as linhas de árvores desaparecem. Similarmente ao método anterior, um filtro Sobel foi aplicado para destacar as bordas e um *threshold* permite selecionar apenas pontos com valores maiores que um determinado limiar. Nos pontos selecionados um filtro de cor foi aplicado, eliminando pontos pertencentes a grama ou folha das árvores. O experimento obteve sucesso em cenários com diferentes condições de iluminação e configurações de ambiente. Na Figura 3.8(a) a área demarcada pela linha amarela representa a região de interesse, os pontos vermelhos representam as características que foram rastreadas e os segmentos azuis representam a movimentação desses pontos calculada pelo algoritmo Lucas-Kanade. Na Figura 3.8(b) as linhas representam arestas verticais extraídas da região de interesse, simbolizando os troncos das árvores.

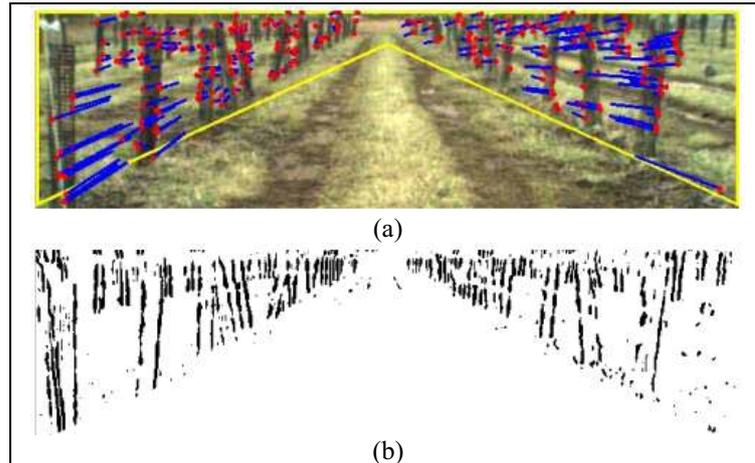


Figura 3.8 – Pontos de rastreamento encontrados na área de interesse (a), arestas verticais simbolizando elementos na imagem (b)
Fonte: Zhang et al., 2012

3.2. Considerações do Capítulo

Nesse capítulo foram apresentados alguns trabalhos sobre Sistemas de Visão Omnidirecional, Sistemas de Visão Omnidirecional para cenários naturais e Sistema de Visão Monocular para cenários naturais. Nesses trabalhos foi possível encontrar a utilização de diversas técnicas de visão computacional, além de detalhes sobre a construção dos equipamentos utilizados. Vale destacar que a utilização dos sistemas omnidirecionais na agricultura é pouco explorado nos dias atuais, então coube nesse capítulo a apresentação de alguns trabalhos em ambientes fechados, onde é possível encontrar trabalhos desde o final da década de 90. Os trabalhos apresentados referentes aos sistemas de visão monocular na agricultura, com âmbito em atividades de navegação, serviram para destacar algumas técnicas utilizadas para encontrar regiões em cenários agrícolas e traçar um caminho a ser explorado na apresentação da metodologia do proposta.

4. METODOLOGIA PROPOSTA

Nesse capítulo serão apresentadas as ferramentas e técnicas que compõem a metodologia do trabalho.

4.1. Introdução

A solução proposta buscou proporcionar uma arquitetura modular de segmentação de imagens onde a imagem, originalmente adquirida por um sistema de visão omnidirecional catadióptrico, é separada em regiões significativas que facilitem o desenvolvimento de aplicações específicas direcionadas à Agricultura de Precisão (AP). A AP pode ser conceituada como um conjunto de técnicas e tecnologias utilizadas na otimização de sistemas de produção agrícolas, tendo como elemento chave o gerenciamento da variabilidade espacial da produção e dos fatores nela envolvidos (MOLIN, 2004; SWINTON; LOWENBERG-DEBOER, 1998).

Em outras palavras, nesse trabalho pretendeu-se realizar um levantamento de regiões que compõem um cenário natural agrícola e utilizar as informações resultantes desse processo como auxílio para diversas aplicações dentro da área da robótica móvel agrícola, desde navegação de robôs móveis até tarefas relacionadas com mapeamento de ambientes e estimativas de produção. Cada imagem resultante está relacionada à visão de um lado do veículo, sendo quatro imagens no total (visão frontal, visão traseira, lateral esquerda e lateral direita).

Além do funcionamento de cada etapa do sistema de visão bem como suas características, torna-se importante analisar alguns tipos de aplicações que esse sistema de visão pode auxiliar:

- **Busca por novas rotas de navegação:** A navegação frontal pode levar o veículo a rotas incompletas ou situações que impeçam uma trajetória segura. Encontrar novos caminhos para navegação é uma tarefa importante pois eleva o grau de autonomia do veículo, uma vez que a visão frontal possui um ângulo de visão limitado do ambiente;

- **Manobras complexas:** A visão omnidirecional pode auxiliar a realização de manobras complexas como, por exemplo, inesperadas mudanças de trajetória, contorno de obstáculos ou algumas ações de esterçamento do veículo;
- **Melhorar eficácia da visão frontal:** Os ambientes agrícolas são totalmente desestruturados e existem inúmeros eventos que não podem ser previstos ou controlados. Em muitos momentos a visão frontal pode apresentar falhas, como no reconhecimento de obstáculos em rotas que são possíveis de serem navegadas. Nessas e em outras ocasiões, a visão omnidirecional pode auxiliar nas ações tomadas pelo veículo;
- **Estimativa de produção:** Em algumas culturas é possível estimar a produção através da medida de área que as regiões relacionadas estão presentes na imagem. Com um amplo campo de visão é possível obter uma maior quantidade de informações que melhoram a eficiência do sistema e tornam a estimativa mais precisa.

4.2. Considerações sobre o projeto

Como foi apresentado na Introdução, esse trabalho pertence ao módulo de Visão Computacional do projeto AgriBOT.

O módulo de Visão Computacional permite fornecer informações para os módulos de navegação e localização da plataforma, onde este é composto de diversos sensores como RTK-GPS, sensores inerciais e lasers de ambiente. As imagens capturadas são utilizadas para fins de navegação e de obtenção de informações sobre as culturas. O agriBOT tem como enfoque de análise as culturas de cana, milho e laranja.

Como o sistema de visão tem como objetivo a captura de informações distantes do veículo, as informações capturadas permitem aumentar a eficiência em tomadas de decisões, uma vez que é possível verificar a longa distância limites de áreas navegáveis em todas as direções do veículo. Assim, as informações geradas permitem com que o veículo busque alternativas para situações pósteras, podendo até mesmo interferir na ação atual do robô.

No decorrer do projeto, foi possível identificar que esse sistema, por ser modular, era capaz de beneficiar outros sistemas presentes na Agricultura de Precisão, proporcionando informações que auxiliassem totalmente ou parcialmente na resolução dos problemas tratados. Assim, a proposta da aplicação, que antes era centralizada para o projeto AgriBOT, passou a ser direcionada para outros sistemas com características semelhantes ao projeto principal. Houve a necessidade de buscar técnicas que gerassem resultados em curto espaço de tempo, se possível em tempo real, com o objetivo de contemplar um número maior de aplicações existentes.

4.2.1. Veículos utilizados para os testes

O veículo titular para captura das informações é o AgriBOT. Existia um processo burocrático interno da faculdade que precisava ser cumprido para que alunos e pesquisadores pudessem trabalhar no veículo. Além disso, o AgriBOT era guardado na Embrapa em São Carlos/SP, e a locomoção até o local, além dos protocolos exigidos para manejo do equipamento no local, dificultou o andamento da pesquisa. Para aumentar a agilidade da pesquisa, optou-se por utilizar de forma paralela um quadriciclo, de propriedade do NEPAS (Núcleo de Ensino e Pesquisa em Automação e Simulação da Escola de Engenharia de São Carlos da Universidade de São Paulo) para fins de pesquisas. O quadriciclo possui diversas características que são semelhantes ao AgriBOT e a outros veículos utilizados na agricultura, como por exemplo, o sistema de amortecimento. Além disso, esse veículo possuía mais facilidade de ser condicionado ao campo em relação ao AgriBOT. Entretanto, também existia uma burocracia envolvida com a instituição de ensino para a utilização do bem nos momentos de captura da imagem, além de um equipamento próprio de reboque para ser condicionado ao campo, o que também acabou limitando sua utilização ao longo do projeto.

Por fim, para aumentar a agilidade da pesquisa, visando também que o autor desse trabalho residia na cidade de Bauru/SP durante o projeto, foi utilizado um terceiro veículo, uma caminhonete no caso, de uso particular. Com esse veículo realizou-se as últimas capturas de imagens, nas quais várias delas são apresentadas nesse trabalho. A vantagem da utilização desse veículo é a facilidade de alocar a câmera alinhada ao centro de massa do veículo, beneficiando o campo de visão de ambos os lados do mesmo. Com relação as vibrações sofridas, apesar de terem menos intensidade do que as do quadriciclo, durante a navegação do veículo elas existem devido as irregularidades do terreno, onde possuíram intensidades suficientes para ser uma característica passível de consideração durante a captura, permitindo a fidelidade nos testes realizados nesse tipo de equipamento.

4.2.2. Suporte para o Sistema de Visão Omnidirecional

No começo do projeto, o Sistema de Visão Omnidirecional utilizado era semelhante ao utilizado por (GRASSI JR.; OKAMOTO JR., 2002), tanto na dimensão e materiais dos equipamentos utilizados, como também o invólucro de vidro. Esse suporte, antes de pertencer ao projeto, era utilizado em pesquisas do NEPAS e da Escola de Engenharia de São Carlos, e foi cedido pelo departamento de forma generosa para o desenvolvimento dessa pesquisa. A diferença, porém, estava na câmera, na qual estava sendo utilizada uma Logitech C525. O foco da câmera havia sido reajustado para manter a proporção do raio do espelho capturado na imagem, informação esta presente no trabalho de referência. Na primeira captura de imagens em ambiente natural, entretanto, o invólucro não resistiu as vibrações que o sistema de visão sofreu causadas pelo motor do veículo e irregularidades do terreno, no qual danificou o objeto prejudicando sua utilização. Os primeiros testes foram realizados utilizando o quadriciclo citado na seção 4.2.1 e seção 4.3.1.

Como a fabricação de outro invólucro do mesmo material não foi possível na circunstância desse evento, optou-se por uma solução temporária para que houvesse a continuação do projeto. Assim, um novo suporte foi construído respeitando as medidas físicas e equacionamento da câmera com o espelho do suporte anterior, porém utilizando uma haste de aço em vez do invólucro de acrílico. Essa solução respeita o equacionamento entre a câmera e o espelho do equipamento antigo, e permitiu obter imagens com maior qualidade uma vez que os materiais são mais resistentes as vibrações. O ponto negativo, entretanto, está na exposição do espelho com o ambiente, no qual não propicia aos equipamentos utilizados segurança com relação a poeira e outros elementos presentes no ambiente, e que podem vir a danificar a integridade dos aparelhos. Com o decorrer do projeto, a câmera Logitech foi substituída por uma Ximea xiQ USB 3.0 modelo MQ013CG-E2, de maior sensibilidade sensorial e taxa de aquisição de imagens, visando aumentar a qualidade das imagens obtidas. No decorrer do projeto parte da base da câmera também foi alterada com o intuito de diminuir o peso do equipamento.

O suporte utilizado para apresentação da metodologia e resultados presentes nesse trabalho foram baseados no suporte temporário. Por sua vez, a utilização de uma estrutura permanente que beneficie o campo de visão de forma completa e que também contorne algumas questões arbitrárias dos ambientes desestruturados está inserida nesse trabalho como tópico de proposta futura, na Seção 6.2, cabendo pesquisas relacionadas a outras áreas do conhecimento.

4.2.3. Captura de Imagens

A cultura agrícola escolhida para realização das coletas de imagens é a laranja. A definição dessa cultura deveu-se ao projeto AgriBOT, onde, de todas as culturas que o projeto contempla, a laranja é que apresenta características mais complexas de serem analisadas por se tratarem de árvores (pomares) e também pela disposição que normalmente são encontradas nas plantações, sendo essa em fileiras únicas de árvores para formação dos corredores das culturas.

A captura da imagem foi realizada em períodos diferentes do ano, nos meses de maio e julho de 2013, em uma fazenda particular no distrito Água Vermelha, município de São Carlos/SP, e em novembro do ano de 2013, em uma fazenda particular do município de São Manuel. Sobre as imagens demonstradas nesse capítulo, todas foram realizadas no mês de novembro, entre as fases de coleta dos frutos. Nessa fase, foi possível identificar nos pomares frutos de diferentes tamanhos e estágios de crescimento, conseqüentemente diferentes tonalidades. Além disso, todas as imagens foram registradas com o veículo em movimento, sendo esse guiado por um operador humano.

Durante as coletas, foi possível identificar cenários diferentes para esse ambiente. As diferenças de cada cenário estão nos elementos representados pelas ruas. A identificação dos cenários foi importante para entender as características do ambiente físico e aplicar o algoritmo de acordo com as necessidades encontradas em cada cenário.

Algumas ruas não possuem vegetação, como ilustrado na Figura 4.1 (a), e isso ocasiona bastante destaque entre a região das árvores e as demais regiões nas imagens.

Em outro cenário, as ruas são representadas com vegetação bastante baixa ou rala, como ilustrado na Figura 4.1 (b). Nessas regiões, existe ainda destaque entre as regiões dos pomares e o resto da imagem, porém a coloração é diferente com relação ao primeiro cenário. Normalmente essas condições estão presentes nos períodos de colheita da cultura.

No terceiro cenário, representado na Figura 4.1 (c), é possível verificar uma vegetação bem mais alta do que no segundo cenário. Essa vegetação promove dificuldade em reconhecer as delimitações de cada região da imagem, tornando o reconhecimento dos pomares e da região navegável um desafio mais complexo do que nas situações anteriores.

Por fim, o último cenário é simbolizado pela quantidade aleatória de vegetação distribuída randomicamente pelo cenário. Não é possível prever a quantidade ou localização de cada um dos elementos, tornando o cenário bastante complexo. Essa situação está representada na Figura 4.1 (d).

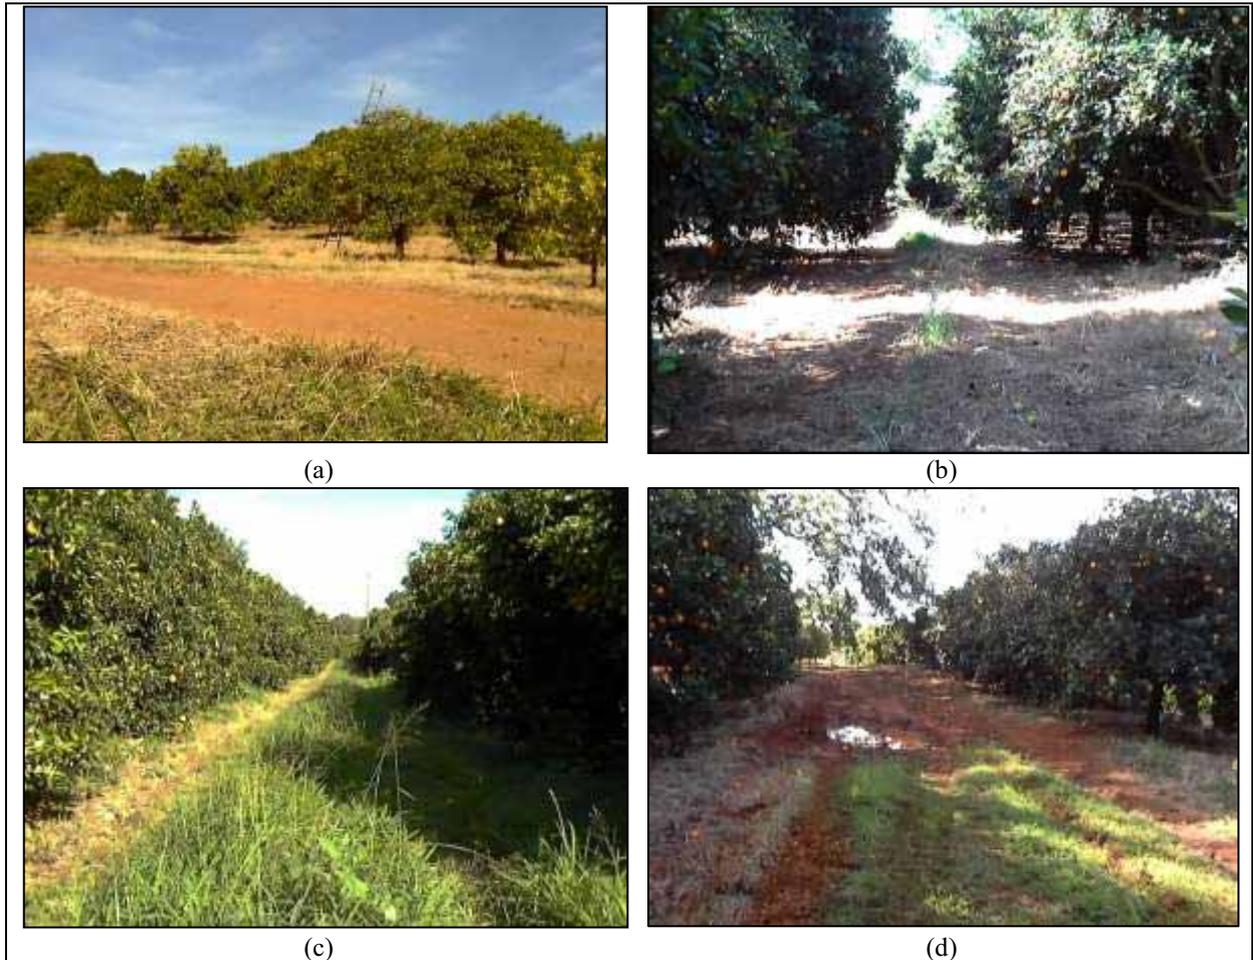


Figura 4.1 – Cenários encontrados no ambiente natural. Em (a) ruas que não possuem vegetação, em (b) ruas com vegetação baixa ou rala, em (c) ruas com vegetação alta e em (d) ruas com quantidade aleatória de vegetação

Nos testes com o suporte temporário, a haste foi alocada na frente do veículo, entretanto poderia ser utilizado qualquer posicionamento, dependendo do objetivo do sistema. A configuração escolhida permitiu analisar a eficiência das técnicas caso houvesse uma área significativa de perda de informação, como a haste do veículo. Para uma proposta de navegação, por exemplo, seria ideal posicionar a haste nos campos de visão de menor importância para o problema como, por exemplo, uma das laterais do veículo. Caso a informação de todos os quadrantes possuam importância equivalente para o problema, torna-se necessário uma verificação mais específica dessas situações na etapa de pós-processamento das imagens.

4.3. Descrição da Aplicação

Essa seção tem como objetivo detalhar o funcionamento de cada etapa do sistema, bem como justificar a importância de cada abordagem escolhida. Os softwares foram criados utilizando a linguagem C++ em conjunto com a biblioteca OpenCV na versão 2.1. Conforme Bradski e Kaehler (BRADSKI e KAEHLER, 2008), o OpenCV é uma biblioteca *open source* destinada a aplicações de Visão Computacional escrita em C e C++ criada para aplicações que exigem eficiência computacional, principalmente em aplicações de tempo real. O objetivo do OpenCV é fornecer ferramentas que auxiliem desenvolvedores na criação de soluções robustas, acelerando o processo de desenvolvimento. Na Figura 4.2 é possível encontrar uma visão geral do sistema, sendo que cada etapa será explicada nas próximas subseções.

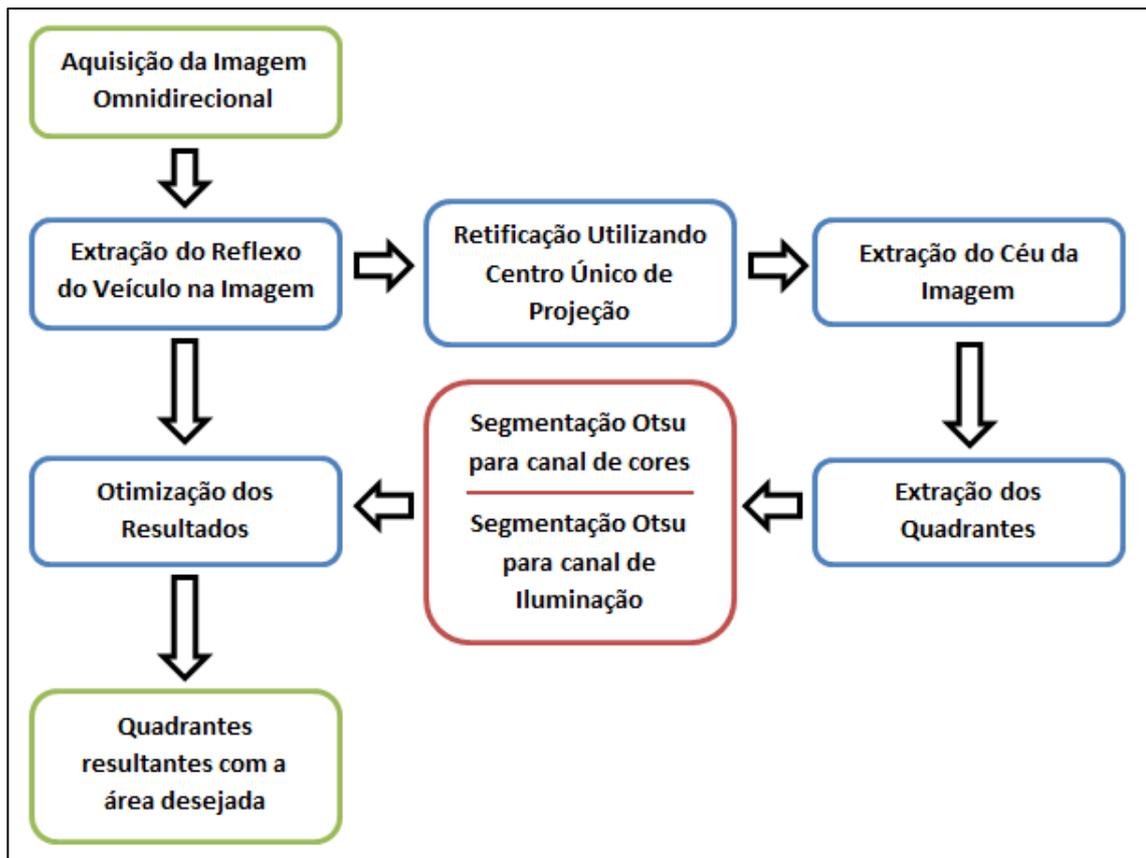


Figura 4.2 – Representação geral do sistema de visão omnidirecional proposto

Na Figura 4.2 é possível observar que a metodologia foi dividida em várias etapas. A etapa de Aquisição da Imagem Omnidirecional tem como objetivo obter imagens com boa qualidade, abstraindo particularidades encontradas no ambiente agrícola. Na etapa de extração do reflexo do veículo, é eliminada a região do veículo na imagem para aumentar a eficiência das etapas posteriores.

Na etapa de retificação utilizando Centro Único de Projeção, a etapa omnidirecional originalmente obtida é transformada em uma imagem panorâmica utilizando, no método de retificação, a propriedade de Centro Único de projeção presente no espelho hiperbólico utilizado. Após a retificação, na imagem panorâmica ocorre a extração do céu, visando aumentar a eficiência da etapa de segmentação e após é executada a extração de quadrantes, buscando extrair da imagem panorâmica quatro quadrantes onde cada um é correspondente a um lado de visão do veículo. Assim, em cada quadrante é aplicado o algoritmo de segmentação.

Dependendo da presença de verde no quadrante, o algoritmo de segmentação é aplicado em canais diferentes do espaço de cores HSV. Após a segmentação, é aplicado técnicas para otimização dos resultados obtidos, como uma máscara de detecção de caminhos e o algoritmo de limpeza de área, gerando ao final do processo os quatro quadrantes resultantes com as áreas desejadas. Detalhes de cada etapa estão presentes nas próximas seções.

4.3.1. Etapa de Aquisição de Imagens

As imagens omnidirecionais capturadas possuem resolução 640x480 e durante a coleta seu mecanismo de balanço de cores ficou ligado, porém o mecanismo de foco automático ficou desligado uma vez que a relação entre câmera e espelho não varia durante a utilização. Essa resolução foi escolhida principalmente após avaliar a latência para processamento dos algoritmos nas etapas de pós-retificação, uma vez que as imagens omnidirecionais com grandes resoluções geram imagens panorâmicas largas, tornando o processamento mais lento.

O sistema de balanço de cores e iluminação da câmera permite que as imagens tenham uma maior qualidade, uma vez que a câmera muda alguns parâmetros de ajuste da imagem de acordo com o ambiente que ela está inserida. Esse mecanismo é muito útil em ambientes agrícolas, uma vez que a iluminação possui natureza variável.

O espelho hiperbólico fornece uma boa distribuição de resolução em toda a área do espelho, além de possibilitar a criação de imagens perspectivas e panorâmicas utilizando o centro único de projeção.

Na Figura 4.3 é possível visualizar a utilização da estrutura temporária no quadriciclo e na Figura 4.4 a utilização do sistema na caminhonete. Detalhes sobre a utilização desses veículos já foram apresentados na Seção 4.2.1.



Figura 4.3 – Sistema de Visão Omnidirecional alocado no quadriciclo

4.3.2. Calibração da câmera

Durante o projeto foi necessário verificar se os centros focais da câmera e do espelho estão devidamente alinhados. Essa etapa é importante uma vez que o alinhamento garante que as vantagens proporcionadas pela retificação utilizando centro único de projeção serão mantidas.

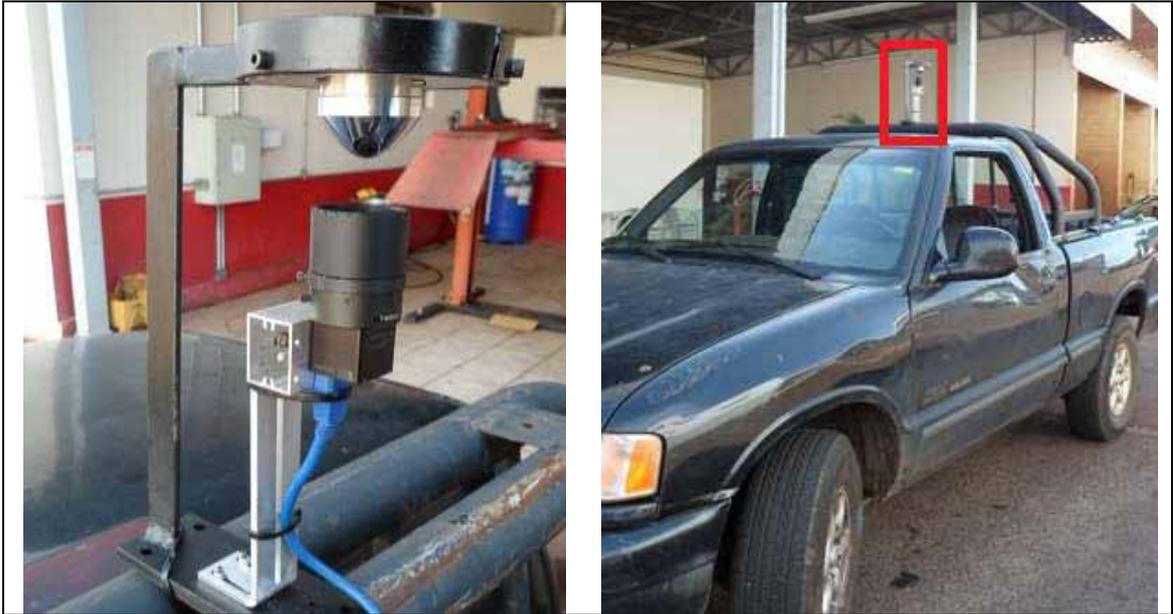


Figura 4.4 – Sistema de Visão Omnidirecional alocado na caminhonete

O método utilizado nesse trabalho é uma proposta simples e possui algumas limitações, porém foi suficiente para suprir as necessidades do escopo atual. Como não foi encontrado um tipo de segmentação própria para o sistema de visão utilizado (no caso, o suporte temporário com o espelho hiperbólico) e visando uma otimização do tempo, optou-se por utilizar uma etapa do sistema já existente no trabalho, no caso a etapa de retificação, para satisfazer essa necessidade do sistema. Assim, esse método foi criado após a implementação da etapa de retificação da imagem omnidirecional original em panorâmica e mescla o processamento dessa etapa com as estimativas de deslocamento da câmera com relação ao espelho.

O primeiro passo é capturar completamente a superfície do espelho alvo na imagem omnidirecional original. Com isso é possível observar na imagem a aresta da base circular que o espelho apresenta. Essa aresta servirá como fator avaliativo para determinar se a câmera está ou não alinhada com o espelho. Na Figura 4.5 (a) é possível observar esse processo.

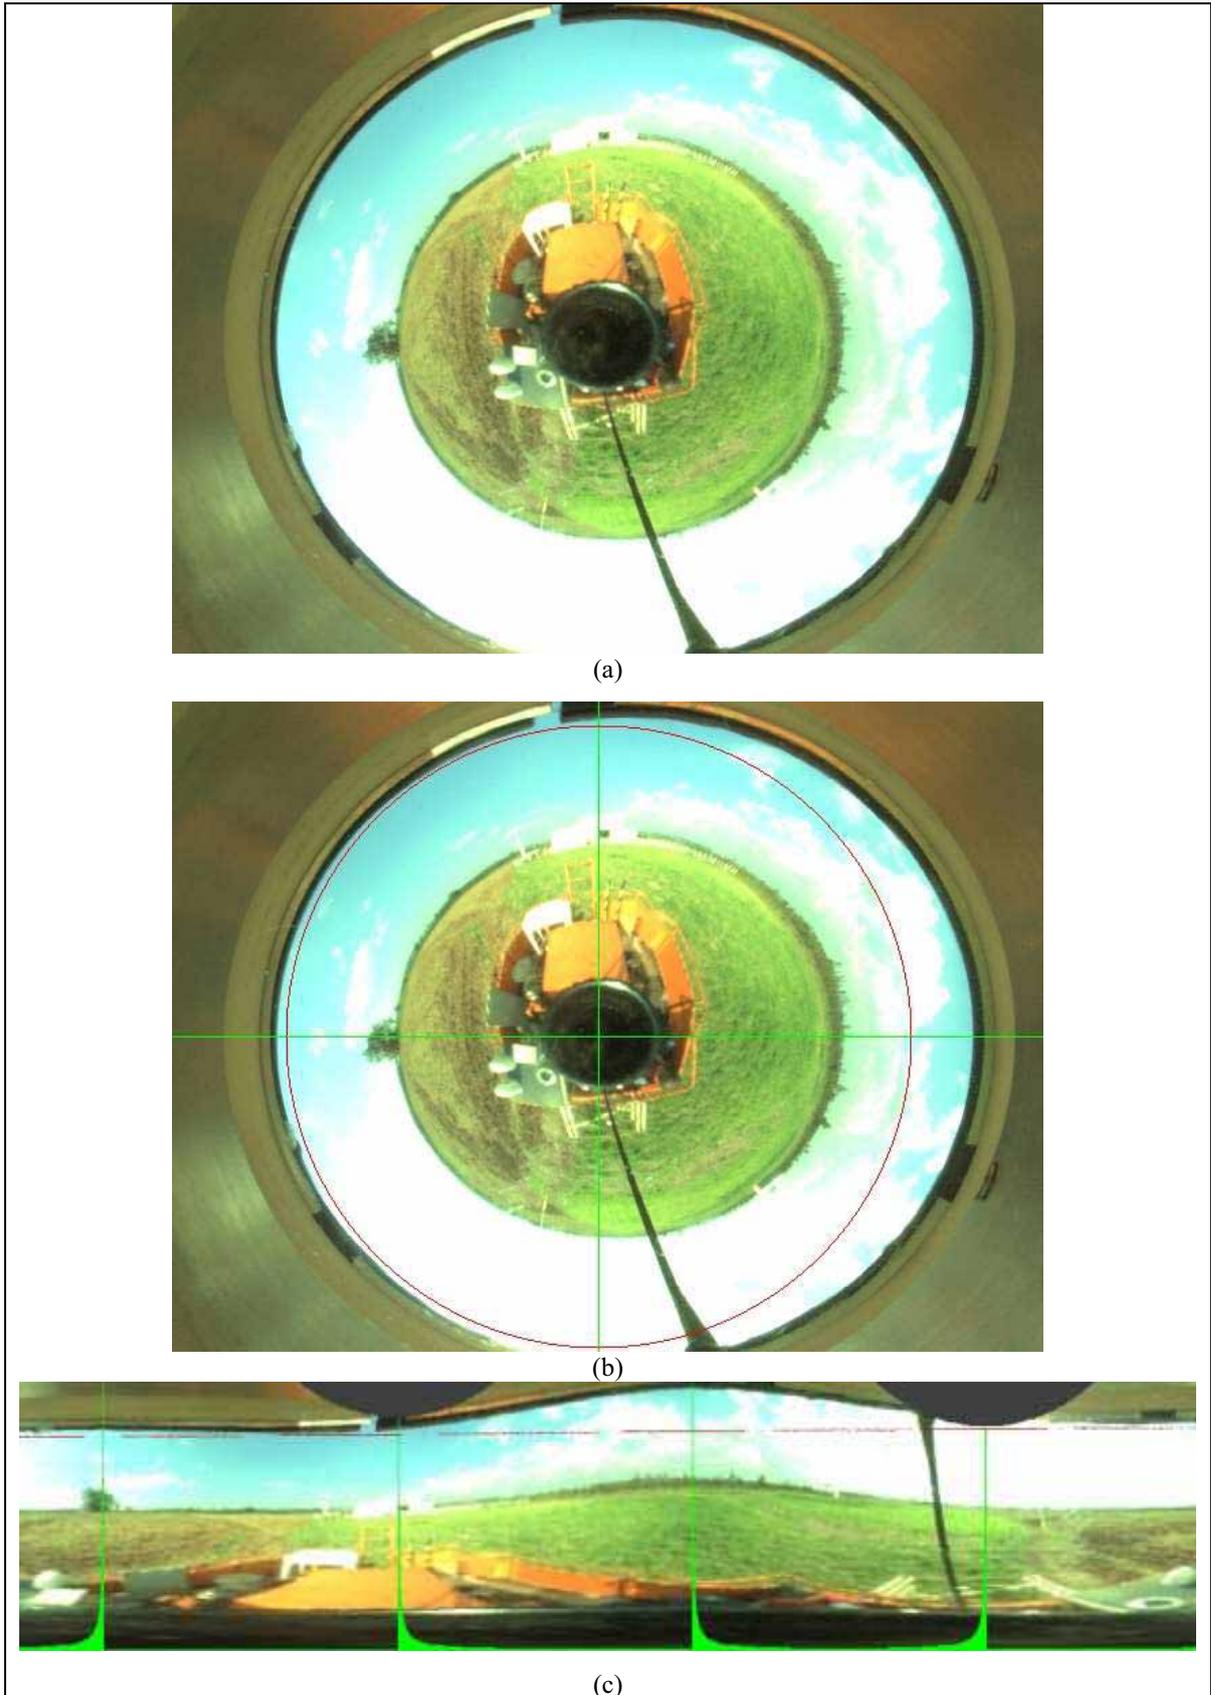


Figura 4.5 – Processo de calibração. Em (a) a imagem original obtida, em (b) as coordenadas inseridas na imagem para comparação posterior, e em (c) a aplicação do algoritmo de retificação na imagem

Uma das variáveis necessárias para efetuar o processo de retificação é a coordenada que representa o centro da imagem omnidirecional. Na imagem original, uma circunferência foi inserida tendo como coordenada central a mesma coordenada base da etapa de retificação. Essa circunferência servirá como linha guia para o processo. Após retificar a imagem omnidirecional, a linha guia deve estar apresentada como uma reta horizontal sendo paralela aos lados superior e inferior da imagem retificada. Se isso não acontecer, significa que o processo de retificação não está funcionando adequadamente. Na Figura 4.5 (b), as linhas em verde representam a coordenada de retificação (ponto central da imagem omnidirecional) e a circunferência em vermelho representa a linha guia. Na Figura 4.5 (c) é possível encontrar um resultado dessa etapa de calibração.

Após essa verificação, a linha guia serve como base para validar o alinhamento do espelho. Se o centro focal do espelho estiver alinhado corretamente com o centro focal da câmera, a imagem resultante pelo processo de retificação deve apresentar a aresta do espelho como uma linha horizontal paralela a linha guia já mencionada. Nesse caso, não é necessário realizar nenhum deslocamento para alterar a posição da câmera.

Caso a aresta se apresentar como uma curva na imagem retificada significa que os centros focais da câmera e do espelho não estão alinhados. Assim, é necessário realizar um deslocamento inverso ao eixo que a curva apresenta maior altura e em alguns casos torna-se necessário também ajustar a inclinação da câmera.

4.3.3. Etapa de Recorte das Imagens

Dependendo das dimensões do veículo utilizado e a altura que o sistema de visão é alocado em relação à plataforma do veículo, o sistema de visão pode constantemente capturar a imagem do veículo na imagem. Essa área não é interessante para o problema proposto e deve ser eliminada, uma vez que essas informações podem interferir na etapa de segmentação.

Para eliminar essa região, uma máscara de corte é ajustada para manter apenas as informações relevantes para o contexto atual. A máscara é uma imagem binária capaz de definir a região de interesse de uma determinada imagem. Assim, as técnicas de processamento serão aplicadas exclusivamente nas regiões estabelecidas. No caso desse trabalho, as máscaras são aplicadas com objetivo de deixar as técnicas de segmentação de imagens mais eficientes.

A máscara a ser definida irá depender do veículo utilizado e configurações do suporte da câmera. Na Figura 4.6 (a) e (d) é possível observar dois momentos ocorridos durante a coleta de imagens. Em (b) e (e) é possível verificar as máscaras utilizadas para excluir o veículo da imagem e em (c) e (f) os resultados obtidos no final dessa etapa de processamento.

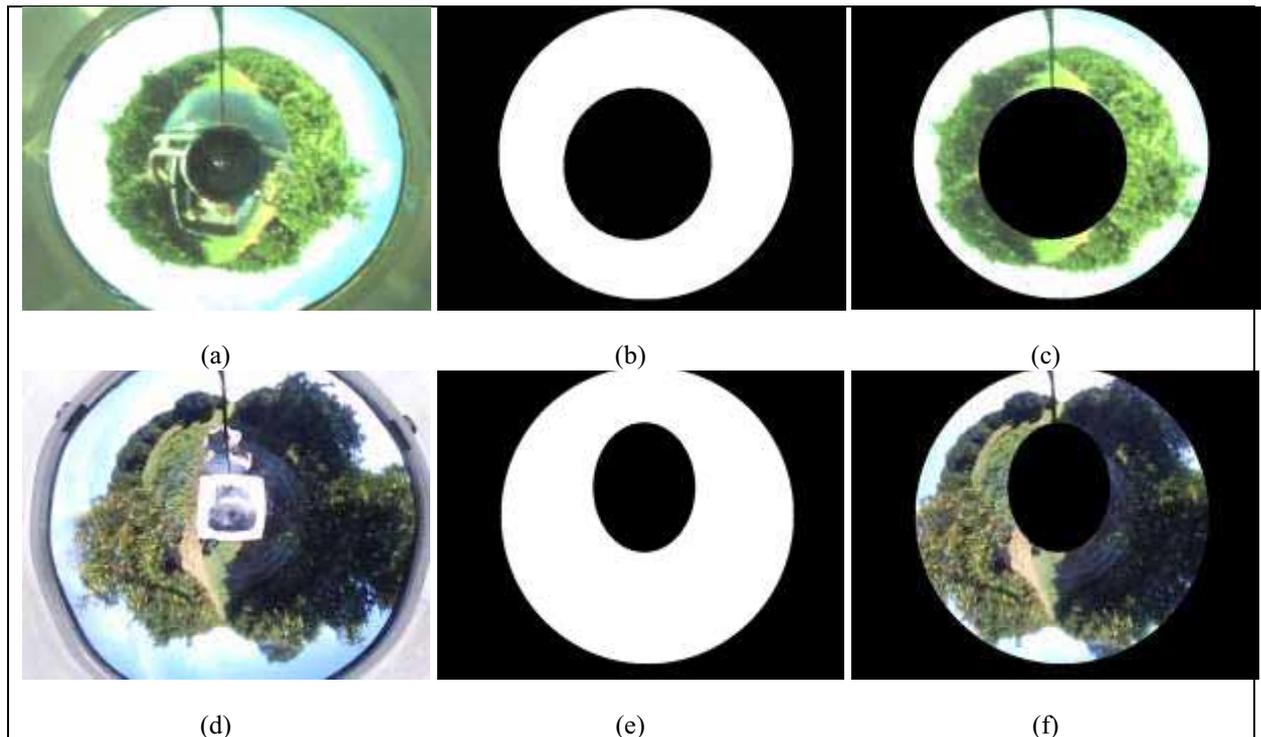


Figura 4.6 – Exemplos da máscara para extração da área do veículo. Em (a) e (d) é possível observar dois momentos de diferentes coletas, em (b) e (e) as máscaras utilizadas para eliminar a região do veículo, em (c) e (f) a aplicação das máscaras

4.3.4. Etapa de Retificação das Imagens

A retificação utilizando Centro Único de Projeção (CUP) consiste na criação de imagens panorâmicas a partir das imagens omnidirecionais. Para isso, o algoritmo tem como base a coordenada central da imagem omnidirecional e o raio de retificação.

Algumas outras variáveis associadas à relação entre câmera e espelho também são necessárias, como o tamanho do cilindro de projeção e a coordenada inicial do espelho mapeada na imagem panorâmica. Essa última informação permite o deslocamento horizontal da imagem gerada pelo processo, sendo utilizada para extrair corretamente os quadrantes da imagem na etapa de extração de quadrantes.

A técnica de Centro Único de Projeção foi implementada com base no trabalho de Grassi Jr e Okamoto Jr. (2007). A criação de *lookup tables* também foi implementada, com vetores multidimensionais, na tentativa de gerar as imagens panorâmicas mais rapidamente, devido ao fato do cálculo das coordenadas ser executado apenas uma vez durante toda a aplicação.

Na Figura 4.7 é possível verificar resultados da etapa de retificação.

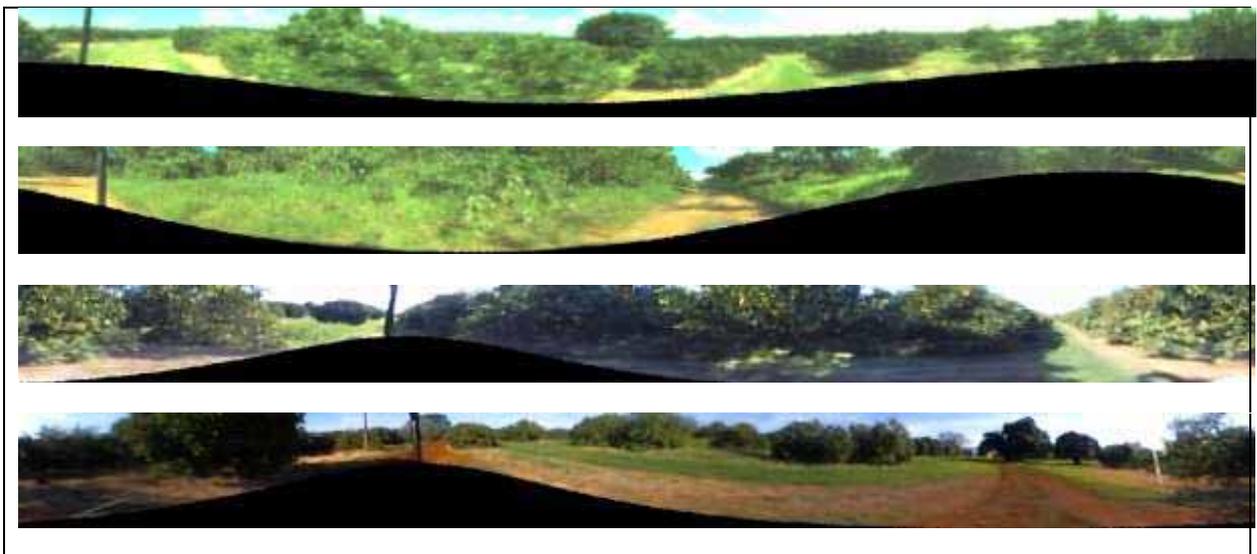


Figura 4.7 – Exemplos de retificação da imagem omnidirecional

4.3.5. Etapa de Extração do Céu das Imagens

Semelhantemente a etapa para retirar o veículo da imagem, a região que representa o céu na imagem também pode interferir no processo de segmentação e não é importante para o sistema. Para retirar essa região, dois *thresholdings* em espaço HSV foram realizados.

O primeiro *thresholding* busca identificar na imagem a área azul que representa o céu. O problema é que muitas vezes o céu possui bastantes nuvens, e por isso essa técnica sozinha não é eficaz. Para retirar as nuvens, precisamos realizar um novo *thresholding* e depois juntar o resultado de ambos. Um outro problema é que a técnica para retirar as nuvens utilizada pode identificar outras regiões quando o veículo está navegando em ruas formadas por areia ou outros materiais próximos a cor branca. Por esse motivo essas duas técnicas são aplicadas apenas na região de interesse, sendo essa a metade superior da imagem.

No primeiro *thresholding*, os limiares encontrados para segmentar a região azul do céu foram: mínimo de 150° e máximo de 270° para o canal *Hue* e mínimo de 110 e máximo de 255 para o canal *Value*. O canal *Value* precisou ser verificado nessa técnica porque algumas imagens apresentaram regiões pretas na representação de árvores que ficaram distantes do veículo e, como se sabe, as regiões pretas podem ser demonstradas no espaço de cores HSV para qualquer valor no canal Hue desde que o valor do canal Value esteja próximo a 0 (zero).

Já no segundo *thresholding*, os valores utilizados foram mínimo de 0 e máximo de 20 para o canal *Saturation* e mínimo de 240 e máximo de 255 para o canal *Value*. No segundo *thresholding* o canal *Hue* não é verificado pois no sistema de cores utilizado a cor branca pode ser demonstrada para qualquer valor possível desse canal, do mesmo modo das regiões pretas.

Na Figura 4.8 (a) está ilustrada a imagem resultante da etapa anterior, em (b) a área da imagem atingida pelo primeiro *thresholding*, em (c) a área da imagem atingida pelo segundo *thresholding* e em (d) o resultado final dessa etapa.

4.3.6. Etapa de Extração de Quadrantes das Imagens

A extração de quadrantes visa separar a imagem panorâmica em quatro partes, onde cada uma corresponde a um lado da visão do veículo.

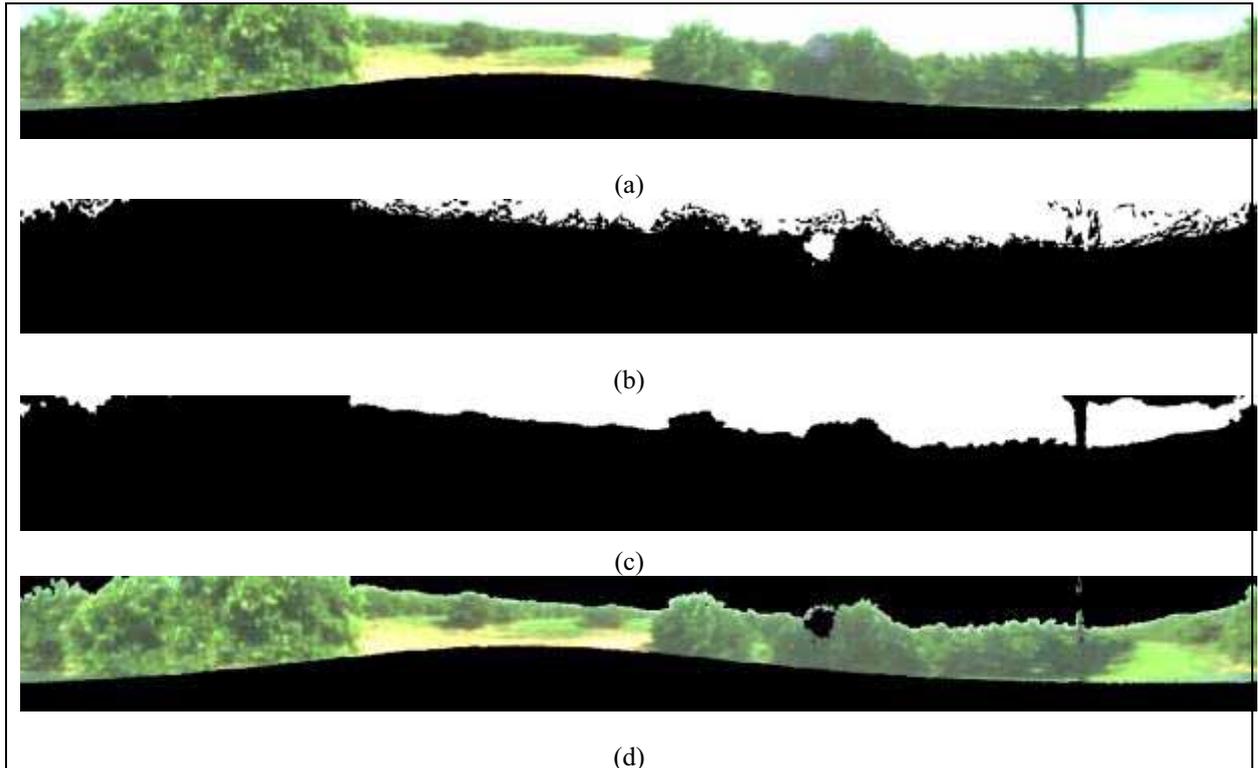


Figura 4.8 – Etapa de Extração do céu da imagem, sendo em (a) uma imagem retificada, em (b) o resultado do primeiro *threshold* para extração da área azul, em (c) o resultado do segundo *threshold* para extração da área branca, e em (d) o resultado final da etapa.

Quando se navega por cenários naturais totalmente desestruturados, como é o caso desse projeto, mesmo que o veículo esteja localizado no centro de uma rua para navegação, a imagem frequentemente contém informações de diferentes colorações de plantas e solos. Quando o veículo estiver no final de uma linha de navegação, a imagem capturada pode conter informações de várias outras ruas, árvores de vários tipos, sombras e mudança repentina da coloração do terreno. O isolamento da visão de cada lado do veículo em imagens separadas pode ser uma abordagem interessante, uma vez que o algoritmo de segmentação se baseará apenas nas informações próximas e é possível assim avaliar um limiar para cada tipo de cenário ou visão. Assim, essa abordagem visa melhorar a eficiência da etapa de segmentação.

No sistema é possível relacionar cada quadrante com uma visão correspondente no veículo. Na Figura 4.9, é possível observar a imagem original e cada visão correspondente extraída da imagem retificada.

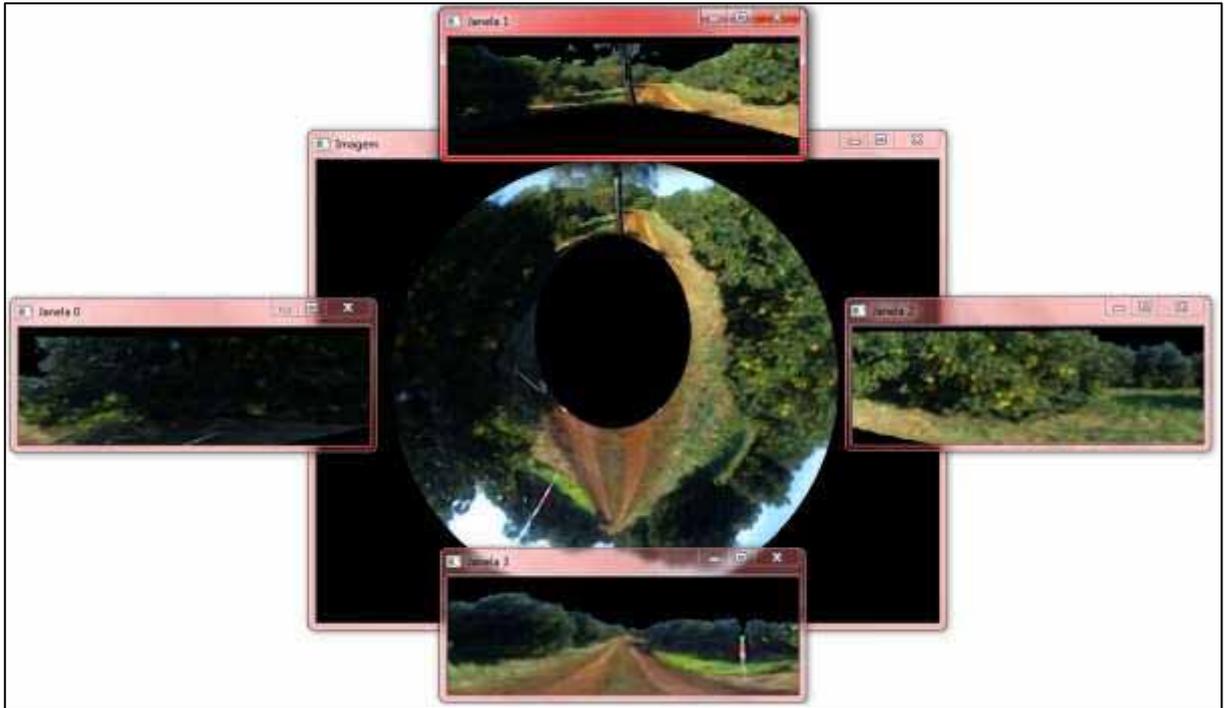


Figura 4.9 – Extração de Quadrantes da Imagem

4.3.7. Etapa de Verificação de Regiões Verdes nas Imagens

Após extrair os quadrantes da imagem panorâmica, é necessário verificar qual a melhor técnica a ser utilizada em cada quadrante da imagem para que a etapa de segmentação possa ter sucesso.

O critério estabelecido para essa etapa é a verificação da participação de *pixels* verdes na região válida da imagem. Caso a participação for menor que 80%, um *threshold* simples em espaço HSV será executado utilizando o algoritmo *Otsu Threshold Adaptado*. Esse algoritmo será apresentado nas próximas seções. Se a participação de verde for maior que 80%, será aplicada uma outra técnica de segmentação por cor em espaço HSV. O *Otsu Threshold Adaptado* também é utilizado nesse processo, porém de maneira diferente à anterior. As duas aplicações do algoritmo de segmentação são descritos na sessão 4.3.8.1 e 4.3.8.2. A justificativa da utilização dessa porcentagem é parte dos resultados desse trabalho e está descrita na seção 5.2.

Para encontrar a participação dos *pixels* verdes na imagem, os canais do espaço de cores HSV foram utilizados. A condição estabelecida para esse processo é o cálculo da porcentagem de *pixels* da imagem que pertencem ao intervalo de 90° à 150° no canal *Hue* e valor mínimo de 50 e máximo de 255 no canal *Value*. O canal *Value* foi utilizado como filtro desse processo para não abranger regiões de *pixels* pretos. Os limites estabelecidos buscam selecionar apenas a região da imagem que pertencem aos *pixels* verdes.

4.3.8. Método Otsu *Thresholding*

O princípio básico do método Otsu (OTSU, 1979) é encontrar o melhor valor de limiar para dividir um histograma de uma imagem em escala de cinza em duas partes. A condição para calcular o limiar é encontrar o maior grau de variância entre grupos de *pixels*. O *Otsu Thresholding* é uma técnica muito utilizada em imagens de cenários naturais por causa da sua eficiência quando se é avaliado uniformidade e medidas das regiões resultantes (referências).

No projeto, o algoritmo de segmentação Otsu apresentado por Otsu (1979) foi adaptado para que pudesse ser executado em colunas específicas do histograma. Isso torna o algoritmo mais flexível e permite a execução de múltiplos *thresholds* simultâneos.

Dessa maneira, o algoritmo Otsu Threshold pode ser adaptado da seguinte forma:

```

OTSU-ADAPTADO(inicio <- 0, fim <- 255)
1. calcular o histograma da imagem em escala de cinza
2. Para k de inicio até fim passo 1 faça
3.   p1 <- SOMARFREQPIXEL(inicio, k)
4.   p2 <- SOMARFREQPIXEL(k + 1, fim)
5.   p12 <- p1 * p2
6.   se p12 = 0
7.     p12 <- 1
8.   m1 <- SOMARVALORESMEDIOS(inicio, k)
9.   m2 <- SOMARVALORESMEDIOS(k+1, fim)
10.  diff <- (m1 * p2) - (m2 * p1)
11.  vetor[k] <- (diff^2)/p12
12. Fim-para
13.
14. Retornar índice da posição do vetor que contém o maior valor

```

O algoritmo funciona como segue: primeiramente é necessário calcular o histograma da imagem para descobrir qual a frequência dos valores dos *pixels* presentes. Esse histograma conterà 256 valores, iniciando com o índice 0 e finalizando com o índice 255. Em seguida, é necessário descobrir qual a melhor posição que o histograma pode ser dividido. A variável *k* tem a função de percorrer o histograma e calcular a diferença de variância entre o grupo cujo índice for menor ou igual à *k* e o grupo cujo índice for maior que *k*. Assim, a probabilidade será calculada para todas as combinações de agrupamento dos *pixels*.

As variáveis início e fim servem para limitar qual a região que deve ser analisada. Início por padrão recebe o valor 0, correspondente a primeira coluna do histograma, mas esse valor pode ser especificado como parâmetro da função. Do mesmo modo, a variável fim recebe o valor padrão de 255, correspondente a última coluna do histograma, e o valor pode ser alterado na chamada da função.

Para realizar o cálculo da probabilidade, somamos todas as frequências dos dois grupos de *pixels* separadamente com a função SOMARFREQPIXEL, que é descrita como segue:

SOMARFREQPIXEL (início, fim)

1. soma <- 0
2. Para i de início até fim passo 1 faça
3. Soma += valor de frequência do histograma para a coluna i
4. Fim-para
- 5.
6. Retornar soma

Após calcular a frequência de cada grupo, é necessário calcular os valores medianos de cada um, valor este obtido pela função SOMARVALORESMEDIOS. O valor de frequência do grupo 1 é multiplicado pelo soma dos valores medianos do grupo 2 e vice-versa. O quadrado da diferença dos dois valores é dividido pela multiplicação dos valores de frequência de cada grupo, e armazenado em uma estrutura vetor. O índice de maior valor no vetor é retornado, representando assim a maior diferença de variância entre dois grupos de *pixels* na imagem. A função SOMARVALORESMEDIOS é descrita como segue:

SOMARVALORESMEIOS (inicio, fim)

1. soma <- 0
2. Para i de inicio até fim passo 1 faça
3. Soma += i * (valor de frequência do histograma para a coluna i)
4. Fim-para
- 5.
6. Retornar soma

Com a adaptação do algoritmo Otsu *Threshold* é possível obter resultados mais satisfatórios nos quadrantes da imagem panorâmica com aplicação no espaço de cores HSV. Essas etapas serão apresentados nas próximas subseções.

4.3.8.1. Otsu Threshold Adaptado no canal Hue

O primeiro método analisado nesse trabalho é a aplicação do algoritmo Otsu Adaptado nos quadrantes da imagem em espaço HSV. Esse método será aplicado em cenários onde as ruas para navegação destacam-se das áreas representadas pelos pomares, ou seja, quando a participação de verde na imagem for menor que 80%.

Como o algoritmo de segmentação é adaptado para ser executado mais de uma vez, no intuito de maximizar a eficiência dessa etapa, o limiar calculado na primeira execução do algoritmo é utilizado como parâmetro de entrada para uma segunda execução. Na ocasião, o limiar calculado é utilizado como limite inicial do cálculo na segunda chamada da função.

Com o valor calculado pelo algoritmo de segmentação, é possível aplicar a regra de *threshold* no canal *Hue* da imagem, sendo que as classes serão definidas de acordo com a Eq. 4.13:

$$v = \begin{cases} 0, & p \geq l \\ 255, & p < l \end{cases} \quad (4.13)$$

onde p é o valor do pixel atual, v é o novo valor do pixel correspondente e l o valor do limiar calculado pelo algoritmo Otsu.

A Figura 4.10 (a) mostra um exemplo de imagem e, na Figura 4.10 (b), o resultado da segmentação.

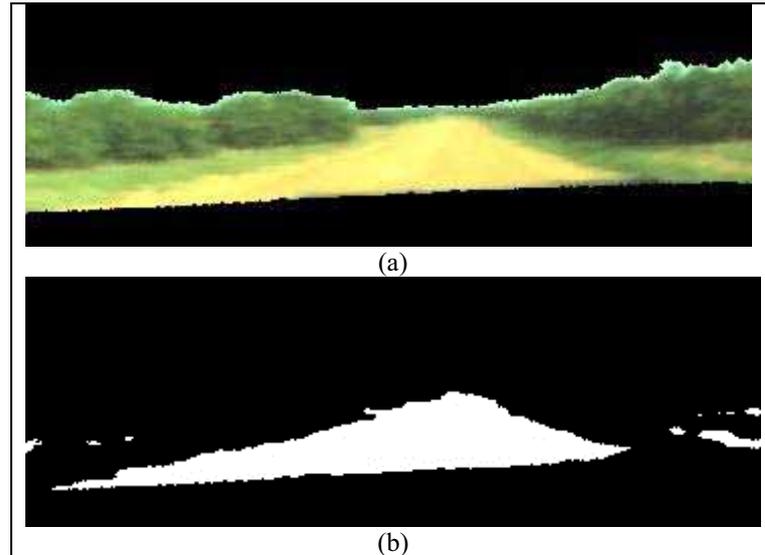


Figura 4.10 – Aplicação do Otsu *Threshold* no canal *Hue*. Sendo que em (a) é ilustrado o quadrante analisado e em (b) a aplicação da técnica

4.3.8.2. Otsu Threshold Adaptado no canal de iluminação

Quando as regiões dos pomares possuem uma cor bastante próxima das ruas de navegação, a segmentação por *threshold* utilizando apenas o canal *Hue* da imagem em espaço HSV torna-se pouco eficiente, uma vez que os valores correspondentes aos *pixels* são bastante próximos.

Para segmentar as imagens relacionadas nessa situação utilizou-se o algoritmo Otsu Threshold Adaptado conjuntamente com as informações do canal *Value*. Assim utilizou-se o canal *Hue* para filtrar os *pixels* verdes e, com o algoritmo Otsu, pretende-se aproximar a relação de luminosidade o máximo possível para encontrar as linhas desejadas. Da mesma forma que o método anterior, o algoritmo é executado duas vezes: a primeira para todos os intervalos de valores do canal e a segunda vez apenas para a região delimitada pelo valor de retorno da primeira execução do algoritmo. Ou seja, o valor de retorno serve como parâmetro *inicio* do algoritmo para e limita a região de cálculo.

Essa técnica só será eficiente quando as linhas de plantação formadas pelos pomares possuem uma moderada distância física entre elas. Em ruas mais estreitas, a luminosidade do ambiente pode ter um alto grau de influência para a captação das cores pelo sensor de visão, o que pode tornar a própria abordagem de utilização de câmera imprópria para esses casos. Em ruas mais largas, a iluminação do ambiente gera uma maior incidência de luz na superfície e torna a capacitação das cores pelo sensor de visão mais eficiente.

Na Figura 4.11 (a) é possível observar o quadrante resultante na etapa anterior e em (b) o resultado utilizando esse método de segmentação.

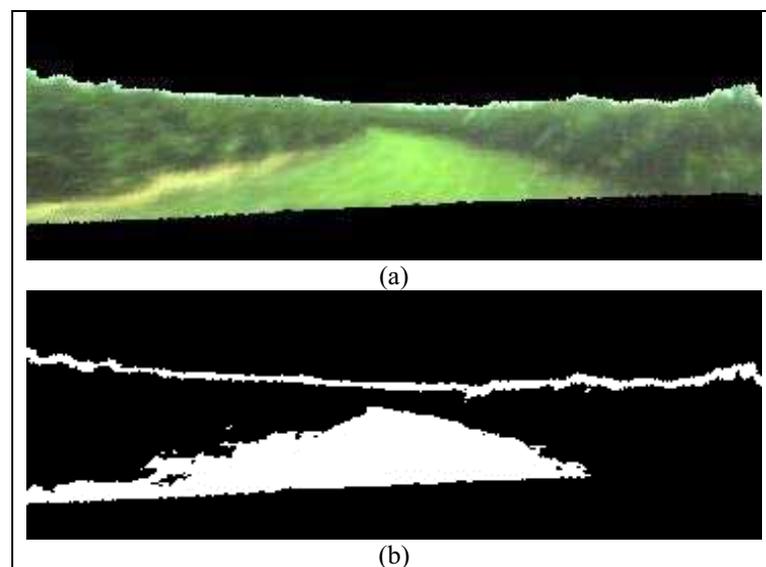


Figura 4.11 – Aplicação do Otsu *Threshold* para o canal de iluminação. Sendo que em (a) é ilustrado o quadrante analisado e em (b) a aplicação da técnica

4.3.9. Etapa de Otimização de Resultados

Após o processamento da segmentação, é necessário aprimorar os resultados obtidos até o momento. A primeira etapa para esse procedimento é a aplicação de uma máscara que limita a região em que se pode encontrar a rua de navegação. Essa máscara deve ser definida fora da etapa de execução do sistema, e pode ser única para cada quadrante da imagem. O tamanho e formato da máscara podem também variar de acordo com cada aplicação. Na Figura 4.12 está ilustrado um modelo de máscara utilizada nessa etapa.



Figura 4.12 – Exemplo de máscara de corte

Com a definição da máscara, é possível aplicá-la na imagem binária resultante do processo de segmentação. Na Figura 4.13 é possível verificar o resultado desse método. Em (a) é possível observar o quadrante original, em (b) o resultado da segmentação e em (c) a utilização da máscara ilustrada na Figura 4.12.

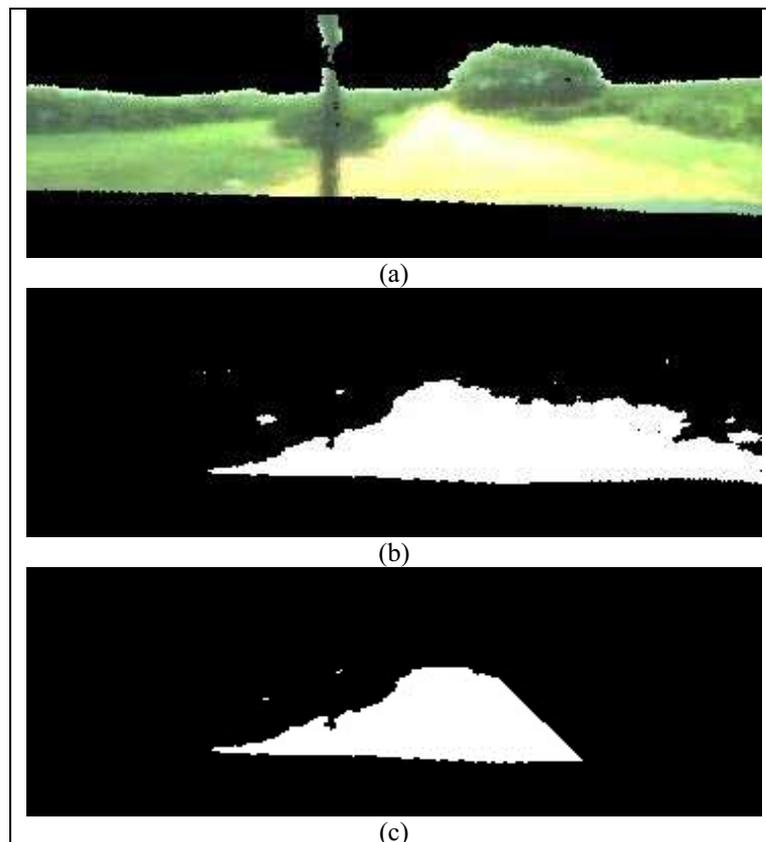


Figura 4.13 – Aplicação da máscara de corte no resultado da segmentação. Sendo que em (a) é ilustrado o quadrante analisado e em (b) o resultado do algoritmo Otsu e em (c) a aplicação da máscara

Mesmo com a aplicação da máscara, a imagem ainda pode apresentar regiões pequenas ou insatisfatórias na imagem que podem atrapalhar os procedimentos de pós-processamento. É necessário eliminar essas regiões que não possuem importância para o problema tratado.

Um método foi criado para realizar a limpeza dessas regiões. Nesse algoritmo, o objetivo é encontrar regiões pequenas de *pixels* brancos e eliminá-los. O algoritmo é descrito como segue:

LIMPARAREA (quadrante)

1. Para i de 1 até altura do quadrante passo 1 faça
2. Para j de 1 até comprimento do quadrante passo 1 faça
3. valor <- quadrante(i, j)
4. Se valor <> 0 então
5. flDireita <- 0, flEsquerda <-0, flCima <-0, flBaixo <-0
- 6.
7. flDireita <- obter qtde *pixels* brancos consecutivos até a borda direita
8. flEsquerda <- obter qtde *pixels* brancos consecutivos até a borda esquerda
9. flCima <- obter qtde *pixels* brancos consecutivos até a borda superior
10. flBaixo <- obter qtde *pixels* brancos consecutivos até a borda inferior
- 11.
12. Se ao menos 3 das variáveis de flag forem <= limite então
13. quadrante(i, j) <- 0
14. Fim-se
15. Fim-se
16. Fim-para
17. Fim-para
18. Fim

A função LIMPARAREA recebe como parâmetro o quadrante a ser analisado. Na imagem, todos os *pixels* são verificados. Quando o algoritmo encontra um pixel branco, é necessário verificar a quantidade de *pixels* brancos consecutivos em todas as direções daquele pixel, excluindo as diagonais. Cada quantidade é armazenada em variáveis flag. Se ao menos três dessas variáveis possuírem valor menor que um limite definido a priori, aquele pixel analisado recebe a cor preta. O valor de limite utilizado neste trabalho foi 5 (cinco).

No sistema, o algoritmo para limpar as regiões é executado duas vezes para cada quadrante na imagem. Na Figura 4.14 é possível verificar a eficiência do algoritmo no quadrante, sendo (a) o threshold original com a máscara, em (b) o algoritmo executado pela primeira vez e em (c) executado pela segunda vez.

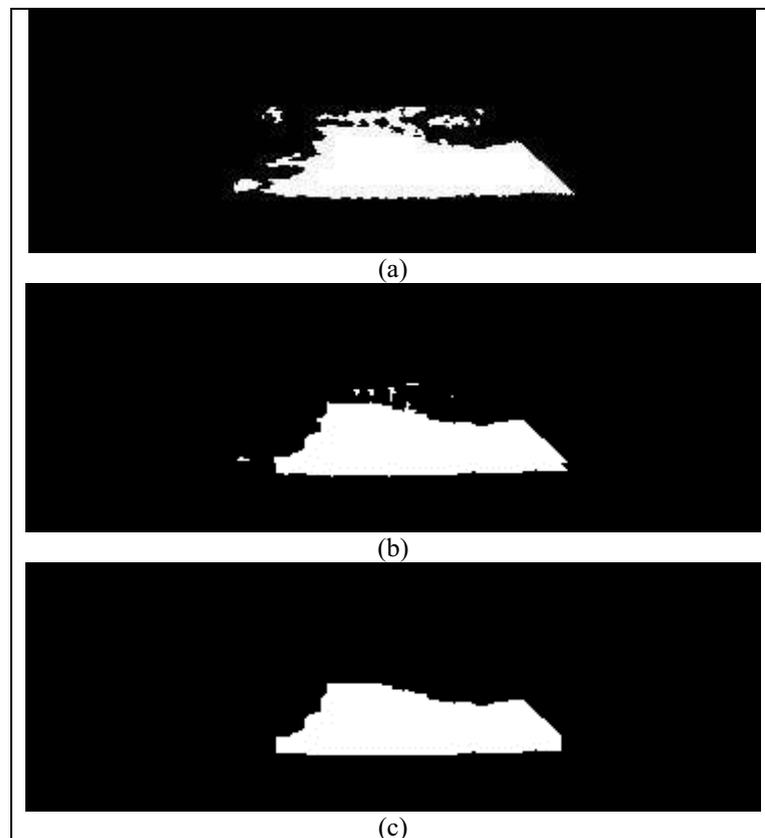


Figura 4.14 – Eficiência do algoritmo para otimização dos resultados. Sendo que em (a) é ilustrado um resultado da etapa de segmentação, em (b) o resultado da aplicação da máscara e em (c) o resultado do algoritmo de limpeza de área

Após esse processamento, a imagem pode ser utilizada em várias aplicações voltadas à Agricultura de Precisão.

Na próxima sessão será abordada uma forma de utilização das imagens geradas para fins da navegação autônoma de robôs móveis.

4.4. Considerações do Capítulo

Nesse capítulo foram apresentadas as técnicas e funcionamento do sistema de visão proposto, como também os cenários encontrados no ambiente estudado. Vale destacar que os testes realizados foram em pomares de laranja, cultura utilizada no projeto AgriBOT, e que as imagens foram capturadas enquanto o veículo estava em movimento, conduzido por um operador humano. As técnicas utilizadas, apesar de serem clássicas na área de processamento de imagens, ganham importância quando aplicadas em conjunto. A aplicação de máscaras para eliminação de regiões e técnicas como a extração do céu da imagem buscam aumentar a eficiência do algoritmo de segmentação. Ao final do processo, é possível obter as imagens dos quatro quadrantes que estão relacionados a diferentes campos de visão do veículo, cada um com a informação das regiões presentes no cenário agrícola. O próximo capítulo será dedicado aos resultados obtidos pelo processamento apresentado nas imagens capturadas do ambiente.

5. RESULTADOS

Neste capítulo são apresentados os resultados obtidos em cada etapa de processamento do sistema implementado. Para isso, diversas situações registradas na etapa de aquisição de imagens foram selecionadas e detalhadas, estabelecendo a importância de cada técnica utilizada.

5.1. Resultados do Processamento de Imagens

Nas próximas sessões são apresentadas situações encontradas durante a etapa de Aquisição de Imagens do Sistema, cada qual com os resultados obtidos em cada etapa de processamento da aplicação. Dentre as situações, pode-se destacar quando existem regiões no ambiente com características diferentes da região que o veículo está posicionado; situações que as características da região em que o veículo está posicionado sofre mudanças; e também situações que não apresentam mudanças das características que o veículo está posicionado. Outros momentos além dos apresentados nesse capítulo estão disponíveis no Apêndice A desse trabalho.

5.1.1. Situação 1

Na situação representada na Figura 5.1 pode-se observar o momento em que o veículo sai de uma linha de plantio e encontra outro caminho com características visuais diferentes. Outros momentos semelhantes podem ser observados na seção A.1.1 e A.1.2 do Apêndice A.

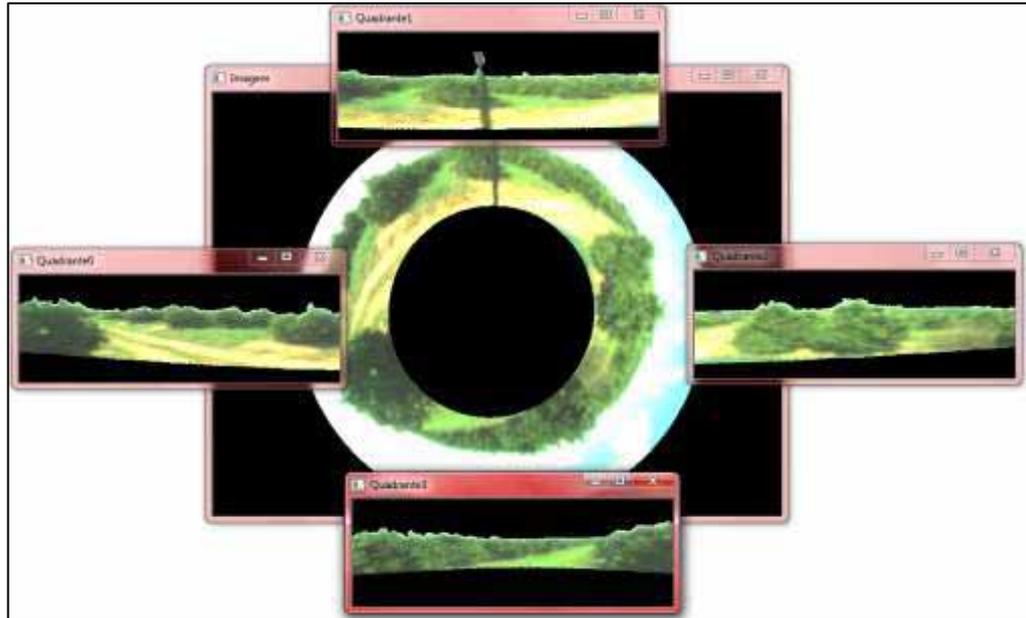


Figura 5.1 – Imagem global da situação analisada

Na Figura 5.2 é possível observar a imagem omnidirecional originalmente obtida pelo sistema.



Figura 5.2 – Imagem omnidirecional obtida pelo sistema de visão

Com a retificação da imagem, produzida pela etapa de retificação, torna-se possível identificar com mais facilidade a quantidade de caminhos presentes em toda a imagem e suas características visuais distintas. Na Figura 5.3 é possível observar o resultado dessa etapa.



Figura 5.3 – Resultado da Etapa de Retificação da Imagem

Após a etapa de retificação da imagem, extrai-se o céu da imagem panorâmica. O resultado desta operação pode ser observado na Figura 5.4.

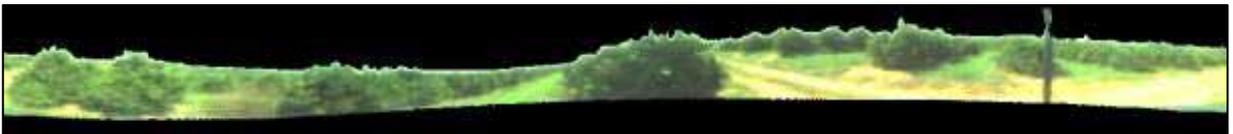


Figura 5.4 – Resultado da Etapa de Extração do Céu das Imagens

Após esse procedimento, a etapa de extração de quadrantes é executada, gerando os resultados mostrados na Figura 5.5. Nesta figura é possível observar a visão frontal do veículo em (a), visão lateral direita do veículo em (b), a visão da traseira do veículo em (c) e a lateral esquerda do veículo em (d).

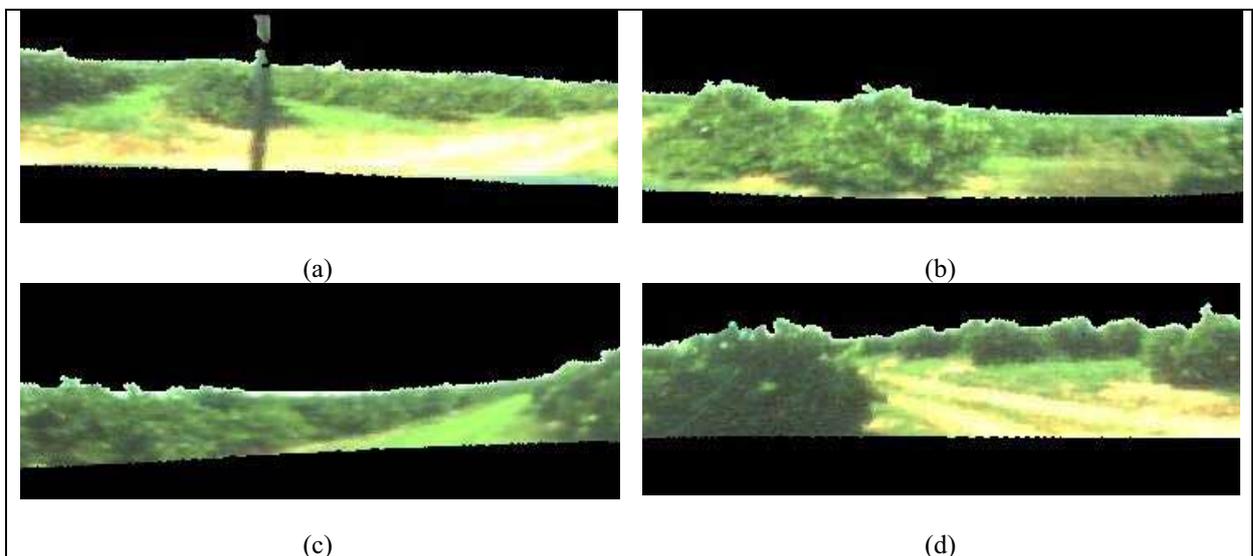


Figura 5.5 – Resultados da Etapa de Extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

Tornou-se possível calcular a participação de verde para cada quadrante, índice alcançado pela Etapa de Verificação de Regiões Verdes na Imagem. Nessa etapa, os quadrantes (b) e (c) apresentaram uma porcentagem de participação de verde igual ou maior que 80%, enquanto que os quadrantes (a) e (d) apresentaram uma porcentagem de participação menor que 80%. Assim, para os quadrantes (b) e (c) foi aplicada a técnica Otsu Adaptada para o canal de iluminação, enquanto que para os quadrantes (a) e (d) foi aplicada a técnica Otsu Adaptada para o canal de cor (*hue*).

Na Figura 5.6 são mostrados os resultados obtidos com a aplicação dos algoritmos da etapa de segmentação.

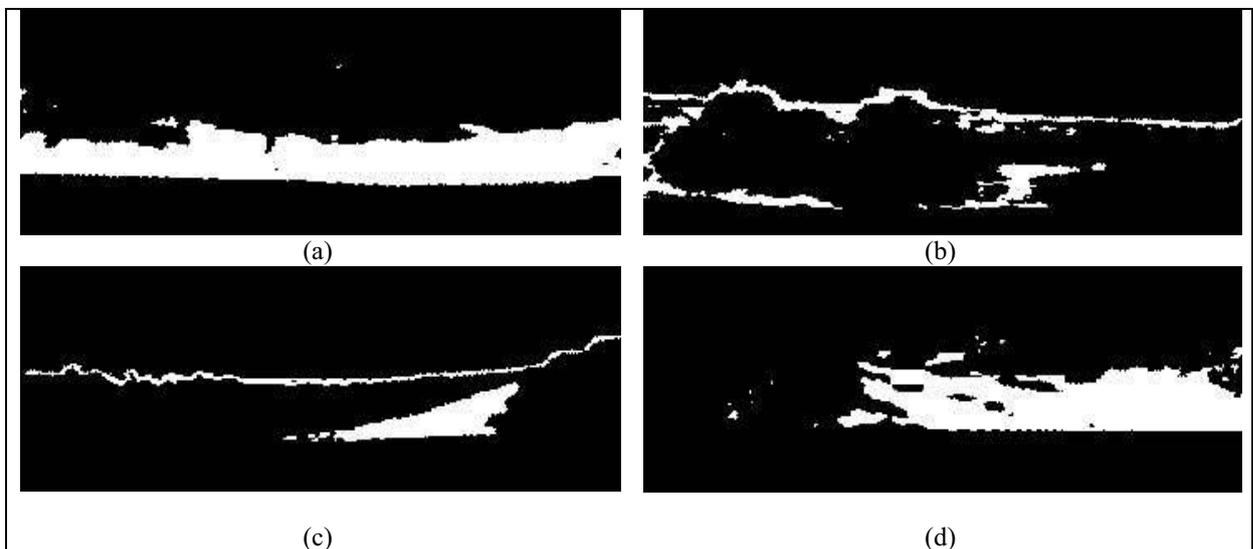


Figura 5.6 – Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Para os quadrantes (b) e (c) foi aplicada a técnica Otsu Adaptada para o canal de iluminação, enquanto que para os quadrantes (a) e (d) foi aplicada a técnica Otsu Adaptada para o canal de cor.

Na Figura 5.6 (a) e Figura 5.6 (d) pode-se verificar a eficiência do algoritmo de segmentação para regiões com características heterogêneas. Algumas regiões brancas de menor área foram selecionadas ao conjunto principal e devem ser eliminadas nas próximas etapas do processo. Caminhos de terra com trechos de grama na região central da linha de navegação também podem ser identificados nos dois quadrantes analisados. Caso a aplicação for destinada à navegação, por exemplo, nesse tipo de situação é necessário verificar, em etapas de pós-processamento, se as áreas resultantes comportam o veículo utilizado.

Uma área candidata à navegação é mostrada na Figura 5.5 (b). Embora tenha ocorrido um ruído durante a aquisição da imagem, o algoritmo conseguiu segmentar parte da área destinada candidata à navegação. Essa área pode ser identificada pelas regiões brancas inferiores da Figura 5.6 (b). As regiões brancas superiores da imagem estão relacionadas com pequenas áreas que são selecionadas para o conjunto, uma vez que estas apresentam características muito próximas das presentes nas ruas de navegação. Isso acontece principalmente porque as regiões superiores dos pomares eventualmente recebem um teor de iluminação bastante próximo das recebidas pelas ruas de navegação. Na Figura 5.5 (c) é possível identificar a mesma situação do quadrante analisado anteriormente, e por isso as mesmas considerações feitas para a Figura 5.6 (b) podem ser aplicadas para a Figura 5.6 (c).

Na Figura 5.7 é possível verificar os quadrantes da imagem analisada após a etapa de otimização dos resultados.



Figura 5.7 – Resultados da Etapa de Inserção de Máscara para Detecção de Caminhos, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

O objetivo da aplicação da máscara e os dos algoritmos de limpeza é melhorar os resultados obtidos pela etapa de segmentação. Na Figura 5.7 (a) é mostrada a área de navegação resultante para cálculo da trajetória. Esse quadrante é livre de considerações específicas, uma vez que a etapa de otimização de resultados não transmitiu grande influencia nos resultados finais.

Na Figura 5.7 (b) observa-se que uma região pequena da área da imagem foi mantida. Dependendo das configurações e dimensões do veículo utilizado essa região pode ser descartada pela etapa de pós-processamento uma vez que a área resultante pode ser muito pequena para comportar o veículo utilizado. Entretanto, em outras aplicações essa área pode apresentar um indício que existe uma nova região de navegação a ser explorada e, no decorrer do processamento, com a aquisição de novas imagens, pode se tornar uma forte candidata para realizar a navegação.

Na Figura 5.7 (c) é possível visualizar parte da área de navegação encontrada na Figura 5.6 (c). A região em questão foi alterada pela aplicação da máscara de corte cujo objetivo é delimitar a região de interesse do veículo. Assim, é possível identificar que existe um caminho para navegação e, caso o veículo realize a navegação nessa região, ao longo do trajeto novas imagens devem ser obtidas e a região destinada à navegação deverá ser constantemente atualizada.

Na Figura 5.7 (d) é possível identificar uma região de grande interesse para navegação e outras regiões brancas menores. Essas regiões menores devem ser descartadas durante o processo de pós-segmentação uma vez que torna-se necessário verificar se o veículo pode navegar nessas regiões de acordo com as características físicas do mesmo. Da mesma maneira, as pequenas regiões pretas presentes na área de navegação principal podem ser analisadas durante a etapa de pós-processamento e, de acordo com as características físicas do veículo utilizado, torna-se possível serem classificadas como obstáculos. No caso desse trabalho, as regiões pretas da imagem apresentada não significam obstáculos.

5.1.2. Situação 2

Na situação representada na Figura 5.8 é possível observar um momento que o veículo se encontra realizando a navegação entre linhas de plantio de pomares. Outros momentos semelhantes podem ser observados na seção A.2.1 e A.2.2 do Apêndice A.

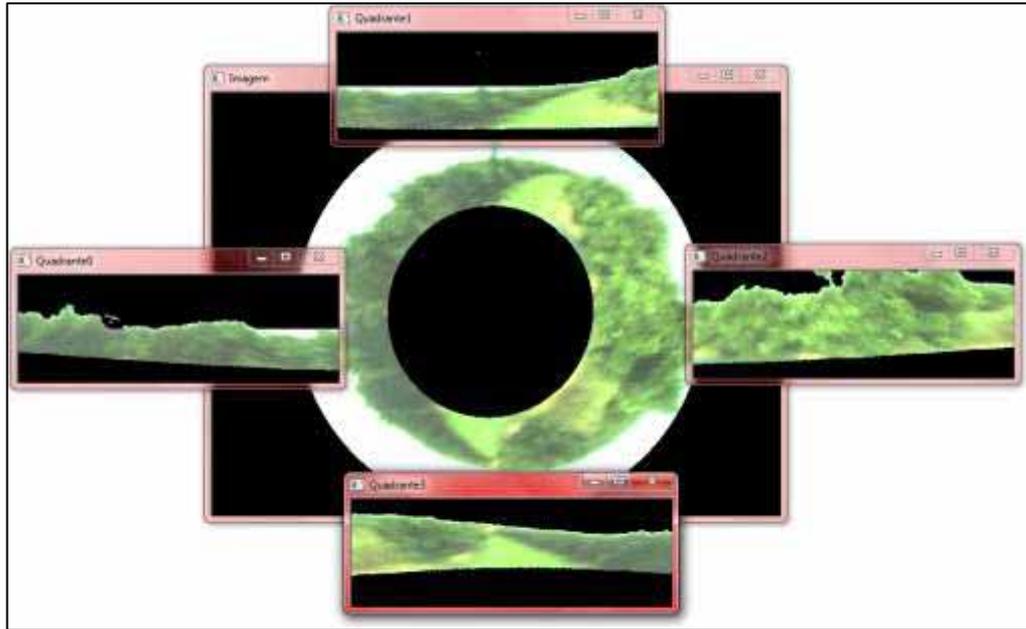


Figura 5.8 – Imagem global da situação analisada

Na Figura 5.9 é possível observar a imagem omnidirecional originalmente obtida pelo sistema.



Figura 5.9 – Imagem omnidirecional obtida pelo sistema de visão

A imagem em questão é retificada pela Etapa de Retificação da Imagem e as informações relacionadas ao céu e outras regiões que possuem pouco interesse para o problema tratado são eliminadas, conforme ilustrado na Figura 5.10.

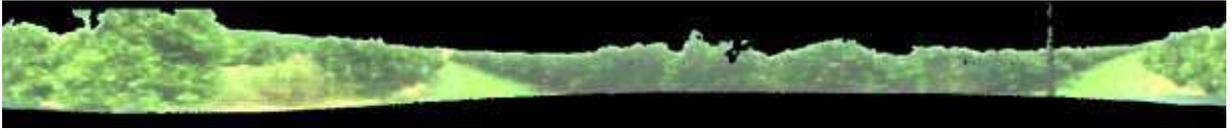


Figura 5.10 –Resultado da Etapa de Extração do Céu das Imagens

Após, a etapa de extração de quadrantes da imagem é executada. Na Figura 5.11 (a) é mostrada a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

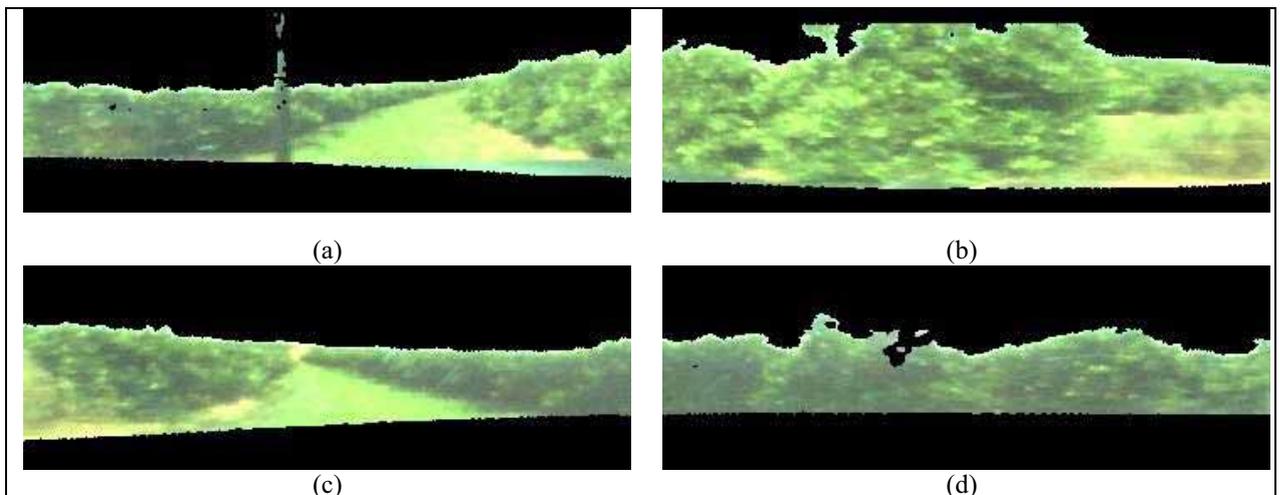


Figura 5.11 – Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A etapa seguinte a ser executada foi o processo para identificação de regiões verdes na imagem. Nessa etapa todos os quadrantes apresentaram uma porcentagem de participação de verde igual ou maior que 80%. Desse modo, para todos os quadrantes serão aplicadas a técnica Otsu Adaptada para o canal de iluminação. Na Figura 5.12 são mostrados os resultados obtidos da segmentação.

Na Figura 5.12 (a) e Figura 5.12 (c) pode-se verificar a eficiência do algoritmo de segmentação para regiões com características homogêneas. Algumas regiões brancas de menor área foram selecionadas ao conjunto principal e devem ser eliminadas nas próximas etapas do processo.

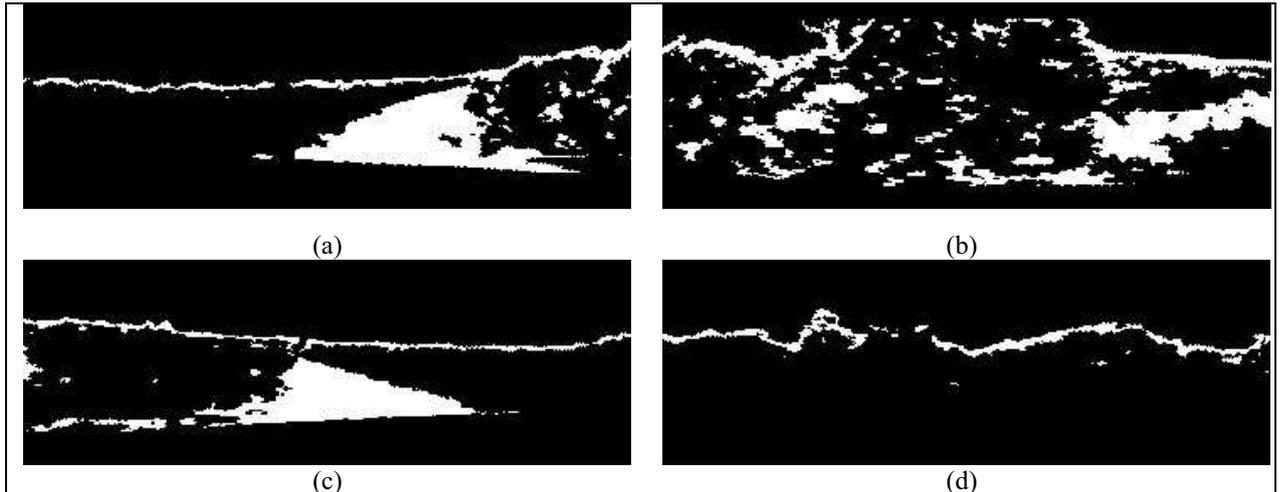


Figura 5.12 – Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica Otsu Adaptada para o canal de iluminação.

Na Figura 5.12 (b) é possível verificar que houve algumas áreas selecionadas, principalmente devido a luminosidade de algumas regiões da árvore. Algumas regiões mais densas, com maior volume e área comparadas as demais representam as regiões de navegação, contudo está fora do alcance de visão do robô. Com essa imagem é possível justificar a importância da etapa de aplicação de máscara para detecção de caminhos, uma vez que os resultados obtidos nessa etapa precisam ser otimizados.

Na Figura 5.12 (d) nota-se que algumas áreas foram selecionadas também devido a alta luminosidade dessas regiões e devem ser destacadas na etapa de aplicação da máscara.

Aplicando a máscara de corte e os algoritmos de limpeza, obtém-se os resultados ilustrados na Figura 5.13.

Na Figura 5.13 (a) e Figura 5.13 (c) nota-se que as áreas presentes equivalem aos resultados esperados ao final do processamento, prevalecendo assim a eficiência do algoritmo de segmentação. Já nas figuras 5.13 (b) e 5.13 (d) percebe-se que nenhuma região foi selecionada. Esse resultado está correto uma vez que em nenhuma dessas imagens possuem novas regiões que não sejam árvores.

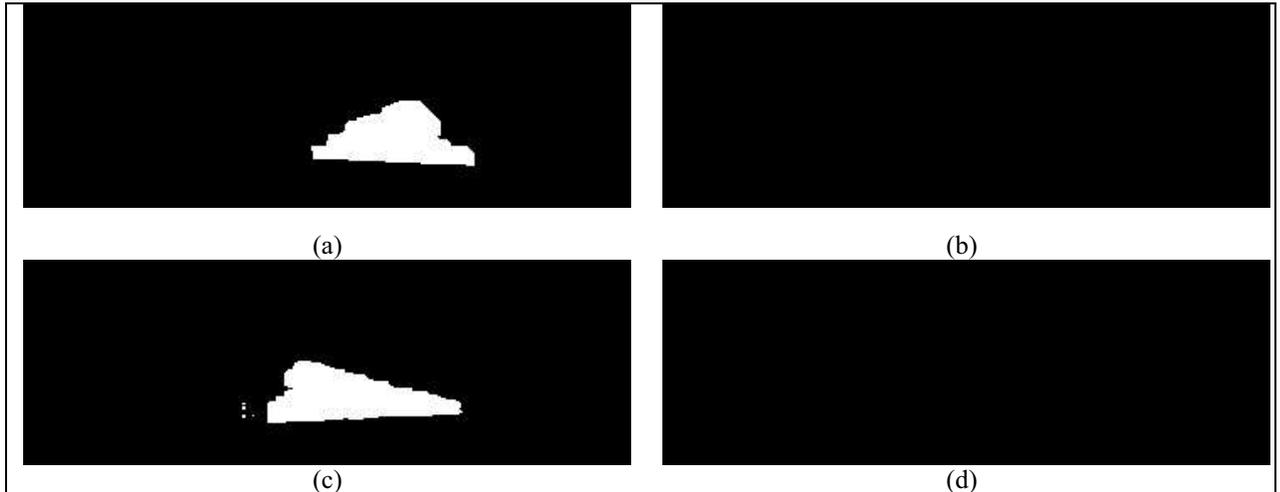


Figura 5.13 – Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

5.1.3. Situação 3

Na Figura 5.14 observa-se o momento em que um veículo navega em uma área de navegação bem definida no cenário natural e, durante a aquisição, é possível identificar outras regiões de interesse no cenário. Outros momentos semelhantes podem ser observados na seção A.3.1 e A.3.2 do Apêndice A.

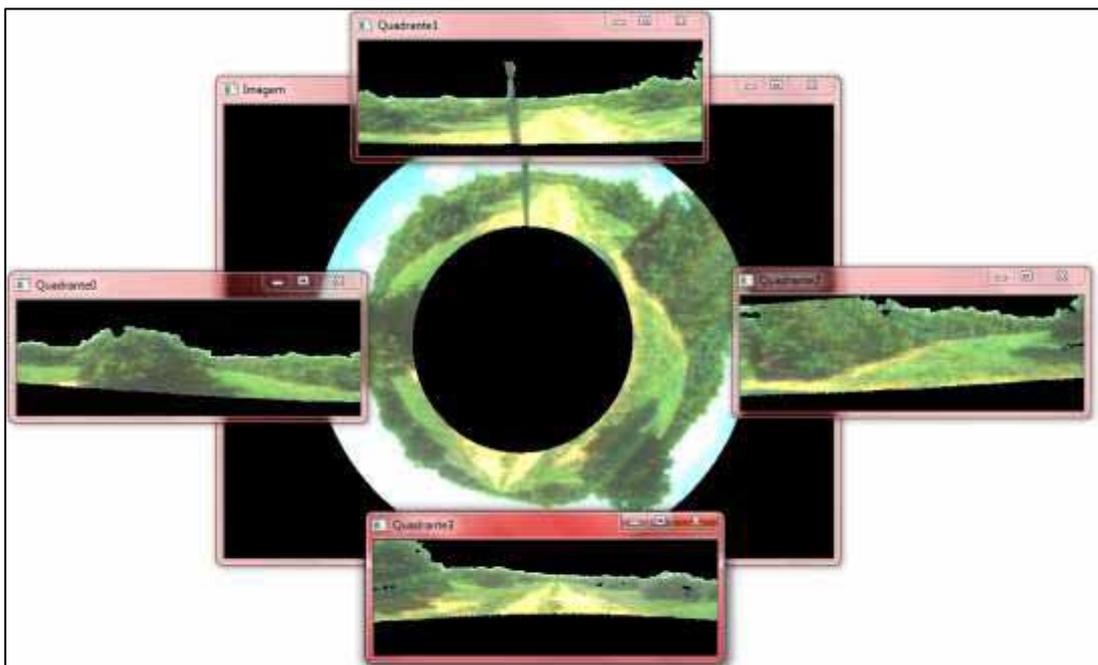


Figura 5.14 – Imagem global da situação analisada

Na Figura 5.15 é possível observar a imagem omnidirecional originalmente obtida pelo sistema.



Figura 5.15 – Imagem omnidirecional obtida pelo sistema de visão

Na Figura 5.16 é possível visualizar o resultado do processo de segmentação e exclusão das regiões que não possuem interesse para o problema.

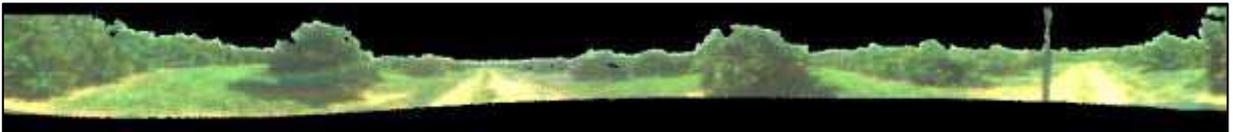


Figura 5.16 – Resultado da Etapa de Retificação da Imagem

Após, a extração de quadrantes é processada. Na Figura 5.17 é possível observar os resultados dessa etapa, sendo que em (a) é possível visualizar a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a visão lateral esquerda do veículo.

Após a extração de quadrantes, para cada quadrante é calculada a porcentagem de verde. Nesse cenário, os quadrantes (b) e (d) apresentaram uma porcentagem maior ou igual a 80%, enquanto que os quadrantes (a) e (c) apresentaram uma porcentagem inferior a 80%. Assim, nos quadrantes (b) e (d) foram aplicadas as técnicas do Otsu Threshold para o canal de iluminação, enquanto que nos quadrantes (a) e (c) foram aplicadas as técnicas do Otsu Threshold para o canal *Hue* do espaço HSV. Na Figura 5.18 é possível observar os resultados dessa etapa de segmentação.

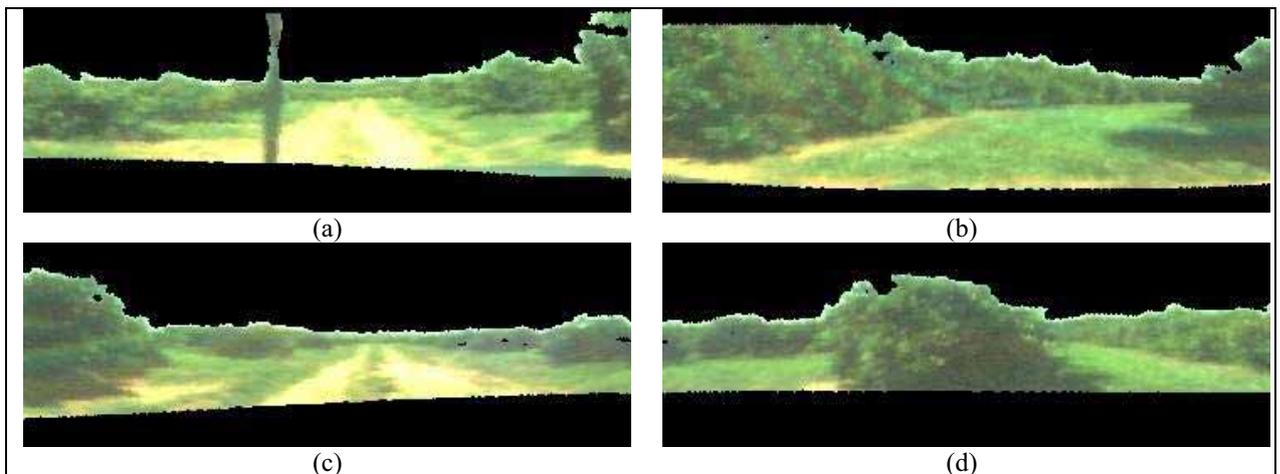


Figura 5.17 – Resultados da Etapa de Extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

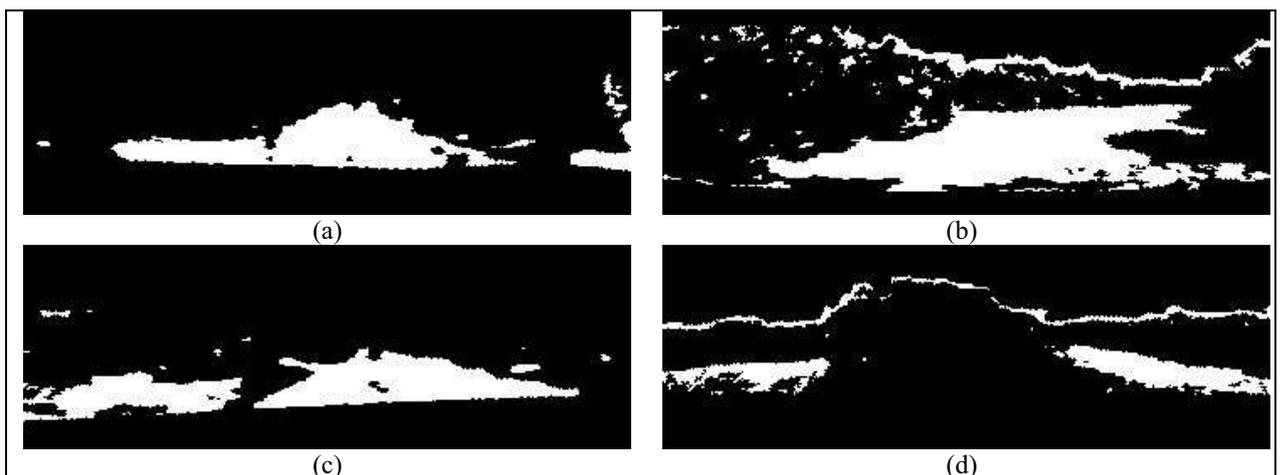


Figura 5.18 – Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Para os quadrantes (b) e (d) foram aplicadas as técnicas do Otsu Threshold para o canal de iluminação, e para os quadrantes (a) e (c) foram aplicadas as técnicas do Otsu Threshold para o canal *Hue*

É possível identificar em cada quadrante as regiões brancas que podem representar caminhos de navegação. Aplicando a máscara de corte e os algoritmos de limpeza, é possível obter os resultados ilustrados na Figura 5.19.

Na Figura 5.19 (a) pode-se identificar o caminho que o veículo estava percorrendo no momento da captura da imagem, reconhecendo a eficiência do processo. Em (b) identifica-se uma possibilidade de rota alternativa na lateral direita do veículo, sem demais observações. Em (c), são observadas duas áreas candidatas para serem trajetórias para navegação, porém essas áreas, na etapa de pós-processamento, devem ser avaliadas se suportam as medidas físicas do veículo. Como o quadrante (c) ilustra as informações da traseira do veículo, a região menor presente no quadrante pode já ter sido avaliada em um momento anterior.

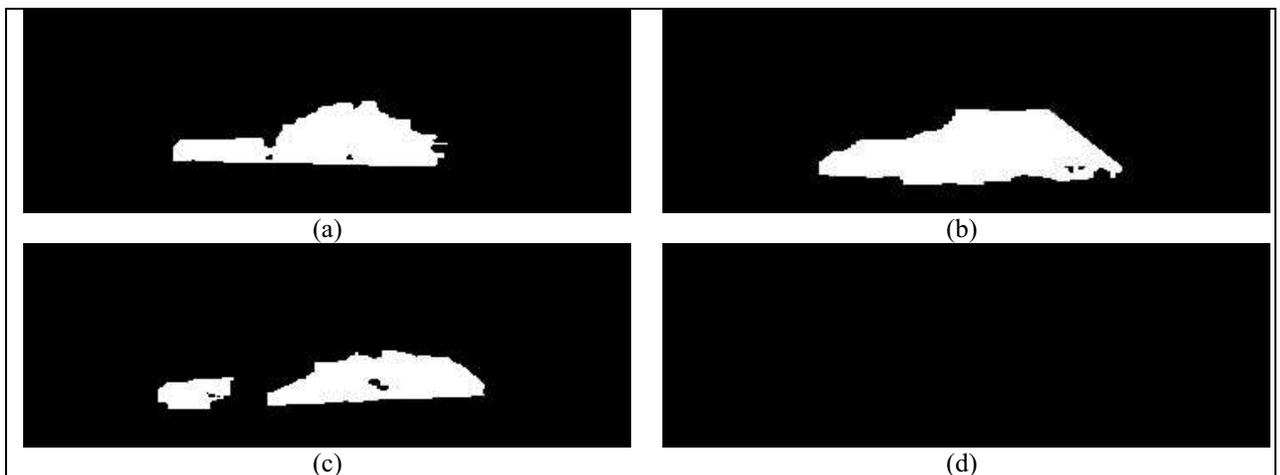


Figura 5.19 – Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

Na Figura 5.19 (d) foi possível identificar que nenhum caminho foi selecionado na imagem. Isso porque no quadrante original existia um obstáculo na imagem. Com a aplicação da máscara de corte, as áreas identificadas na etapa de segmentação ficaram fora do limite do campo de visão.

5.1.4. Situação 4

Na Figura 5.20 observa-se o momento que o veículo inicia sua trajetória em uma linha de navegação e há no ambiente vários outros caminhos alternativos para realizar a navegação. Outros momentos semelhantes podem ser observados na seção A.4.1 e A.4.2 do Apêndice A.

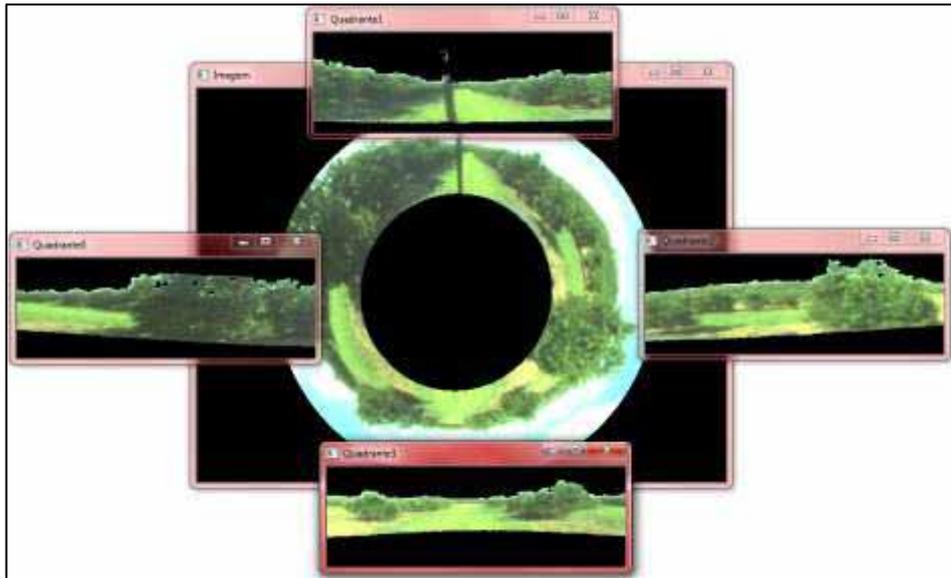


Figura 5.20 – Imagem global da situação analisada

Na Figura 5.21 é possível observar a imagem omnidirecional originalmente obtida pelo sistema.



Figura 5.21 – Imagem omnidirecional obtida pelo sistema de visão

A imagem então é retificada e as regiões que possuem pouco interesse para o problema tratado são eliminadas, conforme ilustrada na Figura 5.22.



Figura 5.22 – Resultado da Etapa de Retificação da Imagem

Após, a etapa de extração de quadrantes é efetuada, como mostrado na Figura 5.23, a seguir.

Figura 5.23 (a) observa-se a visão frontal do veículo. Em (b) a visão lateral direita do veículo; em (c) a visão da traseira do veículo e em (d) a visão da lateral esquerda do veículo.

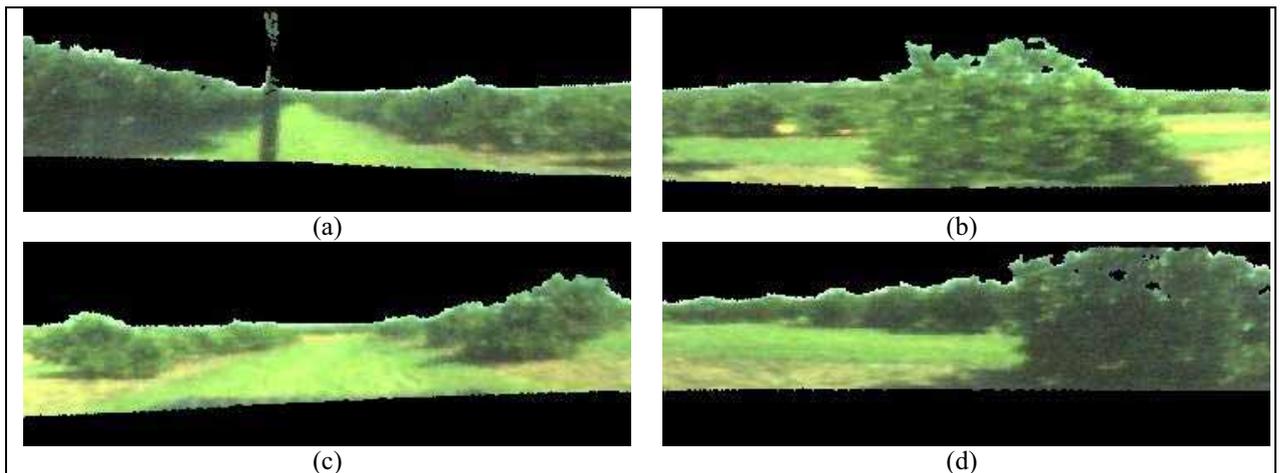


Figura 5.23 – Resultado da Etapa de Extração do Céu das Imagens, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

Após a extração dos quadrantes, torna-se possível calcular a porcentagem de verde para cada quadrante. Nessa etapa, todos os quadrantes apresentaram uma porcentagem de participação de verde igual ou maior que 80%. Assim, nos quadrantes serão aplicadas as técnicas Otsu Threshold Adaptado para o canal de iluminação.

Na Figura 5.24 são mostrados os resultados dessa etapa de processamento.

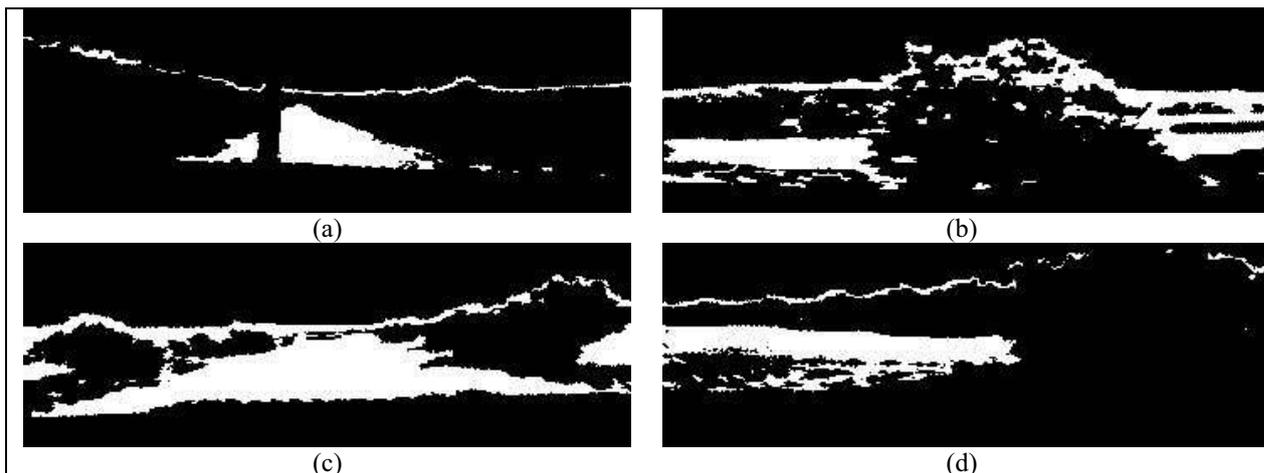


Figura 5.24 – Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica Otsu Thresholding para o canal de iluminação

Na Figura 5.24 pode-se verificar que em todos os quadrantes foram identificados trajetórias candidatas para navegação. Entretanto, é necessário aplicar algoritmos para otimização dos resultados. Na Figura 5.25 são mostrados os resultados da aplicação dessas técnicas.



Figura 5.25 – Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

Na análise dos resultados da etapa de otimização torna-se possível identificar que os quadrantes (a) e (c) apresentaram regiões de navegação mais bem definidas dentro do campo de visão delimitado pela técnica de máscara de corte. O quadrante (b), devido ao obstáculo natural presente na imagem, permaneceu com uma área pequena de resultado dessa etapa. Com o decorrer da captura de imagens a região destacada nesse momento deve ser atualizada para que torne uma região candidata para navegação.

No quadrante (d) é possível identificar uma região de interesse longe de onde o veículo está localizado e torna-se necessário aplicar uma validação nas etapas de pós-processamento para identificar se a região nesse instante é válida para navegação, de acordo com as configurações do veículo e altura que está o sistema de visão. No quadrante (a), por sua vez, torna-se necessário tratar as duas regiões presentes na imagem como uma só, uma vez que houve uma oclusão da região por causa da posição escolhida para a haste do suporte.

5.1.5. Situação 5

Na Figura 5.26 é representado o momento que o veículo navega entre as ruas de navegação e as árvores que formam as linhas de plantio apresentam diferentes níveis de iluminação. Outros momentos semelhantes podem ser observados na seção A.5.1 e A.5.2 do Apêndice A.

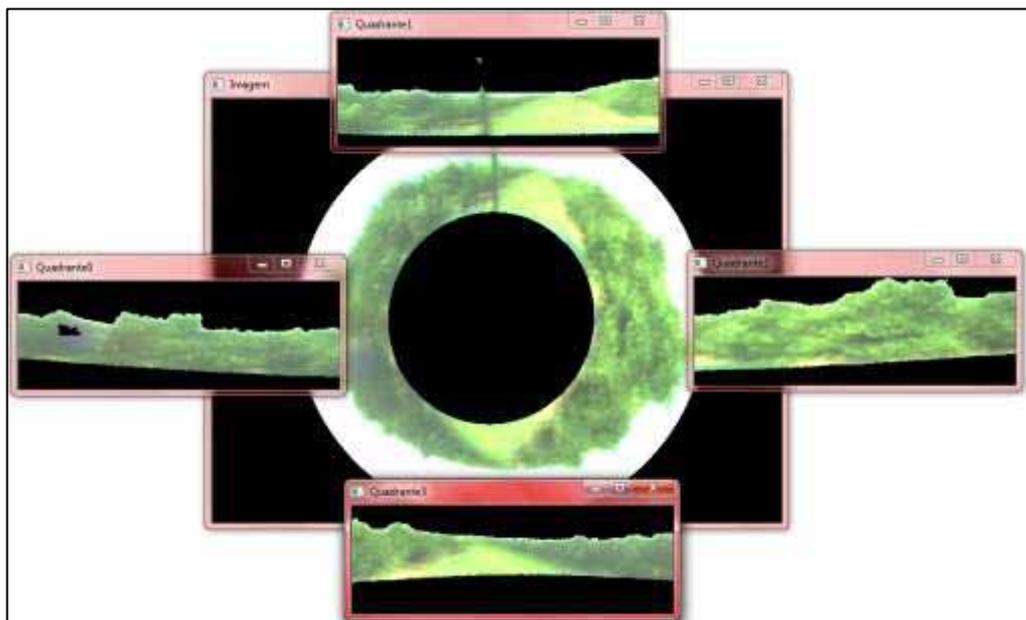


Figura 5.26 – Imagem global da situação analisada

Na Figura 5.27 é possível observar a imagem omnidirecional originalmente obtida pelo sistema.

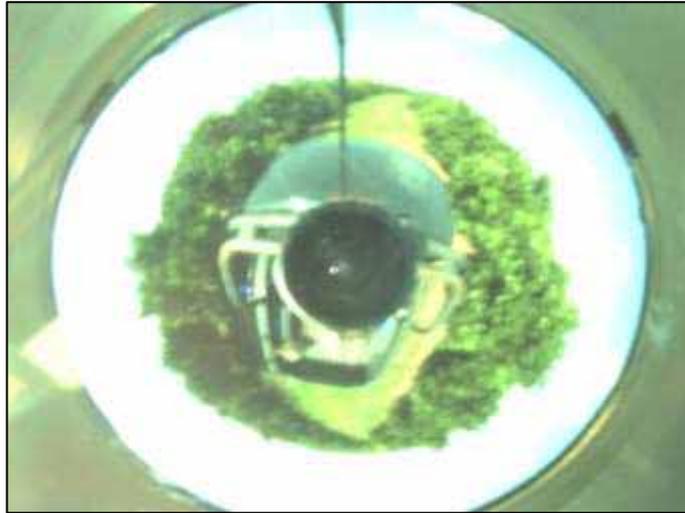


Figura 5.27 – Imagem omnidirecional obtida pelo sistema de visão

Em seguida a imagem é retificada e as regiões que possuem pouco interesse para o problema tratado são eliminadas, conforme ilustrada na Figura 5.28.

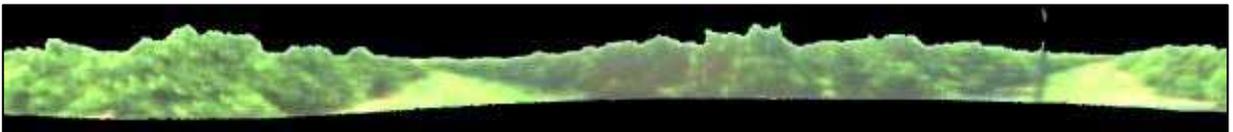


Figura 5.28 – Resultado da Etapa de Retificação da Imagem

Após, a extração de quadrantes é efetuada. Na Figura 5.29 (a) é possível observar a visão frontal do veículo, na Figura 5.29 (b) a visão lateral direita do veículo, na Figura 5.29 (c) a visão da traseira do veículo e na Figura 5.29 (d) a lateral esquerda do veículo.

Após é possível calcular a porcentagem de verde para cada quadrante. Nessa etapa, todos os quadrantes apresentaram uma porcentagem de participação de verde igual ou maior que 80%. Assim, nos quadrantes será aplicada a técnica Otsu Adaptada para o canal de iluminação. Na Figura 5.30 são mostrados os resultados dessas etapas de segmentação.

Nos quadrantes (a) e (c) foram identificadas áreas que possam representar as ruas do ambiente estudado. Entretanto, é necessário aplicar os algoritmos de limpeza e a máscara de detecção para otimizar os resultados obtidos em todos os quadrantes. Na Figura 5.31 é possível verificar os resultados da aplicação dessas técnicas.

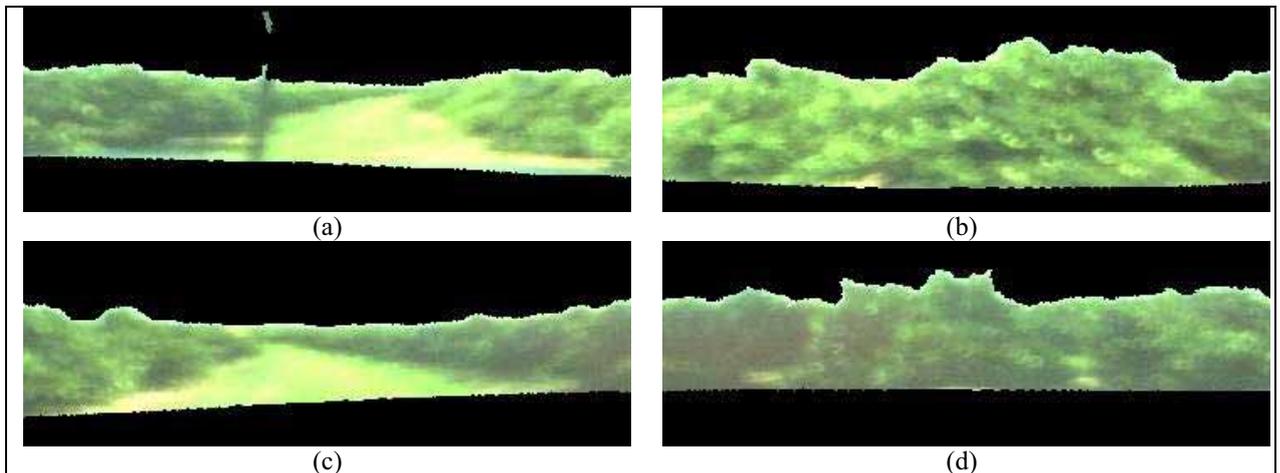


Figura 5.29 – Resultados da Etapa de Extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

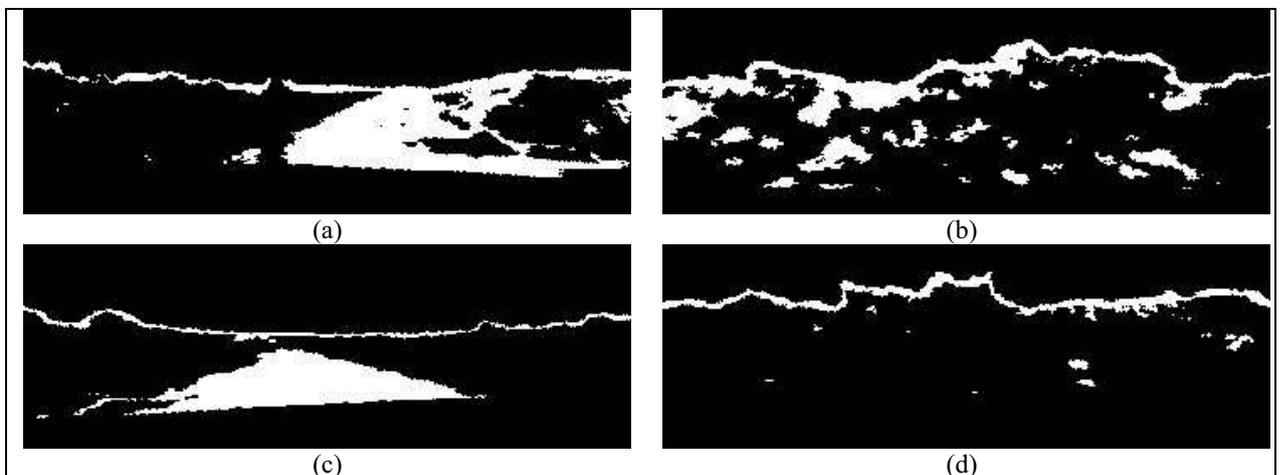


Figura 5.30 – Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica para o canal de iluminação.

Os quadrantes da Figura 5.31 (b) e Figura 5.31 (d) não apresentaram regiões candidatas como ruas no ambiente. Já nos quadrantes da Figura 5.31 (a) e Figura 5.31 (c) é possível observar as áreas das ruas em destaque.

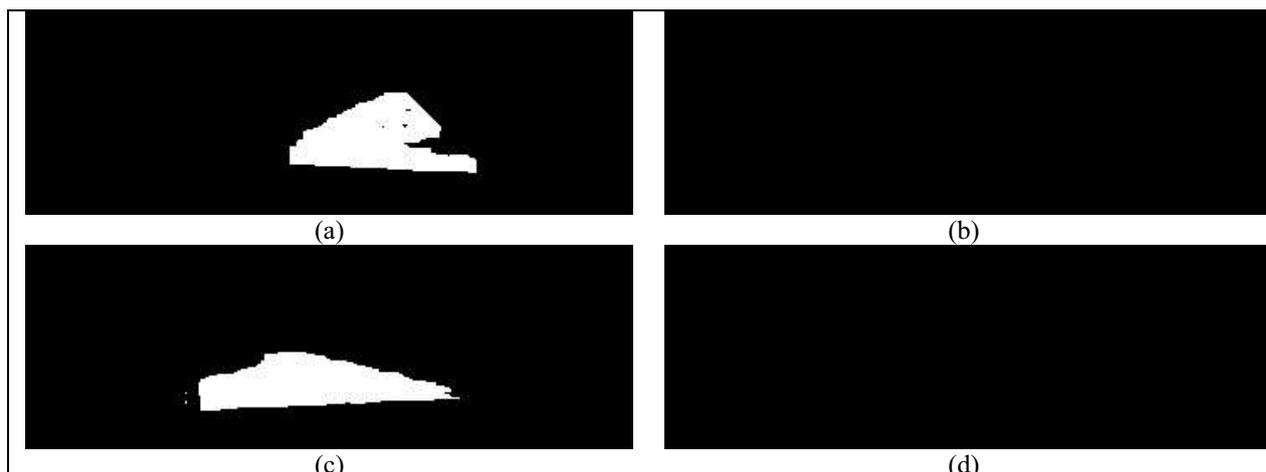


Figura 5.31 – Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A máscara de corte teve um papel fundamental para a obtenção do resultado no quadrante (a), uma vez que a iluminação dos pomares e das ruas estava bastante próxima. Com a aplicação da máscara, foi possível eliminar pequenas regiões que pudessem diminuir a eficiência do algoritmo de limpeza de área.

5.2. Valor para Participação de Verde nas Imagens

Para encontrar o valor do percentual de participação utilizado como comparativo na etapa de Verificação de Regiões Verdes na Imagem, foi analisado a eficiência das duas formas de aplicação do algoritmo Otsu Threshold que compõem esse trabalho.

Para isso, foi estabelecido separar as imagens obtidas pelo sistema omnidirecional em cinco grupos de acordo com o teor de verde de cada imagem. Nas coletas de imagens foram obtidas 4.326 imagens omnidirecionais. Como cada imagem omnidirecional gera quatro quadrantes, foram obtidos no total 17.304 quadrantes possíveis de serem analisados. Os quadrantes foram separados em grupos de acordo com a participação de *pixels* verdes presentes na imagem. Assim, as imagens presentes no grupo 1 possuem 0% à 20% de *pixels* verdes; no grupo 2, 20% à 40%; no grupo 3, 40% à 60%; no grupo 4, 60% à 80%; e no grupo 5, 80% à 100%. Com a concretização da triagem, 421 imagens foram selecionadas para o grupo 1, 1.071 imagens para o grupo 2, 2.617 imagens para o grupo 3, 3.578 imagens para o grupo 4 e 9.617 imagens para o grupo 5.

Em todas as imagens foram processados os algoritmos de segmentação descritos. Selecionando de maneira randômica 40 imagens de cada grupo, foi possível estabelecer o índice de eficiência das técnicas utilizadas para os conjuntos de imagens, conforme a Tabela 5.1.

Tabela 5.1 – Resultados da Etapa de Segmentação do Método Otsu Threshold

Canal de Aplicação do Otsu	Grupos				
	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
	0% - 20%	20% - 40%	40% - 60%	60% - 80%	80% - 100%
Matiz (<i>Hue</i>)	0,552631	0,789473	0,925	0,825	0,375
Iluminação	0,026315	0	0,25	0,4	0,9

A maioria das imagens pertencentes ao grupo 1 possuem uma resolução bem inferior aos demais grupos e são imagens que ficaram muito claras e as linhas de navegação pouco definidas. O grupo 2 é representado por imagens mais nítidas se comparadas ao grupo anterior, porém muitas delas possuem ruas muito largas, onde é bastante difícil definir os limites das ruas de plantação. O grupo 3 e o grupo 4 apresentam imagens bastante definidas e parecidas. As ruas normalmente se destacam das demais regiões da imagem e é possível entender a eficiência da primeira técnica do threshold nesses dois grupos, uma vez que a técnica foi escolhida para funcionar em imagens com essas características. Contudo, o grupo 4 apresenta também imagens com vegetação não uniforme, onde existem regiões pequenas dentro da área da rua com textura diferente das demais áreas que a compõe.

O grupo 5 é representado por ruas totalmente verdes e que se confundem com a área de plantação das culturas. Além disso, imagens que representam os pomares sem a presença de qualquer área navegável também estão presentes.

Como é possível observar na Tabela 5.1, a aplicação da técnica para o canal Matiz apresentou uma maior eficiência para o grupo de imagens 3 e a aplicação da técnica para o canal de Iluminação apresentou uma maior eficiência para o grupo de imagens 5. Para critério de definição de qual técnica será utilizada definiu-se o valor de 80%, buscando contemplar cada grupo com a técnica que possui uma melhor eficiência.

5.3. Considerações do Capítulo

Nesse capítulo foi possível conhecer os resultados obtidos pelas etapas de processamento do sistema. Algumas situações encontradas durante a etapa de aquisição das imagens foram apresentadas, estas sendo momentos em que as características das regiões em que o veículo estava posicionado eram diferentes de outras encontradas no ambiente, ou quando as características da região em que o veículo estava mudou com sua locomoção. Para cada etapa, foi possível explicar o efeito que as técnicas causavam, onde procurou-se também justificar a utilização das técnicas para otimização dos resultados. O próximo capítulo é destinado as conclusões finais desse trabalho.

6. CONCLUSÕES

As conclusões foram divididas em duas partes: Considerações Finais e Discussões, com o objetivo de apresentar os resultados obtidos nesse trabalho de forma organizada e unificada; e Propostas de Trabalhos Futuros, que tem como objetivo apresentar ideias e alternativas para situações encontradas dentro do problema tratado.

6.1. Considerações Finais e Discussões

Nesse trabalho foi possível analisar uma arquitetura de sistema de visão computacional que, mediante implementações de diversas etapas de processamento, alcançou resultados esperados para segmentação e identificação de regiões em cenários agrícolas.

Devido às características do ambiente estudado, a construção do sistema omnidirecional acabou sendo a parte mais crítica do projeto e algumas dificuldades foram encontradas apenas em fase de testes, tais como a redução da taxa de captura câmera e o custo do processamento de algoritmos como o balanço de branco quando a câmera operava em um ambiente aberto.

Na etapa de aquisição de imagens foi possível identificar que o modelo utilizado pelo sistema de visão demonstrou ser interessante uma vez que possui alta resistência para suportar o peso da câmera e também as vibrações sofridas causadas pelo motor e variações da superfície do terreno.

Nas etapas de pré-processamento, foi possível observar que a eficiência das etapas de segmentação está diretamente ligada a eficiência da combinação de técnicas para o isolamento de regiões importantes do sistema. Assim, as etapas de aplicação de máscara para recorte das imagens e extração do céu devem ser realizadas.

Na etapa de retificação utilizando centro único de projeção, a aplicação do algoritmo pode possibilitar a utilização de métodos e técnicas que exigiriam uma adaptação caso fossem aplicadas diretamente nas imagens omnidirecionais. Ainda assim, a técnica utilizada só irá funcionar corretamente caso o sistema de visão for capaz de manter o correto alinhamento entre os centros focais da câmera e do espelho durante o processo de aquisição de imagens, condição necessária para manter a propriedade de Centro Único de Projeção do espelho hiperbólico.

Analisando a eficiência da etapa de segmentação, foi possível reconhecer que as técnicas estudadas, quando aplicadas em conjunto, garantem a eficiência desejada para todas as ocasiões possíveis encontradas nos ambientes agrícolas. Como fator condicional da execução de cada etapa, o valor de 80% de participação das regiões verdes na imagem foi utilizado. Esse valor foi encontrado analisando a eficiência dos resultados obtidos para as duas técnicas em diferentes grupos de imagens.

A aplicação da técnica de máscara para identificação de caminhos e o algoritmo de limpeza de área foram necessários em diversas situações para destacar as regiões da imagem de interesse. A utilização da técnica, no entanto, é mais indicada nas situações onde a participação das regiões verdes na imagem são superiores a 80%, uma vez que é necessário retirar algumas regiões da imagem que contém grande teor de iluminação. Contudo, em ambos os casos a aplicação da técnica demonstrou melhora nos resultados obtidos.

Embora a combinação de câmeras e espelhos ainda serem pouco utilizadas em ambientes agrícolas, é possível evoluir na aplicação desses sistemas na agricultura quando tomada algumas precauções na fase de aquisição de imagens. A aquisição de imagens do ambiente com alta qualidade torna possível trabalhar tanto com algoritmos já conhecidos na área de navegação, através da retificação das imagens, como também explorar novas possibilidades.

6.2.Propostas de Trabalhos Futuros

Após a apresentação do mecanismo de funcionamento da aplicação e também a averiguação dos resultados obtidos, é possível apontar alguns aspectos a serem melhorados no sistema proposto e algumas linhas de trabalho de continuidade do presente trabalho descritos a seguir.

Apesar de possuir características interessantes para o ambiente tratado, o suporte do sistema de visão pode ser alocado a uma altura maior no veículo utilizado, de forma que a área de interesse da imagem torna-se mais abrangente. Isso permitiria também utilizar máscaras de corte menores para extração da área do reflexo do veículo, aumentando a quantidade de informações no sistema. Além disso, uma nova estrutura poderia ser utilizada, visando contemplar todos os lados do campo de visão do veículo, sem a inclusão causada pela haste do suporte temporário utilizado.

A utilização de uma máscara de corte de formato circular e que esteja corretamente alinhada com o centro-base da retificação da imagem também seria ideal para facilitar a utilização das imagem resultantes nas etapas de pós-processamento da imagem.

Outras técnicas de retificação de imagens omnidirecionais podem ser implementadas, uma vez que a retificação por centro único de projeção cria imagens panorâmicas retificadas com projeção cilíndrica, característica original fornecida pela superfície do espelho. Outras técnicas de transformação de imagens omnidirecionais em imagens panorâmicas ou perspectivas podem ser avaliadas.

Uma etapa de pós-processamento da imagem poderia ser aplicada nos veículos utilizados, onde os cálculos devem ser implementados de acordo com a configuração geométrica do veículo e seus componentes. Outras etapas de pós-processamento também podem ser implementadas futuramente, para análise da eficiência das imagens geradas na solução de problemas da área estudada.

REFERÊNCIAS

- AVRITZER, D. **Geometria analítica e álgebra linear: uma visão geométrica**. Belo Horizonte: Ed. UFMG, 2009. P. 37.
- BAKER, S.; NAYAR, S. K. A theory of single-viewpoint catadioptric image formation. **International Journal of Computer Vision**, Hingham, v. 35, n. 2, p. 175-196, nov., 1999.
- BAKKER, T. et al. A vision based row detection system for sugar beet. **Computers and Electronics in Agriculture**, Amsterdã, v. 60, n. 1, p. 87-95, jan., 2008.
- BALLARD, D. H.; BROWN, C. M. **Computer vision**. 1. ed. Englewood Cliffs: Prentice-Hall, 1982.
- BANCHEV, B.; GEORGIEVA, L. Comparison of pixel based skin recognition techniques. **НАУЧНИ ТРУДОВЕ НА РУСЕНСКИЯ УНИВЕРСИТЕТ**, Ruse, v. 51, n. 3.2, p.170-175, 2012.
- BOGNER, S.L. An introduction to panospheric imaging. **IEEE International Conference on Systems, Man and Cybernetics. Intelligent Systems for the 21st Century**, Vancouver. v. 4, p. 3099-3106, out., 1995.
- BONARINI, A.; ALIVERTI, P.; LUCIONI, M. An omnidirectional vision sensor for fast tracking for mobile robots. **Instrumentation and Measurement Technology Conference**, Veneza, v. 1, p. 151-155, maio, 1999.
- BONEV, B.; CAZORLA, M.; ESCOLANO, F. Robot navigation behaviors based on omnidirectional vision and information theory. **Journal of Physical Agents**, v. 1, n. 1, p.27-35, set., 2007.
- BRADSKI, G. E.; KAEHLER, A. **Learning OpenCV: Computer vision with OpenCV library**. 1. ed. Sebastopol: O'Reilly Media. 2008.

CABRAL, E. L. L.; SOUZA JR., J. C.; HUNOLD, M. C. Omnidirectional stereo vision with a hiberbolic double lobed mirror. **International Conference on Pattern Recognition**, Cambridge, v. 1, p. 1-9, ago., 2004.

CANNY, J. A computational approach to edge detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, Washington, v. 8, n. 6, p.679-698, jun., 1986.

CHAHL, J. AND SRINIVASAN, M. Reflective surfaces for panoramic imaging. **Applied Optics**, v. 36, n.31, p. 8275-8285, nov., 1997.

CHAUMONT, F.; MARHIC, B.; DELAHOUCHE, L. Omnidirectional mirror design: multiple linear ring-windows viewing. **International Symposium on Industrial Electronics**, Ajaccio, Ajaccio v. 1, p. 311-316, maio, 2004.

CHENG H. D., JIANG, X. H., SUN, Y., WANG, J. Color image segmentation: advances and prospects. **Pattern Recognition**, v. 34, n. 12, p. 2259-2281, dez., 2001.

CUTLER, R. et al. Distributed meetings: a meeting capture and broadcasting system. **ACM Multimedia**, Nova Iorque, p. 503-512, dez., 2002.

DEERING, M. The limits of human vision. [S.l.]: 2nd International Immersive Projection Technology Workshop, 1998.

DENG, Y.; MANJUNATH, B. S.; SHIN, H. Color image segmentation. **IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, Fort Collins, v. 2, p. 2446-2451, jun., 1999.

DIAZ, J. F. A. et al. Agribot - Mobile robot to support of agricultural precision activities. **22nd International Congress of Mechanical Engineering, COBEM**, Ribeirão Preto, p. 6243-6254, nov., 2013.

DUDA, R. O.; HART, P. E. Use of the hough transformation to detect lines and curves in pictures. **Communications of the ACM**, Nova Iorque, v. 15. n. 1, p. 11-15, jan., 1972

ERICSON, S.; ÅSTRAND, B. Row-detection on an agricultural field using omnidirectional camera. **International Conference on Intelligent Robots and Systems**, Taipé. p. 4982-4987, out., 2010.

FAIRHURST, M. C. **Computer vision for robotic systems: an introduction**. 1. ed. Englewood Cliffs: Prentice Hall, 1988.

FIALA, M.; BASU, A. Robot navigation using panoramic landmark tracking. **International Conference on Vision Interface**, Calgary, Canada, p. 117-124, 2002.

FISCHLER, M. A.; BOLLES, R. C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. **Communications of the ACM**, Nova Iorque, v.24, n. 6, p.381-395, jun., 1981.

FORSYTH, D. A; PONCE, J. **Computer vision: a modern approach**. 1. Ed. Pearson, 2002.

GEYER, C.; DANIILIDIS, K. Catadioptric projective geometry. **International Journal of Computer Vision**, v. 45, n. 3, p. 223-243, dez., 2001.

GONZALES, R. C.; WOODS, R. E. **Digital image processing**. 3. Ed. Englewood Cliffs: Prentice-Hall, 2007.

GONZALES, R. C.; WINTZ, P. **Digital image processing**. 2. Ed. Reading: Assison-Wesley Publishing Company, 1987.

GRASSI JR, V.; OKAMOTO JR., J. Development of an omnidirectional vision system. **Mechatronics and Machine Vision in Practice**, Xiamen, p. 217-222, dez., 2007.

GRASSI JR., V.; OKAMOTO JR., J. Visual servo control of a mobile robot using omnidirectional vision. **Proceedings of Mechatronics 2002**, Enschede, v. 8. p. 413-422, jun., 2002.

GRASSI JR., V.; OKAMOTO JR., J. Desenvolvimento de um sistema de visão omnidirecional. **Congresso Brasileiro de Engenharia Mecânica**, Uberlândia, v. 15, p. 28-37, nov., 2001.

HALLIDAY, D.; RESNICK, R.; WALKER, J. **Fundamentos de Física: Óptica e Física Moderna**. 4. ed. São Paulo: Editora LTC, 1995.

HECHT, E. **Optics**. 3. ed. Pearson Education, 1997.

HICKS, R.; BAJCSY, R. Catadioptric sensors that approximate wide-angle perspective projections. **IEEE Conf. Computer Vision and Pattern Recognition**, Hilton Head Island, v. 1, p. 545–551, jun., 2000.

HONG, J. et al. Image-based homing. **IEEE Int. Conf. on Robotics and Automation**, Sacramento, v. 1, p. 620–625, abr., 1991.

IGEL, C.; HÜSKEN, M. Empirical evaluation of the Improved Rprop Learning Algorithms. **Neurocomputing**, v. 50, p. 105-123, 2003.

ISHIGURO, H. Development of low-cost compact omnidirectional vision sensors and their applications. **International Conference on Information Systems, Analysis and Synthesis**, p. 433–439, 1998.

JIANG, G.; ZHAO, C. A vision system based crop rows for agricultural mobile robot. **International Conference on Computer Applications and System Modeling**, Taiyuan, v. 11, p. 142-145, out., 2010.

JIANG, H. et al. Curve path detection of unstructured roads for the outdoor robot navigation. **Mathematical and Computer Modelling**, v. 58, n. 3-4, p. 536-544, ago., 2013.

LEVINE, M. D. **Vision in man and machine**. Nova Iorque: McGraw-Hill Book Co. 1985.

LI, M. et al. Position estimation method for agricultural field road. **International Conference on New Technology of Agricultural Engineering (ICAE)**, Zibo, p. 126-129, maio, 2011.

LI, M. et al. Artificial landmark positioning system using omnidirectional vision for agricultural vehicle navigation. **International Conference on Intelligent Systems Design and Engineering Application**, Sanya, p.665-669, jan., 2012.

LUCAS, B. D.; KANADE, T. An iterative image registration technique with an application to stereo vision. **Proceedings of the 7th international joint conference on Artificial intelligence**, Vancouver, v. 2, p. 674-679, ago., 1981.

LULIO, L. C. **Técnicas de visão computacional aplicadas ao reconhecimento de cenas naturais e locomoção autônoma em robôs agrícolas móveis**. 2011. 353 f. Dissertação (Mestrado em Engenharia Mecânica) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 2011.

LULIO, L. C.; TRONCO, M. L.; PORTO, A. J. V. ANN statistical image recognition method for computer vision in agricultural mobile robot navigation. **International Conference on Mechatronics and Automation**. Xian, p. 1771-1776, ago., 2010.

MAOHAI, L.; HAN, W.; SUN, L.; ZESU, C. Robust omnidirectional mobile robot topology navigation system using omnidirectional vision. **Engineering Applications of Artificial Intelligence**, Tarrytown, v. 26, n. 8, p. 1942-1952, set., 2013.

MOLIN, J. P. Tendências da agricultura de precisão no Brasil. **Congresso Brasileiro de Agricultura de Precisão**, Piracicaba, p. 1-10, maio, 2004.

MOREL, J.M., YU, G, ASIFT: a new framework for fully affine invariant image comparison. **SIAM Journal on Imaging Sciences**, Philadelphia, v. 2, n. 2, p. 438-469, abr., 2009.

NAYAR, S. Catadioptric omnidirectional camera. **IEEE Computer Society Conference**, San Juan, p. 482-488, jun., 1997.

NAYAR, S. K.; BAKER, S. Catadioptric image formation. **Darpa Image Understanding Workshop**, San Francisco, maio, 1997.

NEPAS. **Núcleo de ensino e pesquisa em automação e simulação: AgriBOT**. Disponível em: <<http://www.simulacao.eesc.sc.usp.br/roboticaagricola/index.php/robos-agricolas/agribot>>. Acesso em: 3 ago. 2014.

ORTIZ, J. M.; OLIVARES, M. A vision based navigation system for an agricultural field robot. **IEEE 3rd Latin American Robotics Symposium, LARS '06**, Santiago, p. 106-114, out., 2006.

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Trans. on Systems Man and Cybernetics**, v. 9, n. 1, p. 63–66, jan., 1979.

PEREIRA, R. R. D. **Protocolo ISO 11783: Procedimentos para comunicação serial de dados com o Controlador de Tarefas**. 2008. 188f. Dissertação (Mestrado Engenharia Mecânica) – Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos. 2008.

PERI, V.; NAYAR, S.K. Generation of perspective and panoramic video from omnidirectional video. **Darpa Image Understanding Workshop**, San Francisco, maio, 1997.

PONS, J. S. et al. Vision-based robot homing in dynamic environments. **RA '07 Proceedings of the 13th IASTED International Conference on Robotics and Applications**, Anaheim, p. 293-298, 2007.

REES, D. W., **Panoramic television viewing system**, United States Patent US3505465 A, 21 Apr. 1967, 7 Apr. 1970.

RUSSELL, S.; NORVIG, P. **Inteligência artificial**. 1. ed., São Paulo: Editora Campus. 2004.

SEMARY, N. A; HADHOUD, M. M.; ABBAS, A. M. An effective compression technique for HSL color model. **The Online Journal on Computer Science and Information Technology**, v. 1, n. 1, p. 29-33, abr. 2011.

SHAH, S.; AGGARWAL, J. K.. Intrinsic parameter calibration procedure for a (high distortion) fish-eye lens camera with distortion model and accuracy estimation. **Pattern Recognition Society**, v. 29, n. 11, p. 1775–1788, 1996.

SHAPIRO, L. G. STOCKMAN, G. **Computer Vision**. 1. ed., Englewood Cliffs: Prentice Hall, 2001.

SHUM, H.-Y.; SZELISKI, R. Systems and experiment paper: Construction of panoramic image mosaics with global and local alignment. **International Journal of Computer Vision**, v. 36, n. 2, p.101–130, fev., 2000.

SOUZA, G. G. **Visão estéreo omnidirecional catadióptrica com espelho de lobo duplo aplicado na geração de grades de evidências**. 2009. 131f., Tese (Doutorado em Ciências Mecânicas), Departamento de Engenharia Mecânica, Universidade de Brasília, Brasília, 2009.

SOUZA, G.G.; MOTTA, J.M.S.T. Simulation of an omnidirectional catadioptric vision system with hyperbolic double lobed mirror for robot navigation. **In: ABCM Symposium Series in Mechatronics**, v. 3, p. 613-622, 2008.

SRINIVASAN, M.; WEBER, K.; VENKATESH, S. **From living eyes to seeing machines**. 1 ed., New York, Oxford University Press, 1997

SVOBODA, T.; PADJLA, T.; HLAVÁČ, V. Central panoramic cameras: design and geometry. **Third Computer Vision Winter Workshop**, Gozd Martuljek, 1998.

SWINTON, S. M.; LOWENBERG-DEBOER, J. **Evaluating the profitability of site-specific farming**, Journal of Production Agriculture, Madison, v.11, n.4, p. 439-446. 1998.

TABILE, R. A. **Desenvolvimento de uma plataforma robótica modular e multifuncional para aquisição de dados em agricultura de precisão**. 2012. 103 f., Tese (Doutorado em Engenharia), Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

VASSALO, R. F. **Uso de mapeamentos visuomotores com imagens omnidirecionais para aprendizagem por imitação em robótica.** 2004. 119 f., Tese (Doutorado em Engenharia Elétrica/Automação), Programa de Pós Graduação da Engenharia Elétrica, Universidade Federal do Espírito Santo, Vitória, 2004.

WINTERS, N. et al. Omni-directional vision for robot navigation. **Proc. IEEE Workshop on Omnidirectional Vision.** Hilton Head Island, p. 21-28, 2000.

WINTERS, N. **A holistic approach to mobile robot navigation using omnidirectional vision.** 2001. 157 f., Tese (Ph.D.), Departamento de Ciência da Computação, Universidade de Dublin, Irlanda, 2001.

XUE, J.; ZHANG, L.; GRIFT, T. E. Variable field-of-view machine vision based row guidance of an agricultural robot. **Computers and Electronics in Agriculture**, v. 84, p. 85-91, jun, 2012.

YAGI, Y. Omnidirectional sensing and its application. **IEICE Transactions on Information and Systems**, v.3, p. 568-579, 1999.

YANG, L.; NOGUCHI, N. Human detection for a robot tractor using omni-directional stereo vision. **Computers and Electronics in Agriculture**, v. 89, p. 116-125, nov., 2012.

YAMAZAWA, K.; YAGI, Y.; YACHIDA, M. Omnidirectional imaging with hyperboloidal projection. **Proceedings of the International Conference on Robots and Systems**, Yokohama, v. 2, p. 1029-1034, jul., 1993.

YI, S. AHUJA, N. An omnidirectional stereo vision system using single camera. **In. 18th International Conference on Pattern Recognition - ICPR**, Hong Kong, p. 861–865, 2006.

YING, X.; HU, Z. Catadioptric camera calibration using geometric invariants. **Pattern Analysis and Machine Intelligence**, v. 26, n. 10, p. 1260-1271, out., 2004.

ZHANG, Z., Flexible camera calibration by viewing a plane from unknown orientations. **In: IEEE International conference on computer vision - ICCV'99**, Kerkyra, p. 666–673, sep. 1999.

ZHANG, Z. A flexible new technique for camera calibration. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 22, n. 11, p. 1330–1334, nov. 2000.

ZHANG, J. et al. Monocular visual navigation of an autonomous vehicle in natural scene corridor-like environments. **IEEE/RSJ International Conference on Intelligent Robots and Systems**, Vilamoura, p. 3659-3666, out., 2012.

APÊNDICE A – ANÁLISE DE SITUAÇÕES ENCONTRADAS

A.1 Primeira Situação

Na primeira situação é possível analisar o momento em que o veículo sai de uma linha de plantio e encontra outro caminho com características visuais diferentes.

A.1.1 Momento 1

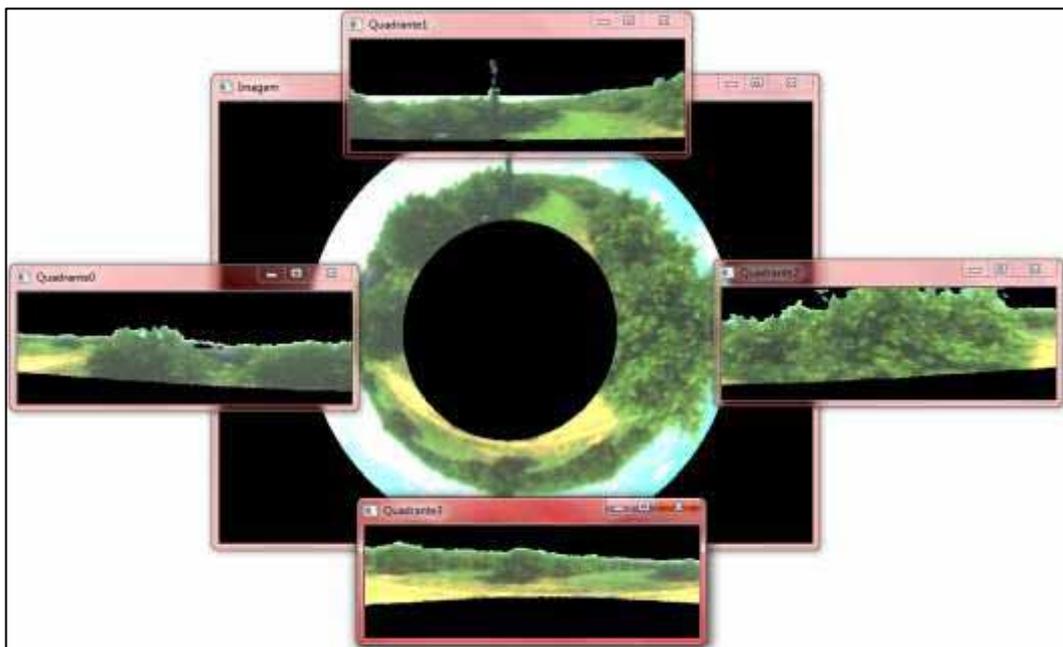


Figura A.1 - Imagem global da situação analisada



Figura A.2 - Imagem omnidirecional obtida pelo sistema de visão



Figura A.3 - Resultado da Etapa de Extração do Céu das Imagens

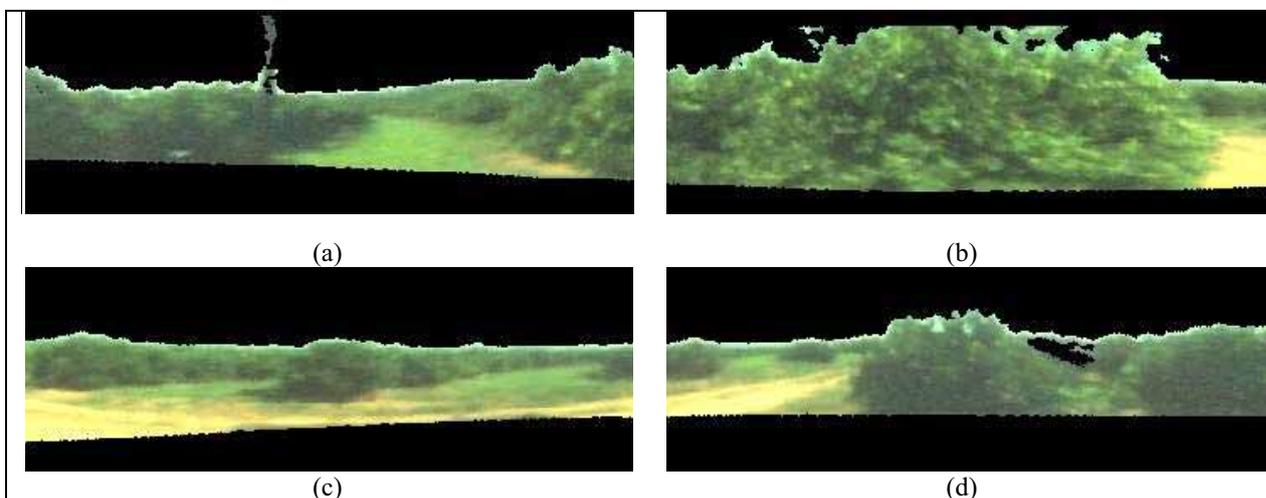


Figura A.4 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

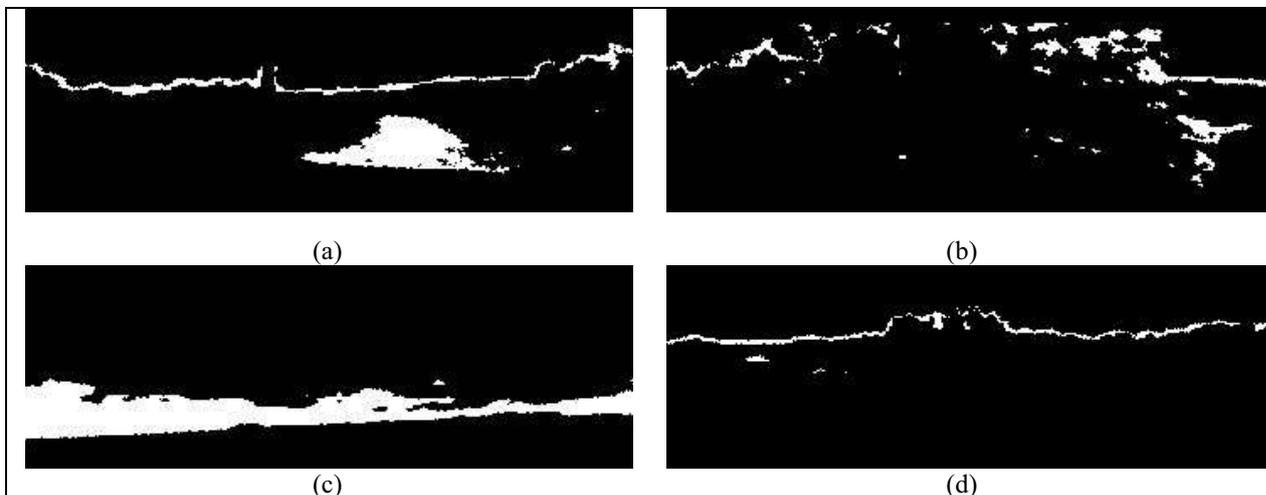


Figura A.5 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. No quadrante (a), (b) e (d) foi aplicada a técnica para o canal de iluminação, e no quadrante (c) foi aplicada a técnica para o canal *Hue*.



Figura A.6 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A.1.2 Momento 2

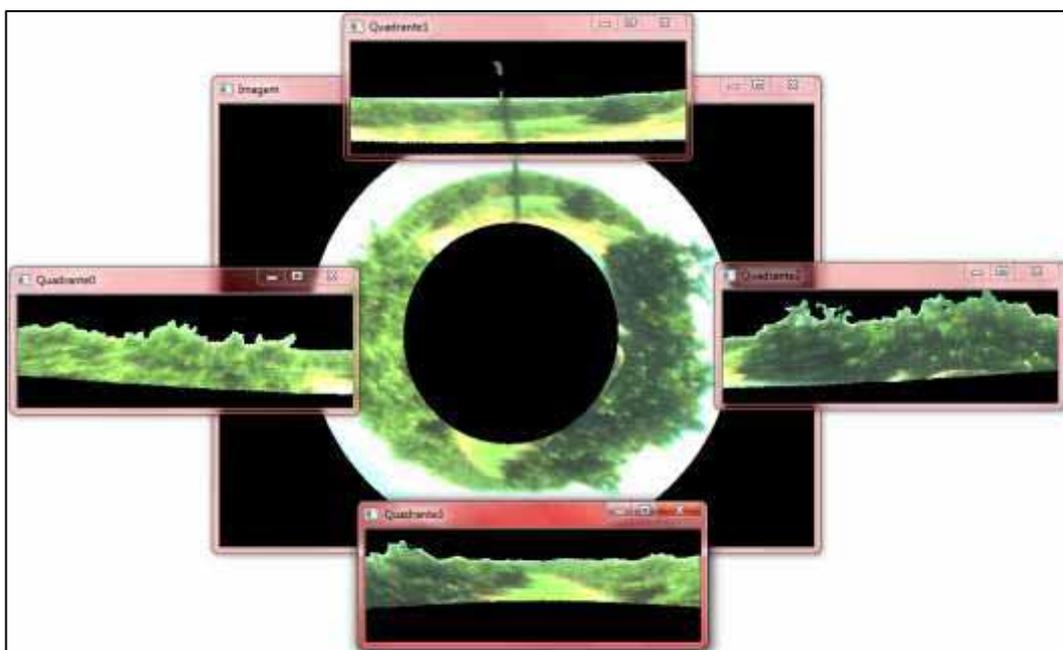


Figura A.7 - Imagem global da situação analisada



Figura A.8 - Imagem omnidirecional obtida pelo sistema de visão

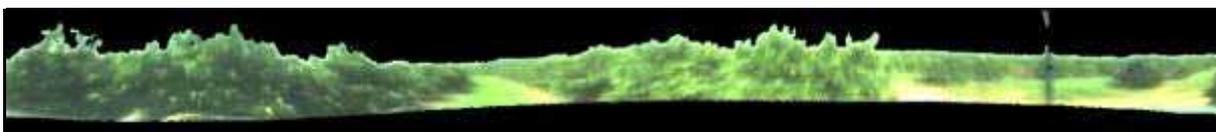


Figura A.9 - Resultado da Etapa de Extração do Céu das Imagens

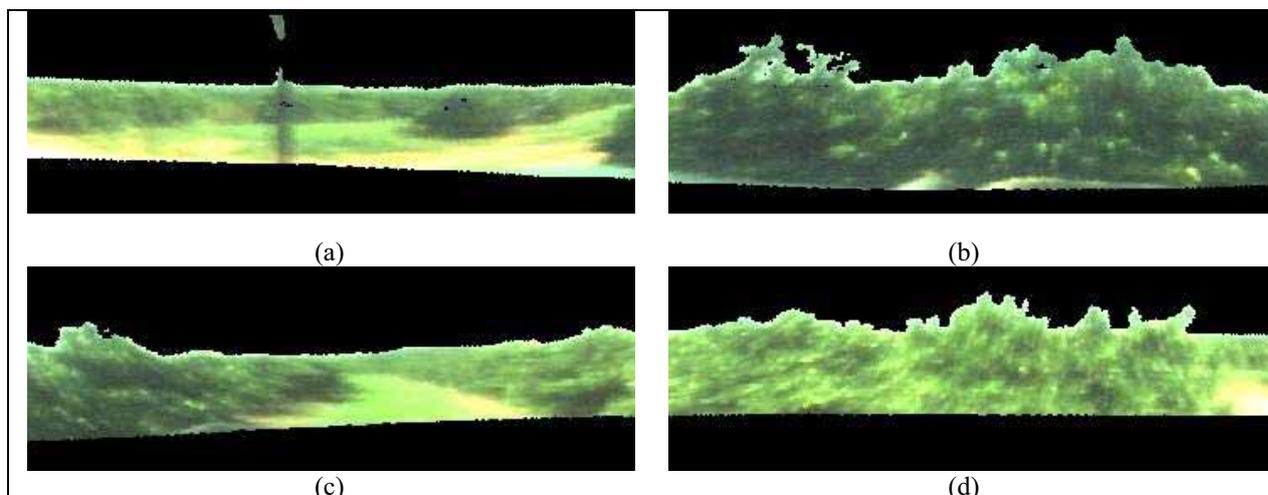


Figura A.10 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

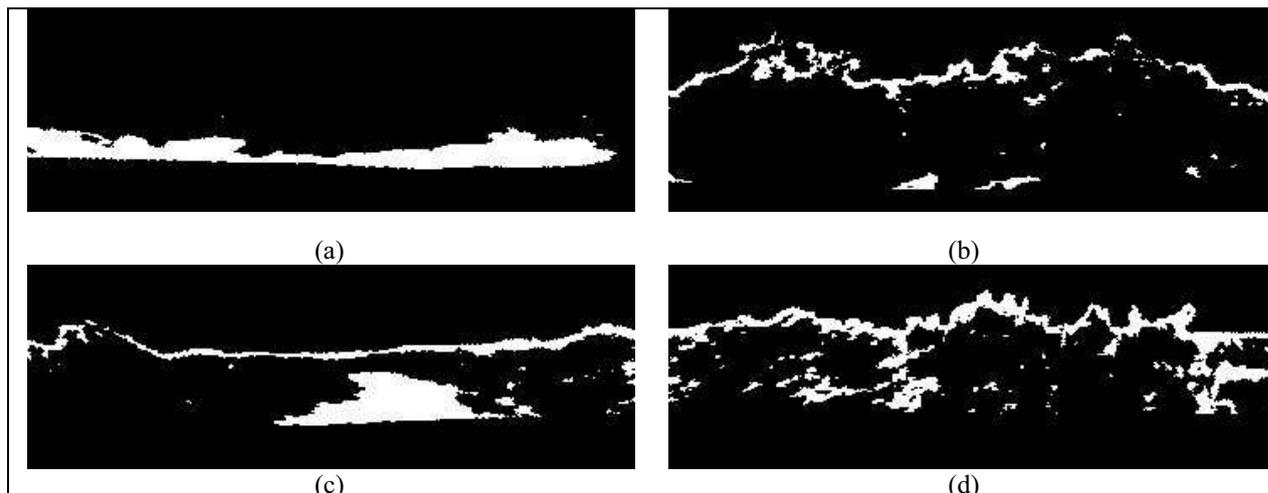


Figura A.11 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. No quadrante (a) foi aplicada a técnica no canal *Hue* da imagem, e em (b), (c) e (d) foi aplicada a técnica no canal de Iluminação da imagem.



Figura A.12 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A.2 Segunda Situação

Na segunda situação é possível analisar o momento que o veículo se encontra realizando a navegação entre linhas de plantio de pomares.

A.2.1 Momento 1

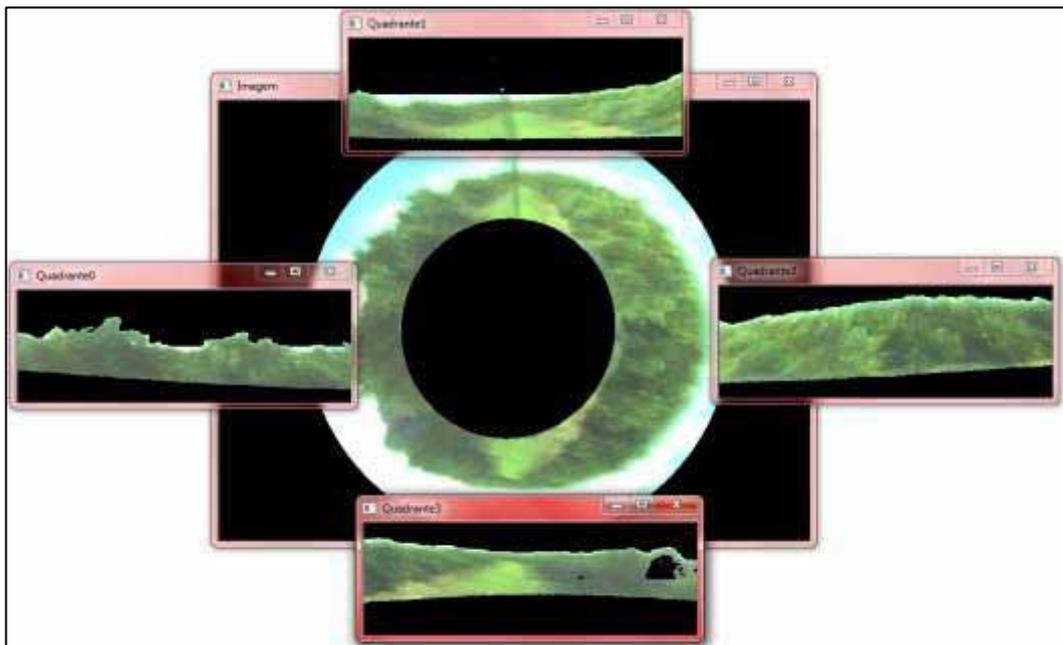


Figura A.13 - Imagem global da situação analisada



Figura A.14 - Imagem omnidirecional obtida pelo sistema de visão



Figura A.15 - Resultado da Etapa de Extração do Céu das Imagens

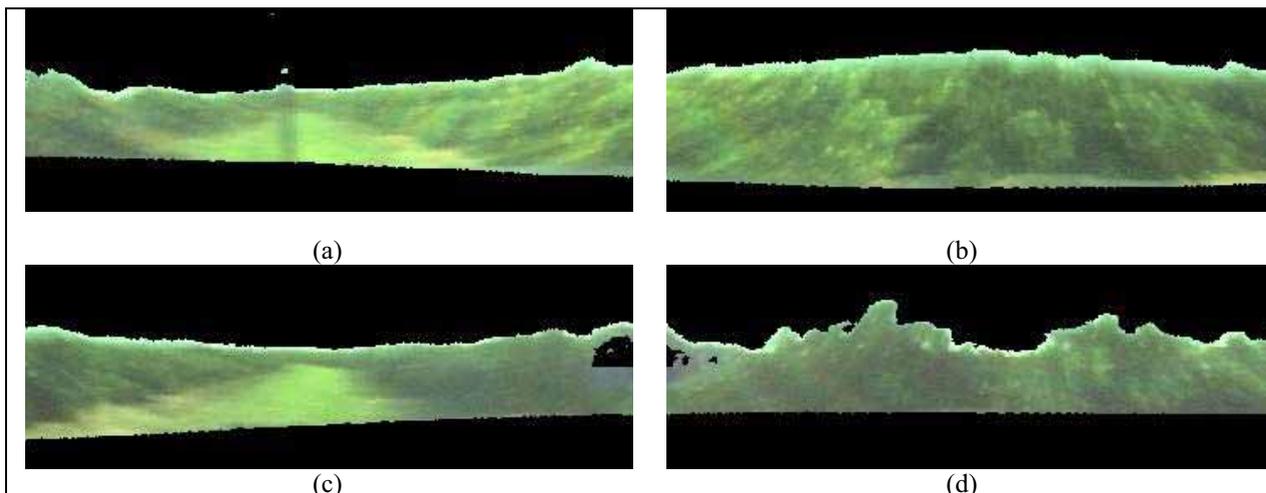


Figura A.16 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

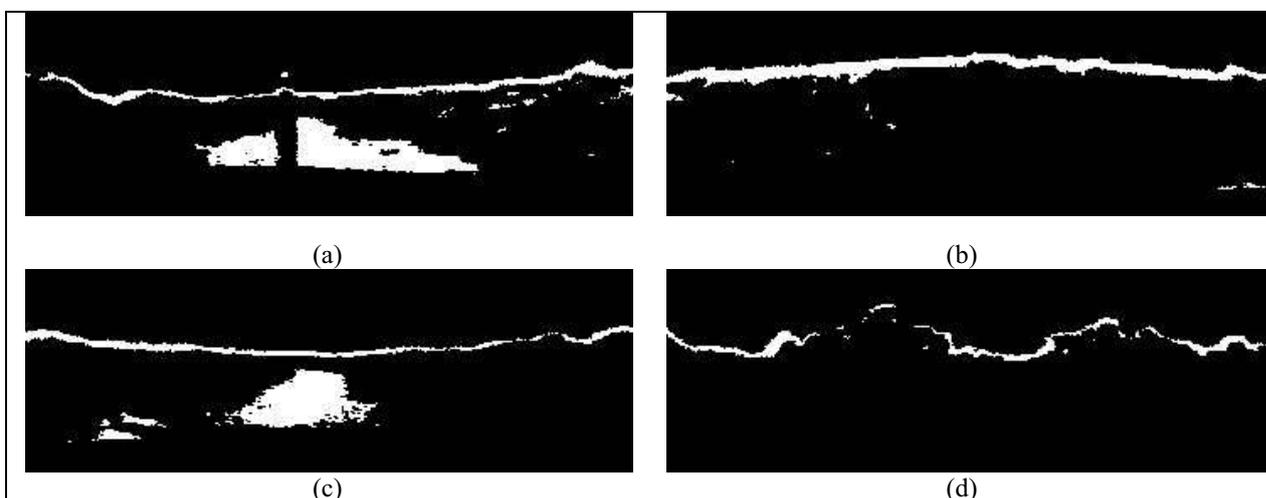


Figura A.17 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica de Iluminação da imagem.



Figura A.18 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A.2.2 Momento 2

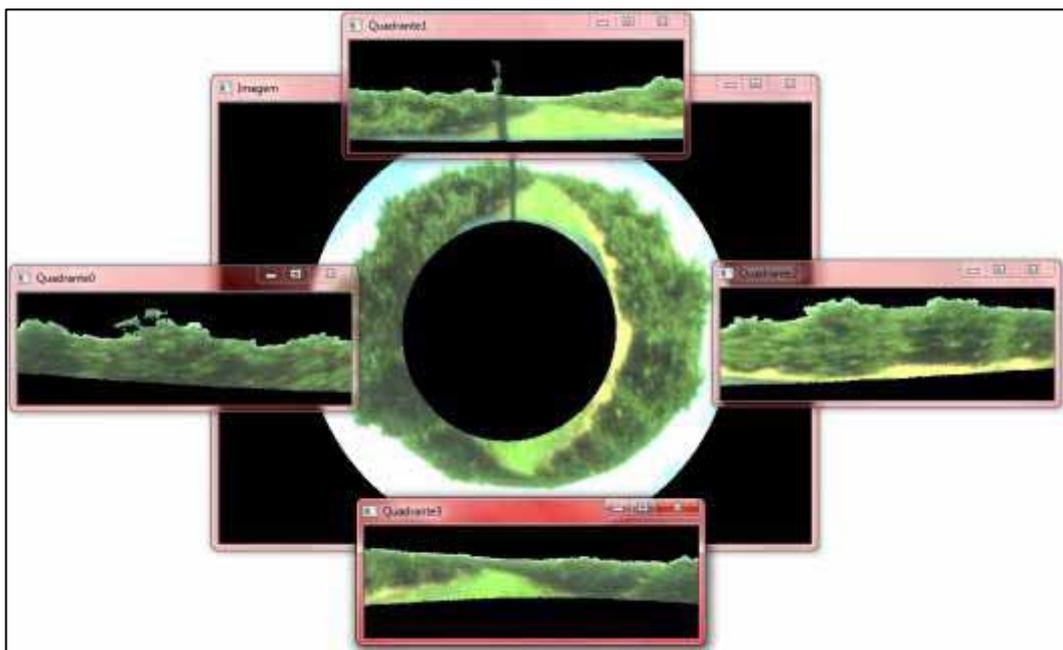


Figura A.19 - Imagem global da situação analisada



Figura A.20 - Imagem omnidirecional obtida pelo sistema de visão

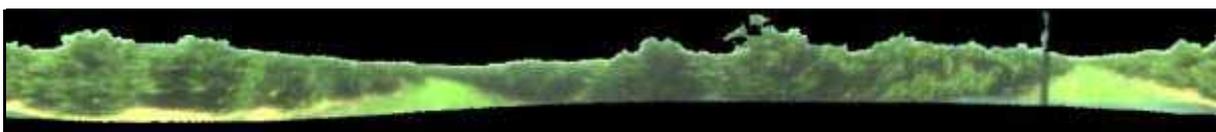


Figura A.21 - Resultado da Etapa de Extração do Céu das Imagens

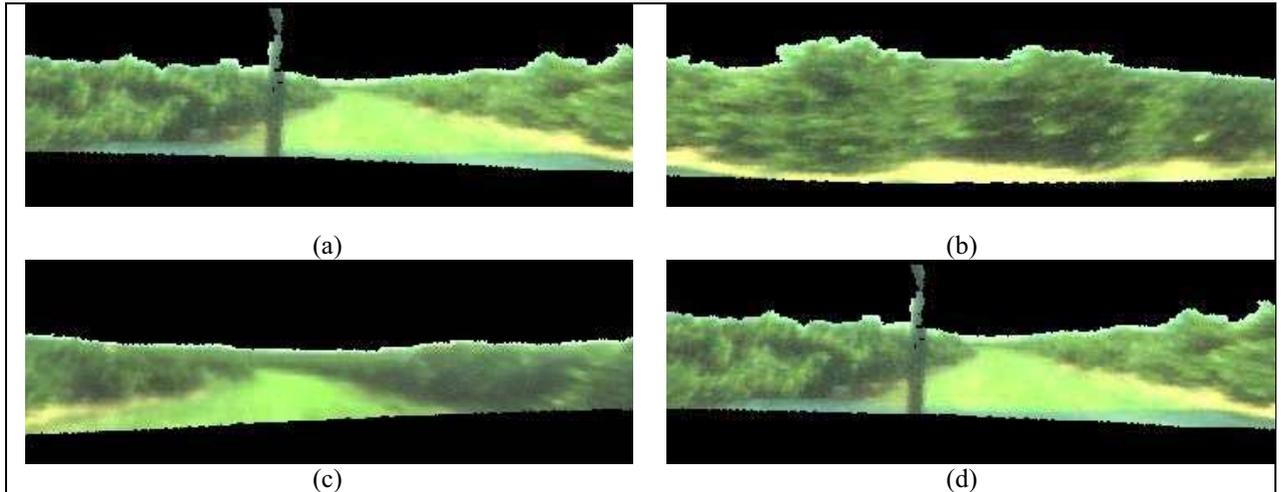


Figura A.22 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

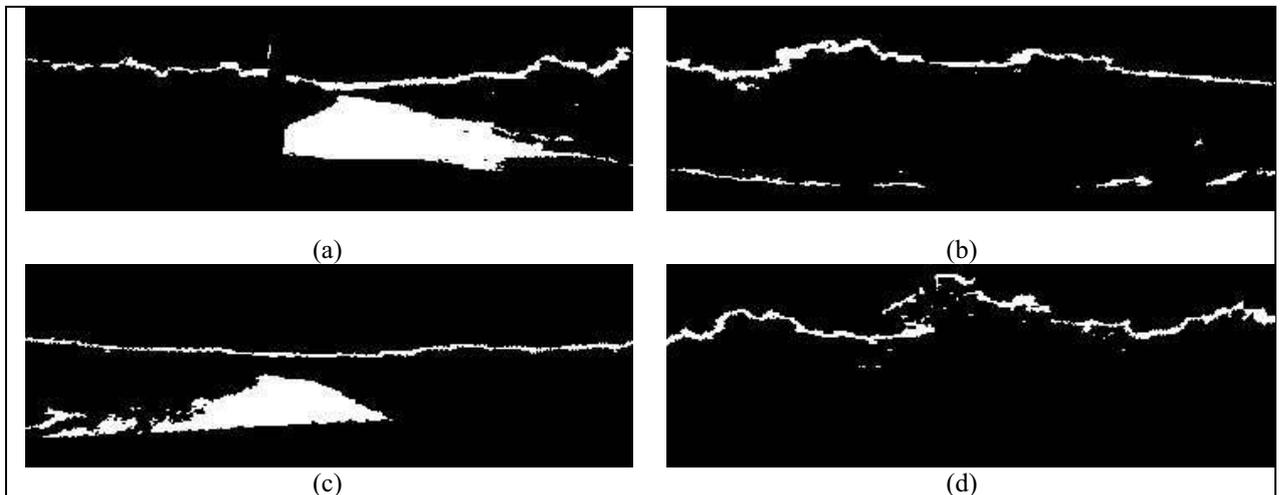


Figura A.23 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica de Iluminação da imagem.

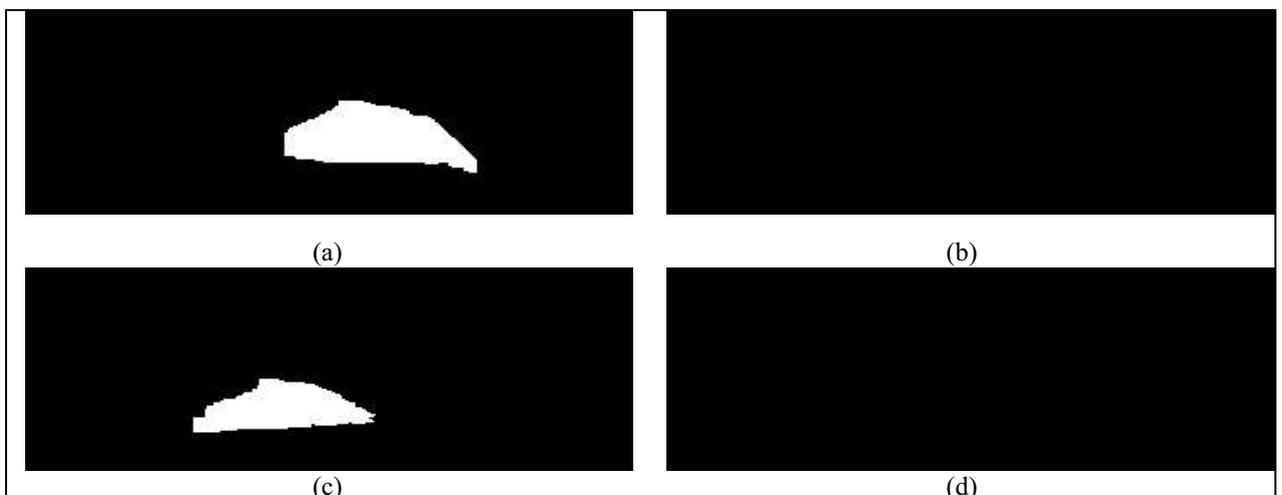


Figura A.24 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A.3 Terceira Situação

Na terceira situação é possível analisar o momento em que um veículo navega em uma área de navegação bem definida no cenário natural e, durante a aquisição, é possível identificar outras regiões de interesse no cenário.

A.3.1 Momento 1

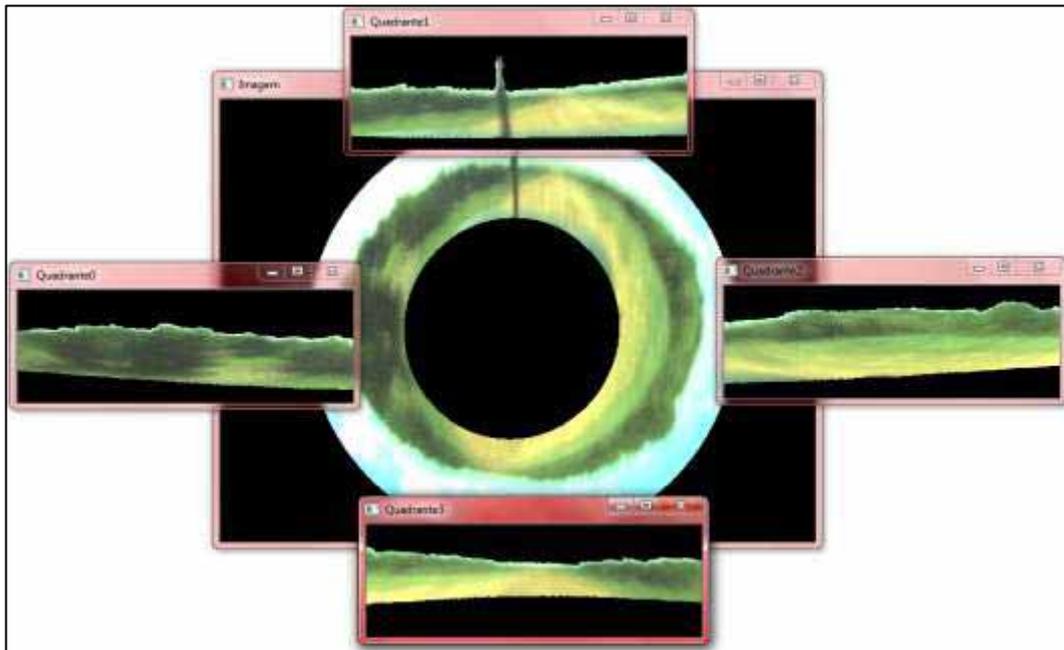


Figura A.25 - Imagem global da situação analisada

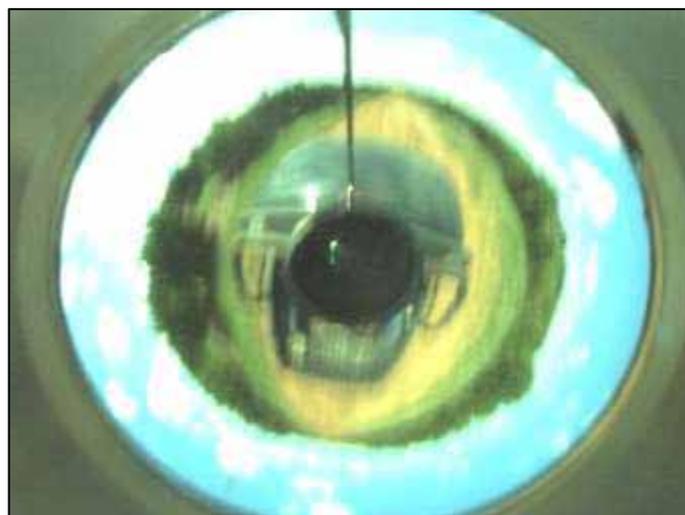


Figura A.26 - Imagem omnidirecional obtida pelo sistema de visão

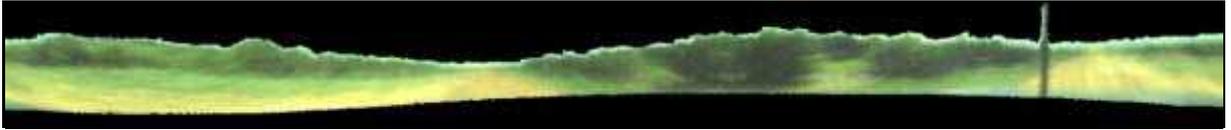


Figura A.27 - Resultado da Etapa de Extração do Céu das Imagens

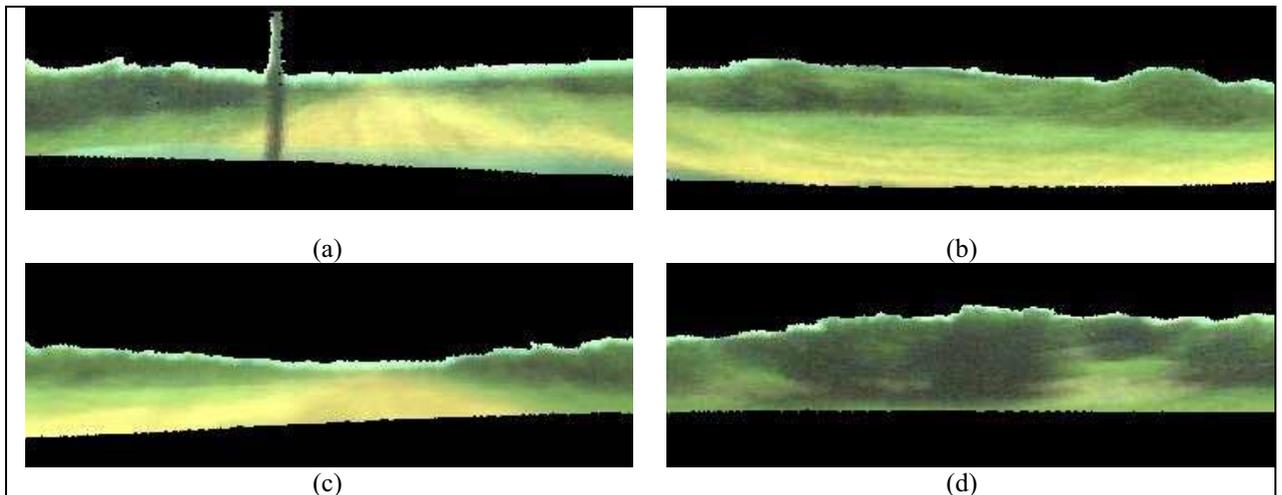


Figura A.28 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

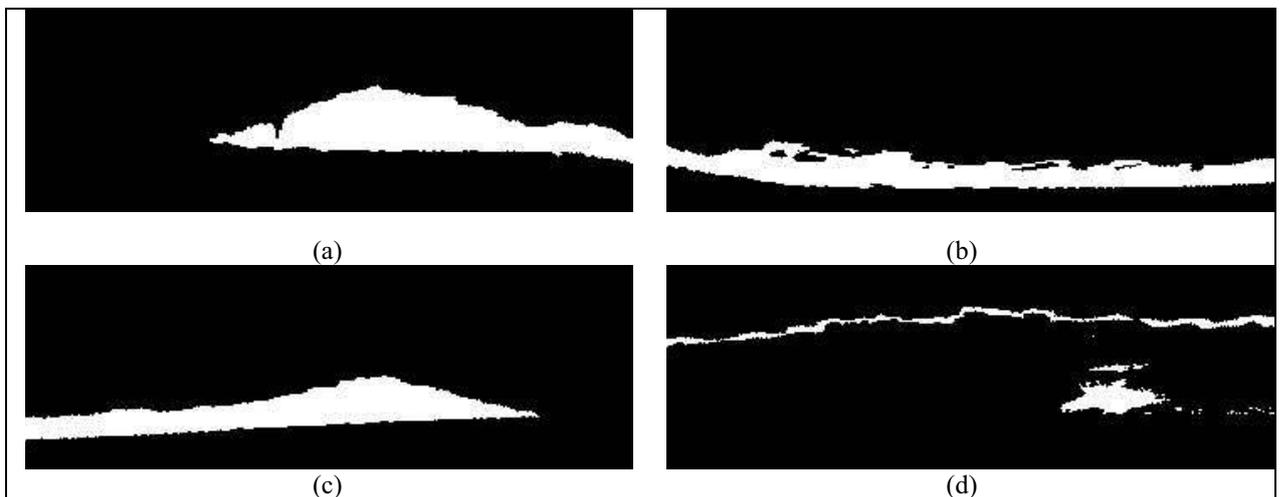


Figura A.29 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Nos quadrantes (a), (b) e (c) a técnica foi aplicada no canal *Hue*, e em (d) a técnica foi aplicada no canal de iluminação.

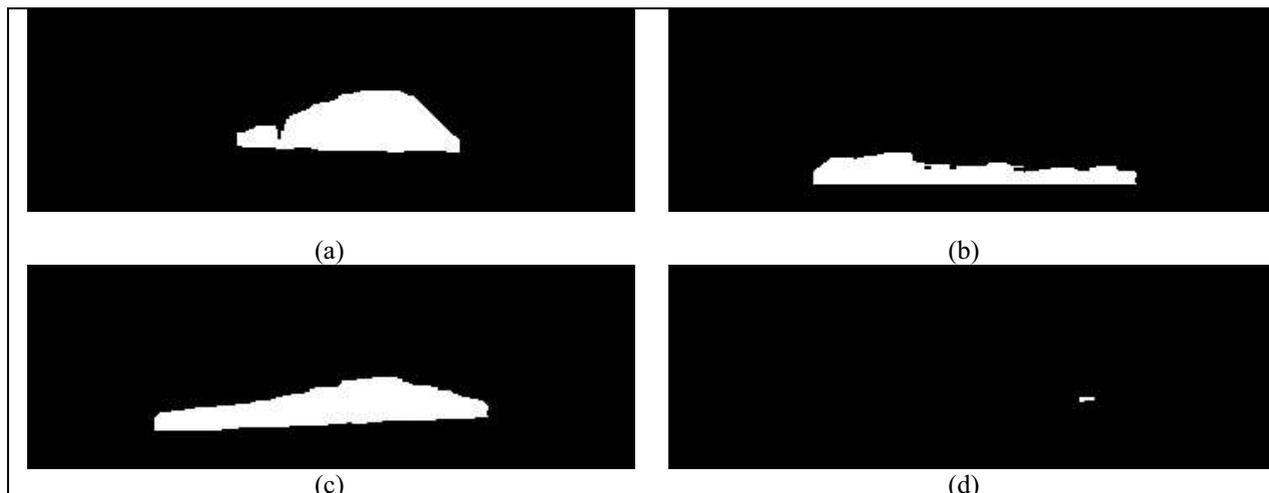


Figura A.30 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A.3.2 Momento 2

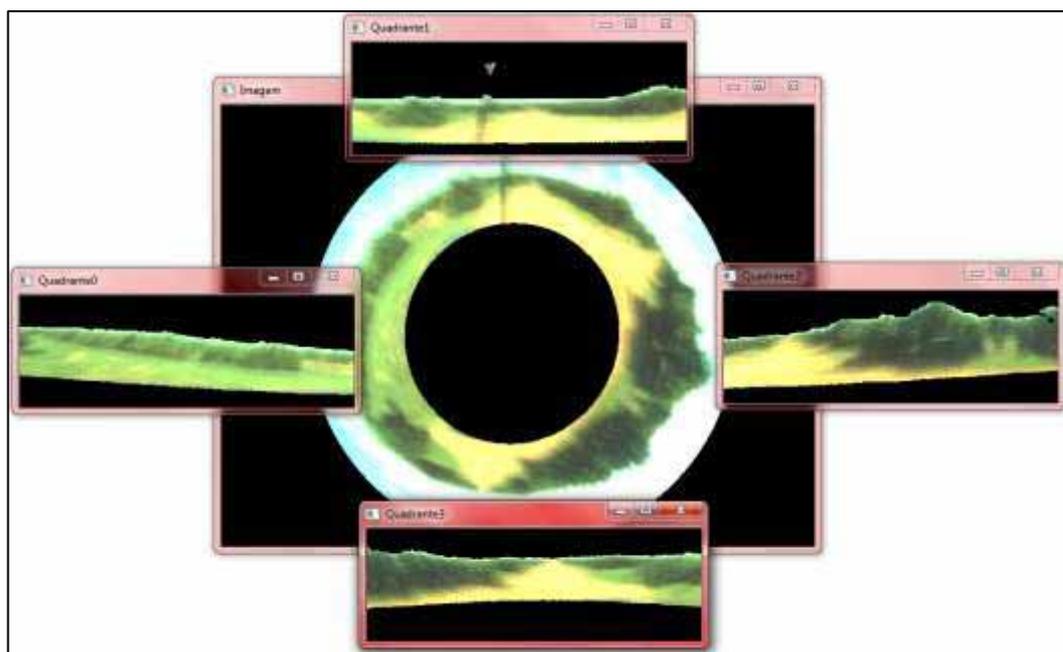


Figura A.31 - Imagem global da situação analisada



Figura A.32 - Imagem omnidirecional obtida pelo sistema de visão

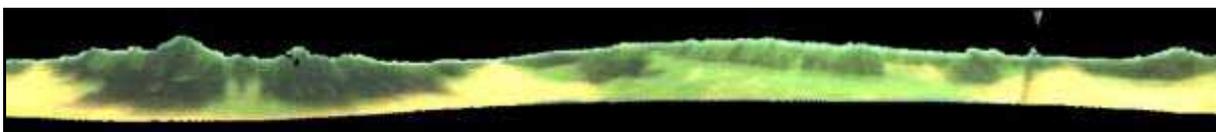


Figura A.33 - Resultado da Etapa de Extração do Céu das Imagens

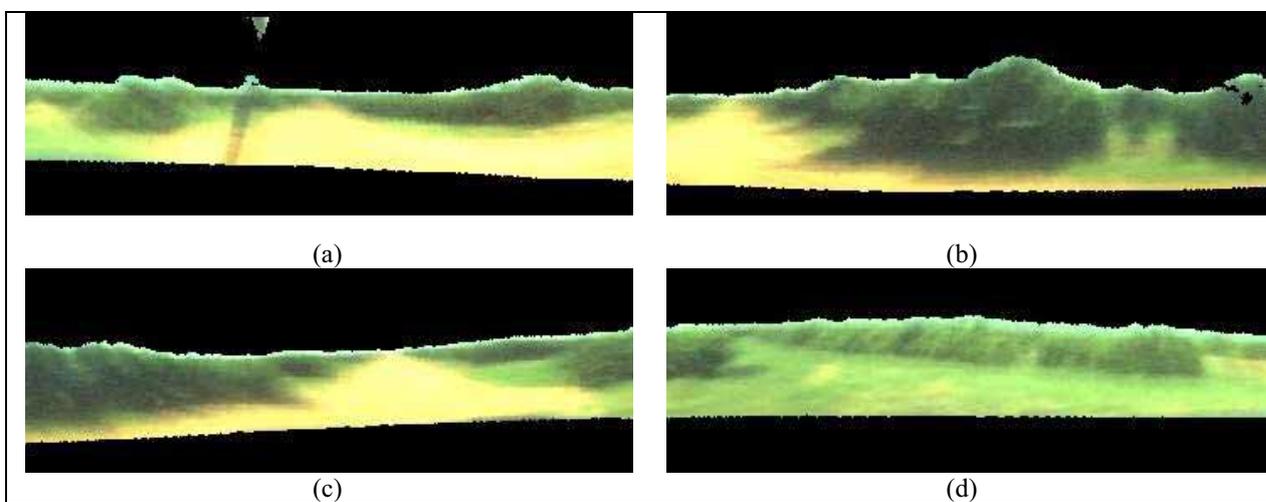


Figura A.34 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

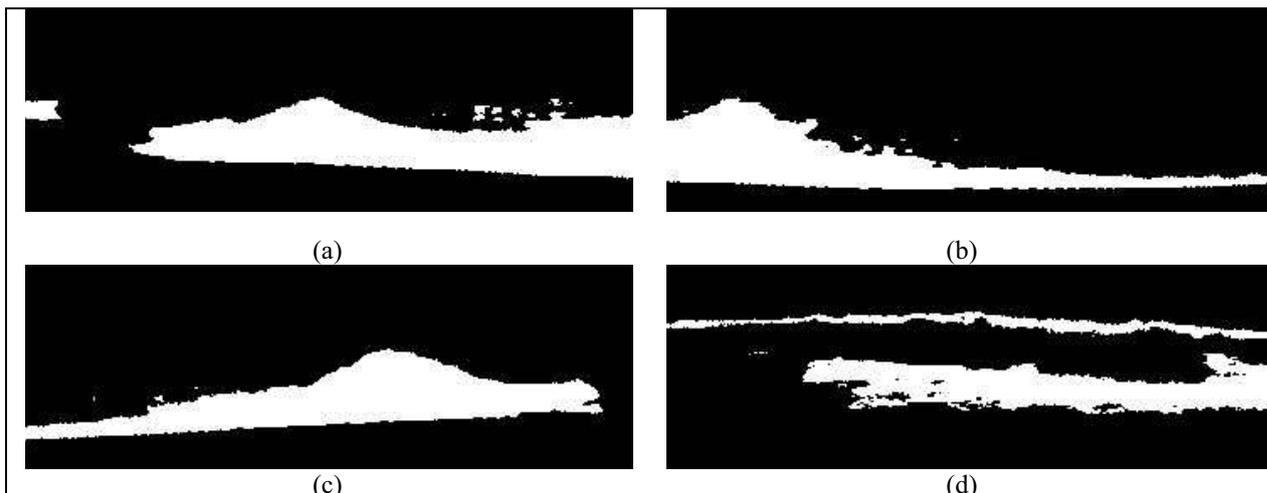


Figura A.35 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Nos quadrantes (a), (b) e (c) foi aplicada a técnica no canal *Hue*, e em (d) foi aplicada a técnica no canal de iluminação.

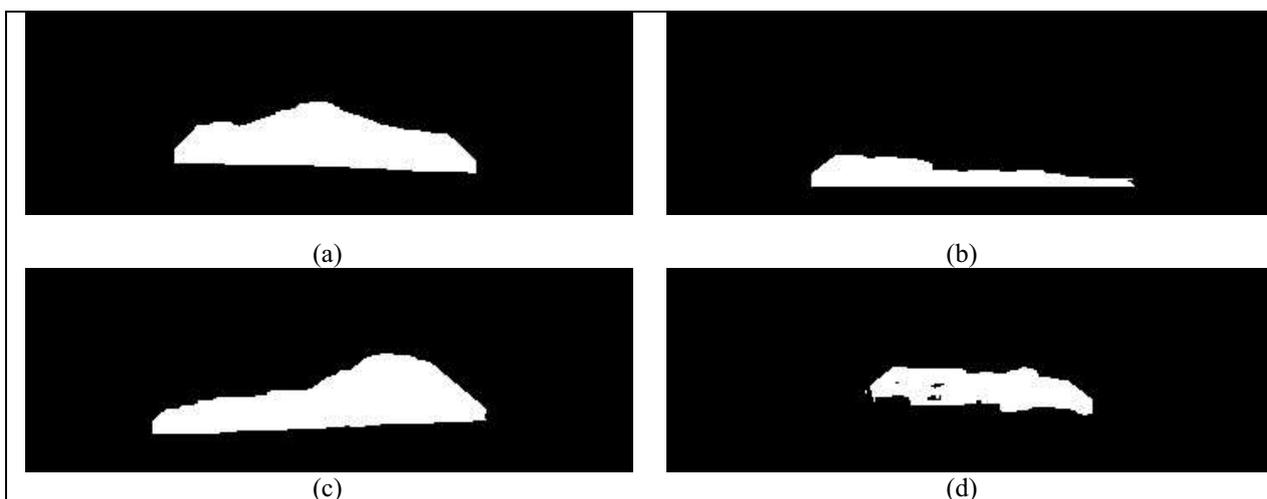


Figura A.36 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A.4 Quarta Situação

Na quarta situação é possível analisar o momento que o veículo inicia sua trajetória em uma linha de navegação e há no ambiente outras regiões de interesse.

A.4.1 Momento 1

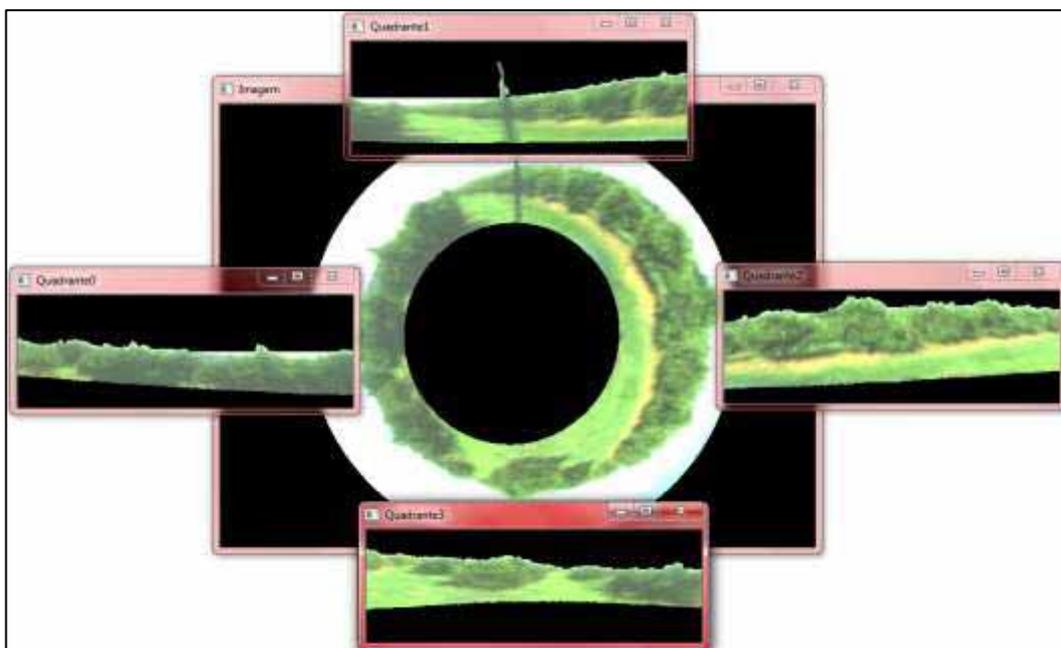


Figura A.37 - Imagem global da situação analisada



Figura A.38 - Imagem omnidirecional obtida pelo sistema de visão



Figura A.39 - Resultado da Etapa de Extração do Céu das Imagens

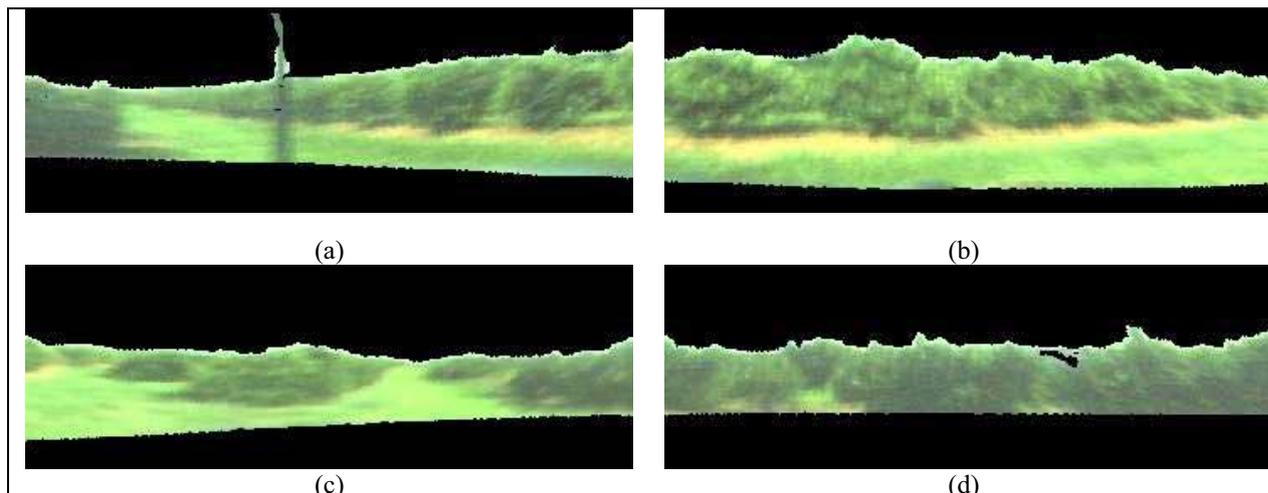


Figura A.40 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

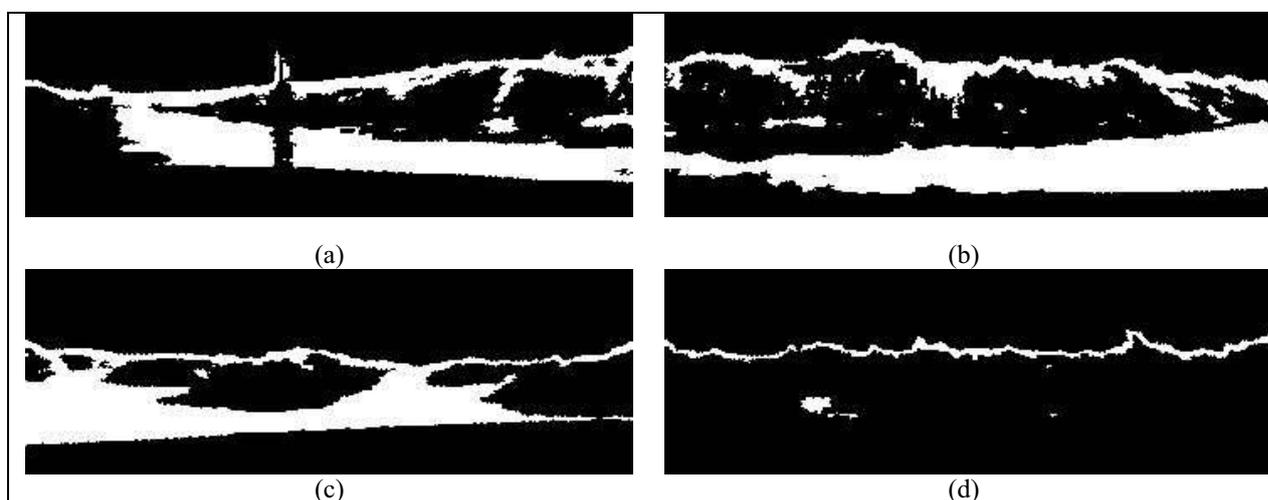


Figura A.41 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes a técnica foi aplicada no canal de iluminação.

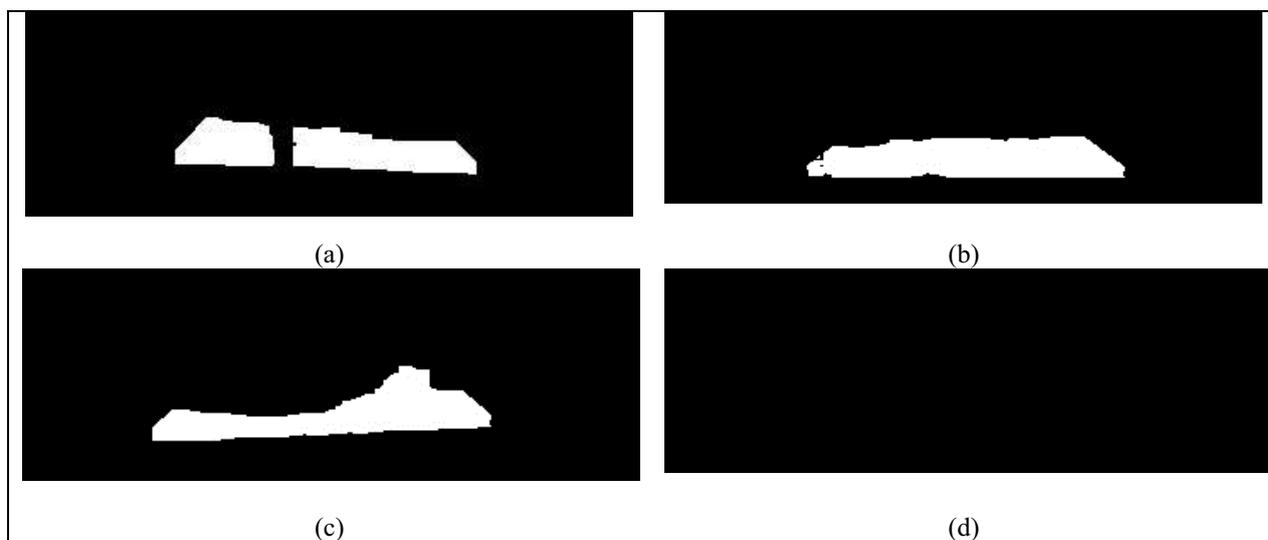


Figura A.42 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A.4.2 Momento 2

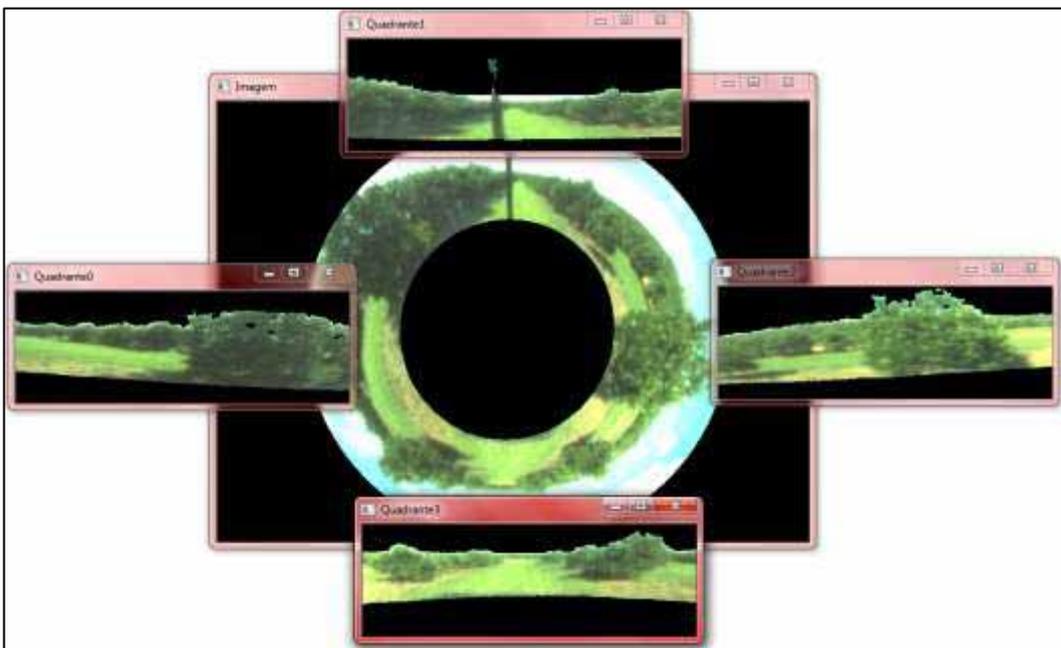


Figura A.43 - Imagem global da situação analisada



Figura A.44 - Imagem omnidirecional obtida pelo sistema de visão



Figura A.45 - Resultado da Etapa de Extração do Céu das Imagens

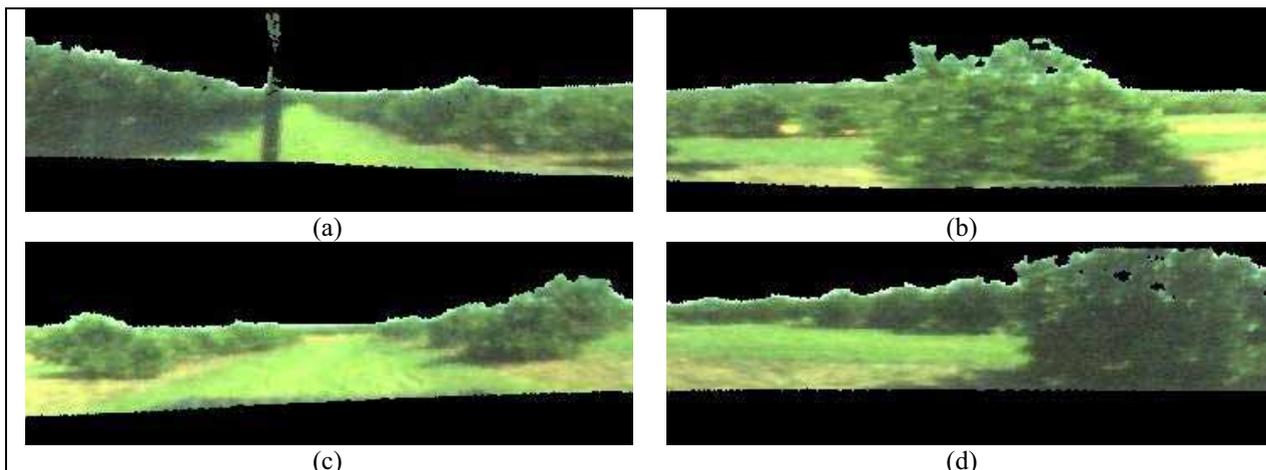


Figura A.46 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

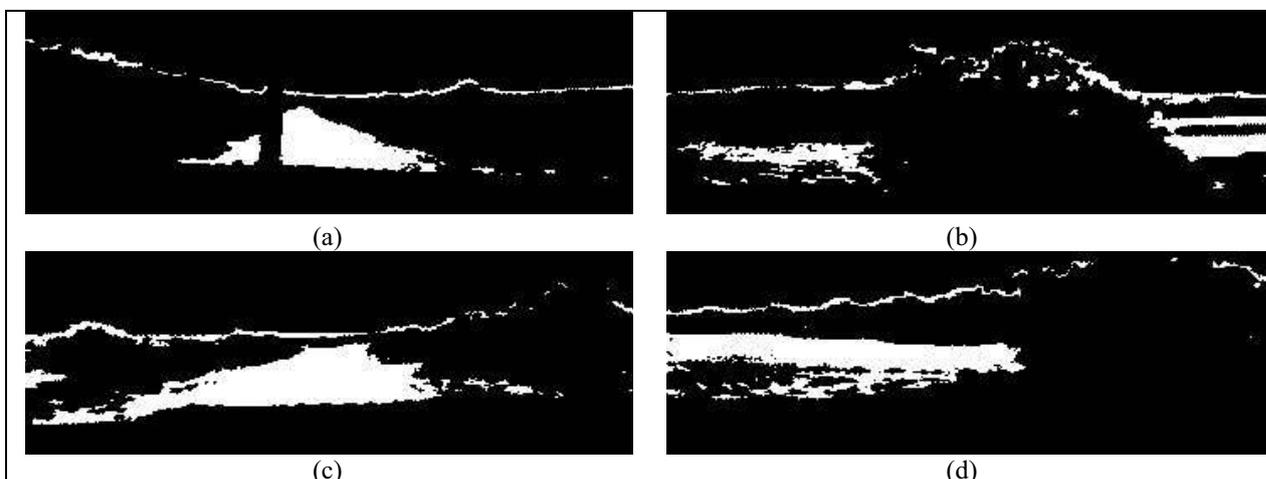


Figura A.47 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes a técnica foi aplicada no canal de iluminação.



Figura A.48 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A.5 Quinta Situação

Na quinta situação é possível analisar o momento que o veículo navega entre as ruas de navegação e as árvores que formam as linhas de plantio apresentam diferentes níveis de iluminação.

A.5.1 Momento 1

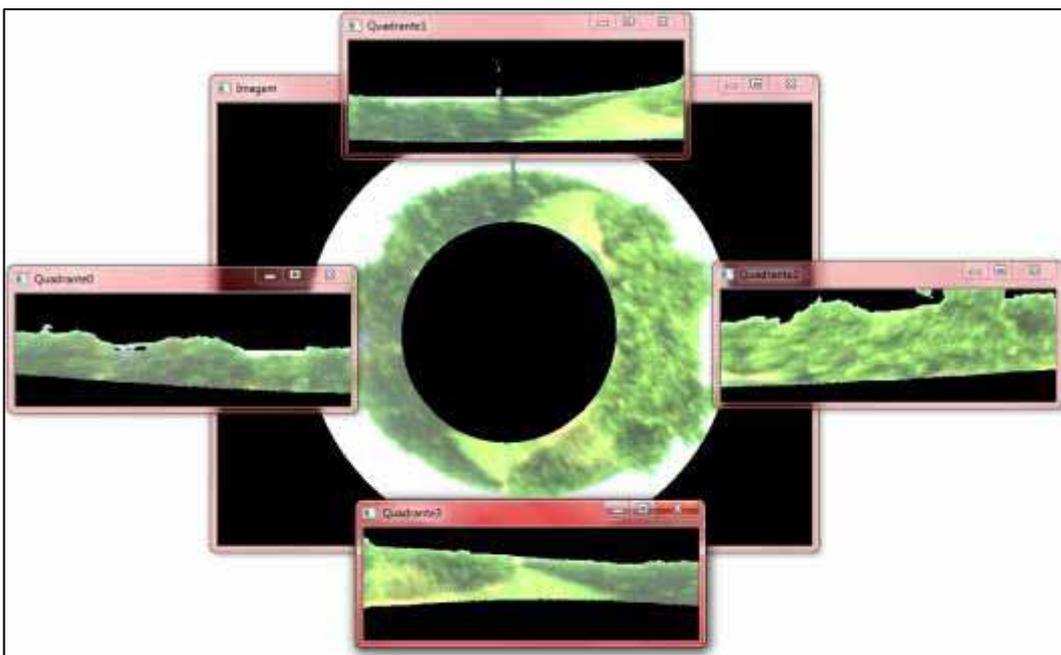


Figura A.49 - Imagem global da situação analisada



Figura A.50 - Imagem omnidirecional obtida pelo sistema de visão

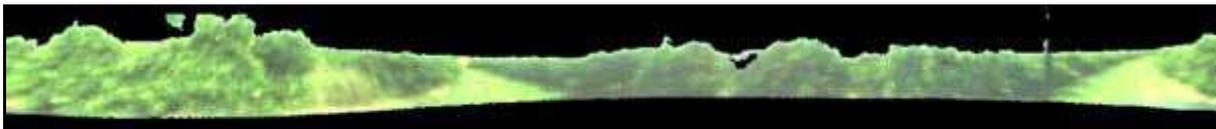


Figura A.51 - Resultado da Etapa de Extração do Céu das Imagens

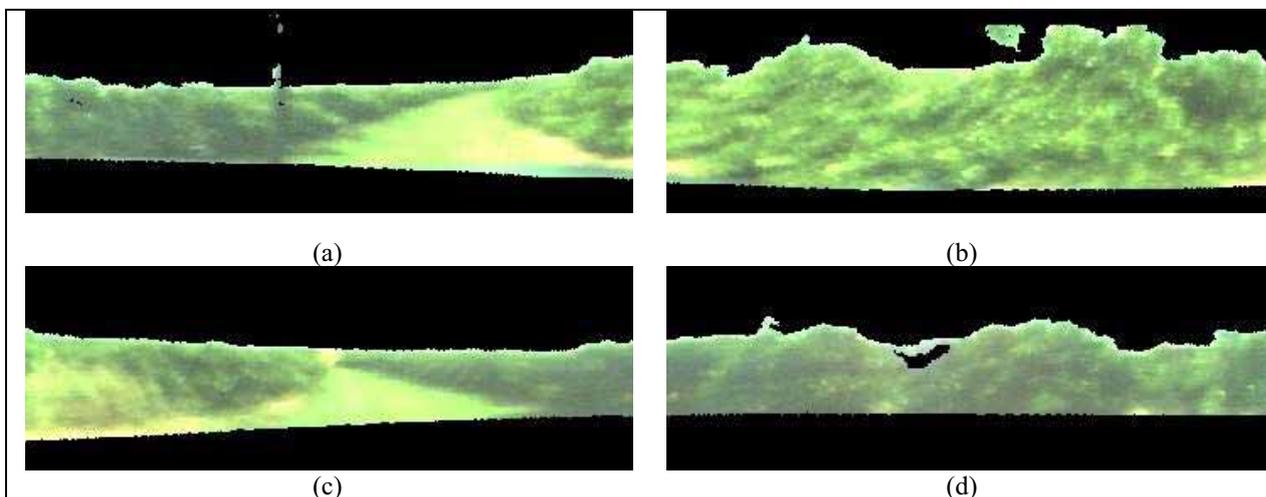


Figura A.52 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

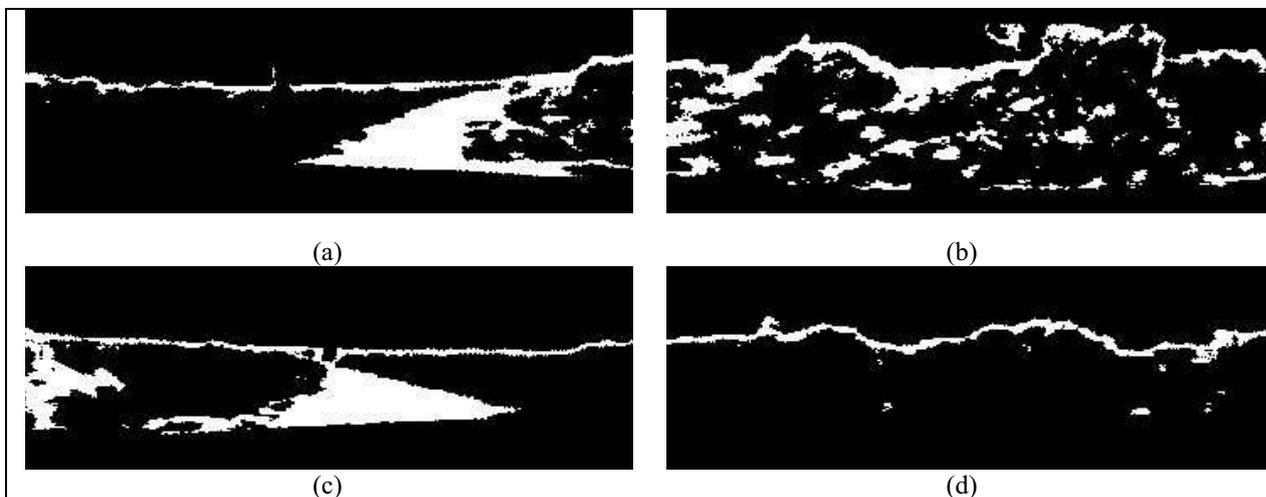


Figura A.53 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica de Iluminação da imagem.

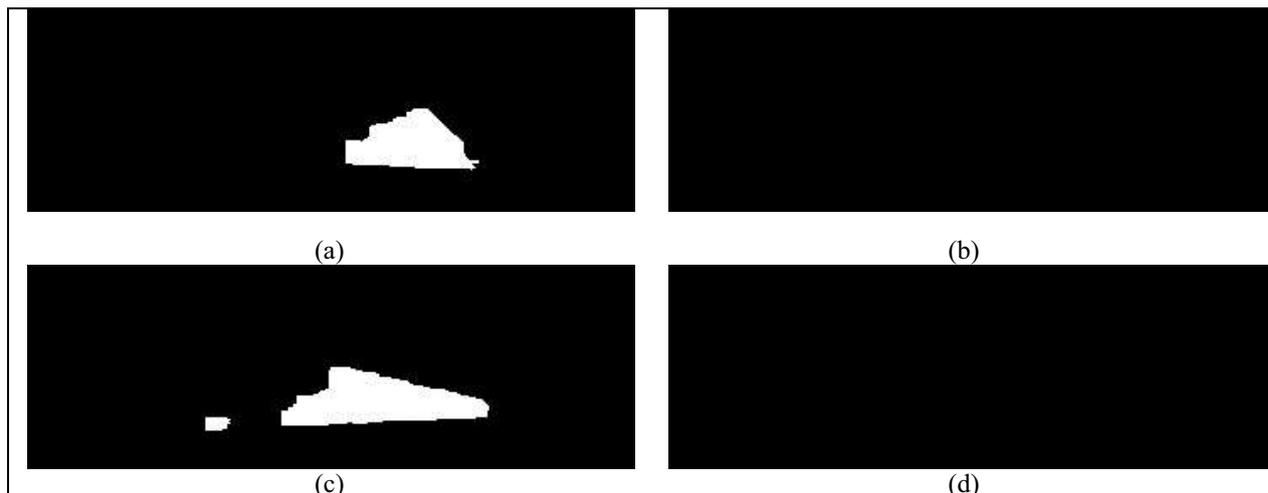


Figura A.54 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

A.5.2 Momento 2

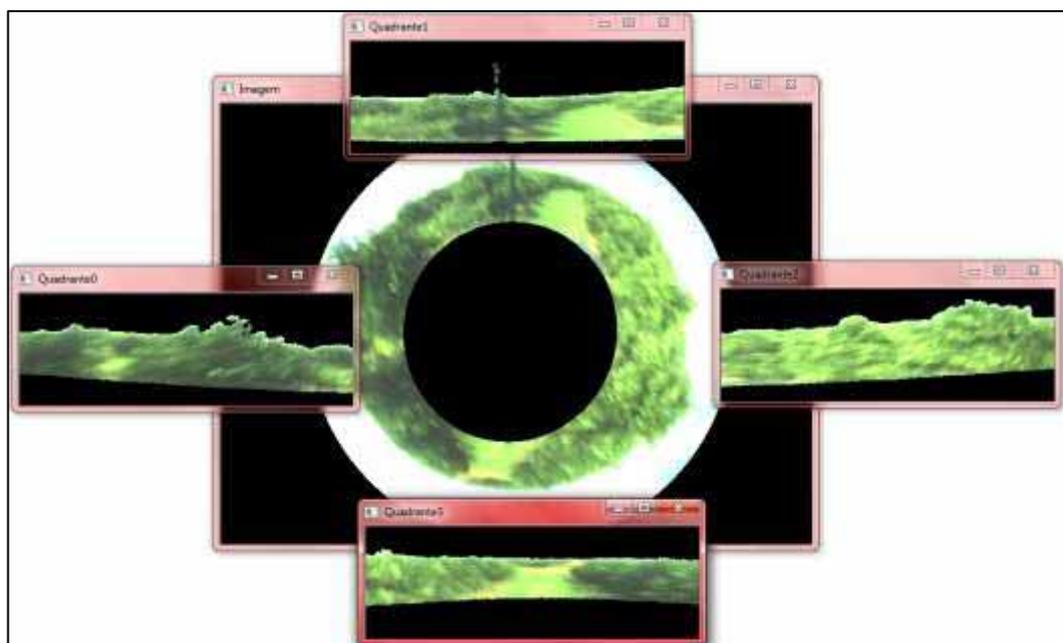


Figura A.55 - Imagem global da situação analisada



Figura A.56 - Imagem omnidirecional obtida pelo sistema de visão



Figura A.57 - Resultado da Etapa de Extração do Céu das Imagens

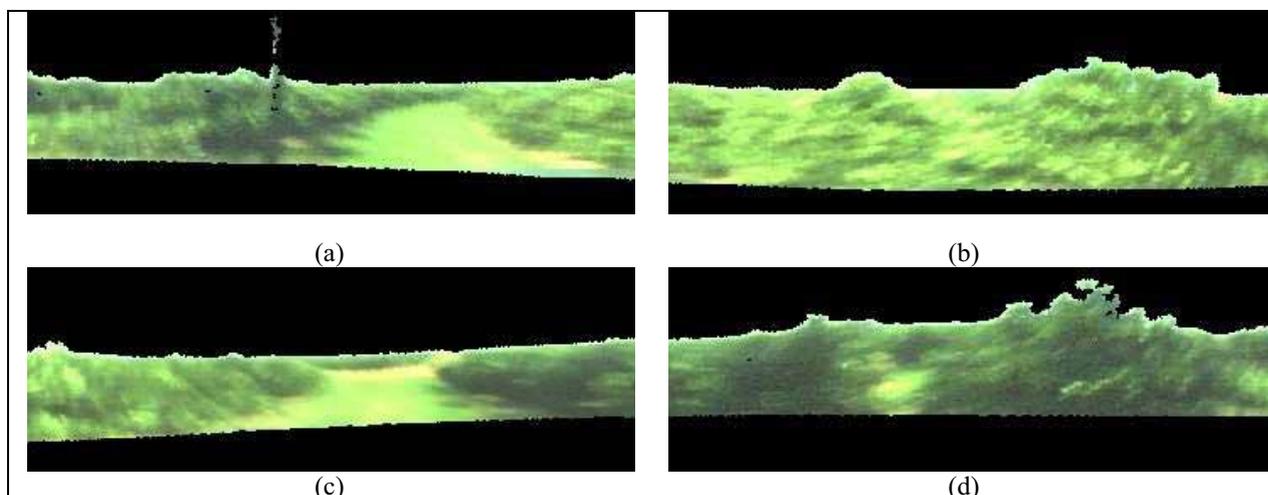


Figura A.58 - Resultado da etapa de extração de quadrantes, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

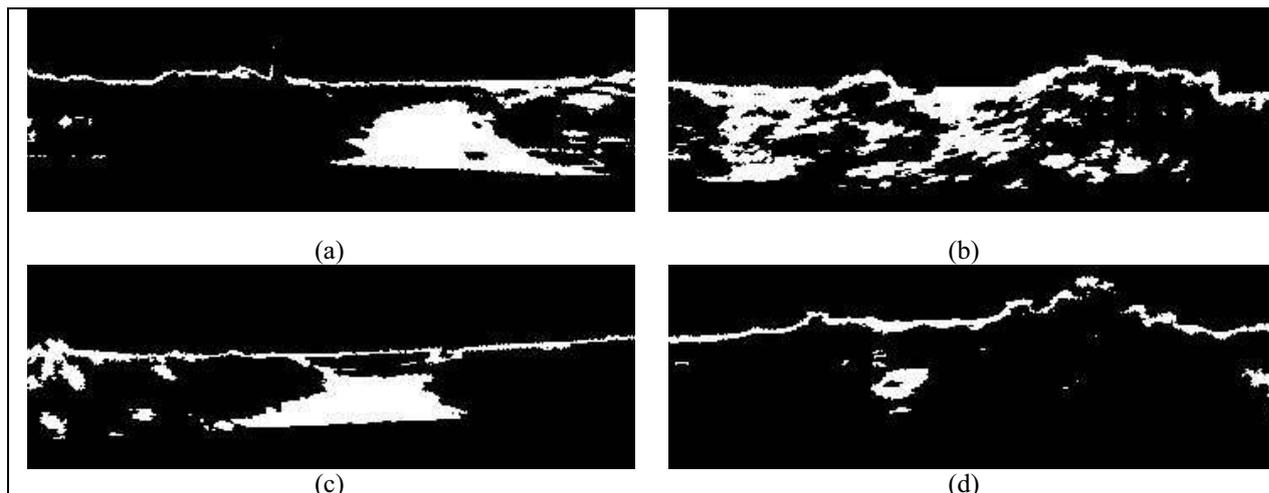


Figura A.59 - Resultados da etapa de segmentação com aplicação do Otsu Thresholding. Em todos os quadrantes foi aplicada a técnica de Iluminação da imagem.



Figura A.60 - Resultados da Etapa de Inserção de Máscara e Otimização dos resultados, sendo que em (a) é ilustrado a visão frontal do veículo, em (b) a visão lateral direita do veículo, em (c) a visão da traseira do veículo e em (d) a lateral esquerda do veículo.

Autorizo a reprodução xerográfica para fins de pesquisa.

São José do Rio Preto, 31 / 07 / 14

Victor de Assis Rodrigues
Assinatura