LUCIANO CÁSSIO LULIO

**Fusão sensorial por classificação cognitiva ponderada no mapeamento de
cenais naturais agrícolas para análise quali-quantitativa em citricultura**

**São Carlos
2016**

LUCIANO CÁSSIO LULIO

***Fusão sensorial por classificação cognitiva ponderada no mapeamento de
cenas naturais agrícolas para análise quali-quantitativa em citricultura***

Tese de doutorado acadêmico apresentada à
Escola de Engenharia de São Carlos da
Universidade de São Paulo para obtenção do
Título de Doutor em Engenharia Mecânica.

Programa de Pós Graduação: Engenharia
Mecânica.

Área de Concentração: Manufatura

Orientador: Mário Luiz Tronco

ESTE EXEMPLAR TRATA-SE DA
VERSÃO CORRIGIDA.
A VERSÃO ORIGINAL ENCONTRA-SE
DISPONÍVEL JUNTO AO
DEPARTAMENTO DE ENGENHARIA
MECANICA DA EESC-USP.

**São Carlos
2016**

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

L955f Lulio, Luciano Cássio
Fusão sensorial por classificação cognitiva
ponderada no mapeamento de cenas naturais agrícolas
para análise quali-quantitativa em citricultura /
Luciano Cássio Lulio; orientador Mário Luiz Tronco;
coorientador Arthur José Vieira Porto. São Carlos,
2016.

Tese (Doutorado) - Programa de Pós-Graduação em
Engenharia Mecânica e Área de Concentração em
Manufatura -- Escola de Engenharia de São Carlos da
Universidade de São Paulo, 2016.

1. Visão computacional. 2. Cenas agrícolas. 3. Robô
agrícola móvel. 4. Classificação cognitiva. 5. Fusão
sensorial. I. Título.

FOLHA DE JULGAMENTO

Candidato: Bacharel **LUCIANO CASSIO LULIO**.

Título da tese: "Fusão sensorial por classificação cognitiva ponderada no mapeamento de cenas naturais agrícolas para análise quali-quantitativa em citricultura".

Data da defesa: 28/03/2016.

Comissão Julgadora:

Resultado:

Prof. Associado **Mario Luiz Tronco (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Titular **Arthur José Vieira Porto**
(Escola de Engenharia de São Carlos/EESC)

APROVADO.

Prof. Associado **Adilson Gonzaga**
(Escola de Engenharia de São Carlos/EESC)

APROVADO

Prof. Dr. **Emerson Carlos Pedrino**
(Universidade Federal de São Carlos/UFSCar)

Aprovado

Prof. Dr. **Edilson Reis Rodrigues Kato**
(Universidade Federal de São Carlos/UFSCar)

Aprovado

Coordenador do Programa de Pós-Graduação em Engenharia Mecânica:
Prof. Associado **Gherhardt Ribatski**

Presidente da Comissão de Pós-Graduação:
Prof. Associado **Paulo César Lima Segantine**

Dedicatória

À memória de meu querido irmão Juliano Cássio Lúlio.

Agradecimentos

Ao professor Mário Luiz Tronco, pela orientação, supervisão e acompanhamento ao longo do período de pesquisa deste doutorado acadêmico, em todos seus propósitos.

Ao professor Arthur José Vieira Porto, pela oportunidade de desenvolver este trabalho no Núcleo de Ensino e Pesquisa em Automação e Simulação (NEPAS/EESC/USP).

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro, à Escola de Engenharia de São Carlos (EESC) e ao Departamento de Engenharia Mecânica, pelo suporte no desenvolvimento do doutorado acadêmico.

Ao crivo técnico, mentoria e auxílio dos especialistas consultados nas empresas e órgãos responsáveis pela administração e supervisão agrícola nacional, como a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), o Fundo de Defesa da Citricultura (FUNDECITRUS), a Secretaria de Agricultura e Abastecimento do Estado de SP e a Coordenadoria de Assistência Técnica Integral (CATI), pela fundamentação aos aspectos relevantes de fitotecnia, necessários ao conhecimento direto do citricultor/agricultor, essenciais aos objetivos desta pesquisa.

Aos amigos, professores e funcionários do NEPAS, pelas amizades e ideias discutidas.

Aos meus familiares, pelo incondicional apoio e incentivo, e a todos que, direta ou indiretamente me apoiaram neste trabalho.

"(...)

*E você corre e corre atrás do sol, mas ele está se pondo
Fazendo a volta para nascer outra vez atrás de você
De uma maneira relativa o sol é o mesmo, mas você está mais velho
Com menos fôlego e um dia mais perto da morte
(...)"*

Mason, N., Wright, R., Waters, R., Gilmour, D. (Time/Pink Floyd, adaptado e traduzido)

RESUMO

LULIO, L. C. *Fusão sensorial por classificação cognitiva ponderada no mapeamento de cenas naturais agrícolas para análise quali-quantitativa em citricultura*. 305p. Tese de Doutorado Acadêmico – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

Sistemas computacionais empregados na Agricultura de Precisão (AP) são dedicados, atualmente, a prover relativa amostragem, precisão e nível de processamento de dados requeridas pelas práticas agrícolas, que não são comuns a agricultura convencional, elevando custos com a produção e pesquisas direcionadas ao sensoriamento remoto, para o mapeamento e inspeção das linhas de plantio. São tarefas *a priori* realizadas com o uso de sensores *proprioceptivos* e *exteroceptivos*, instrumentação embarcada, informações geográficas e implementos existentes na produção e cultivo, que auxiliam as atividades do agricultor durante as etapas de plantação, maturação, conservação e colheita de determinada cultura. Ainda, estas tarefas são auxiliadas com uso de robôs agrícolas móveis terrestres, como plataformas veiculares autônomas para a locomoção entre as linhas de plantio na aquisição de dados do campo. Dadas estas informações e relacionando o grau de investimento e desenvolvimento destas tecnologias, o objetivo deste trabalho é auxiliar a inspeção, quantificação e qualificação de culturas agrícolas (citricultura) de determinada área de plantio através da análise e identificação de dados por fusão sensorial, associada a processamento de imagens digitais, termografia óptica e sensores de fluxo óptico e refletância, baseado na extração de objetos de cenas naturais reais, identificando itens como frutos, gramíneas, caules, ramos, folhas e galhos, provendo assim um conjunto de dados qualitativos e quantitativos da cultura analisada. A partir de um sistema de visão computacional e fusão sensorial, com câmeras GigE/IP-CMOS, conjunto de sonares, câmera térmica, sensores de fluxo óptico e sensores de refletância, são embarcados nas laterais da estrutura veicular, com a mesma relação do centro geométrico cinemático do robô agrícola móvel. Após a aquisição dos dados, são aplicadas técnicas de processamento de imagens e sinais para a segmentação de regiões não homogêneas, e reconhecimento de padrões por classificadores estatísticos. Tais técnicas são programadas em OpenCV e MATLAB, de forma *offline*. Classificadores cognitivos que realizam as correspondências de padrões e classes são pretendidos na combinação de técnicas de fusão de dados ponderada, para que, durante a locomoção do robô agrícola móvel, as etapas de processamento de imagens e combinação de parâmetros para a classificação sejam manipuláveis para análise *a posteriori*, conflitando os dados existentes com prováveis alterações decorrentes na cultura e na biomassa.

Palavras chave: Visão computacional, Cenas agrícolas, Robô agrícola móvel, Classificação cognitiva, Fusão sensorial.

ABSTRACT

LULIO, L. C. *Cognitive classification sensor fusion applied on mapping of agricultural natural scenes for qualitative and quantitative analysis in citrus*. 2016. 305p. PhD Thesis – Engineering School of São Carlos, University de São Paulo, São Carlos, 2016.

Computer systems are used in Precision Agriculture (PA) to provide relational sampling, accuracy and data processing required for agricultural practices and schemes, which are not common to conventional agriculture, demanding higher costs of production and research directed to the remote sensing for mapping and inspection of crop rows. Tasks are carried out using *a priori* On-the-Go sensors, and proprioceptive and exteroceptive ones, embedded instrumentation, geographic information and existing implements on production and farming, which these activities ensure during the steps of planting, maturation, maintenance and harvesting of a particular culture. Also, these tasks are aided with the use of terrestrial agricultural mobile robots such as autonomous vehicle platforms for locomotion between the crop rows in the acquisition of field data. Given this information and relating the investment and development of these technologies, the goal of this work is to assist the inspection, quantification and qualification of agricultural crops (*citrus*) of planting area through analyzing and identifying data for sensor fusion, associated with digital image processing, optical thermal imaging and optical flow sensors and reflectance, based on the extraction of real natural scenes objects, identifying items such as fruits, grasses, stems, branches and leaves, thus providing a qualitative and quantitative set of data analyzed culture. As of a computer vision system and sensor fusion, Gigabit Ethernet cameras, sonars, thermal camera, infrared optical flow sensors and monochrome CMOS sensors are embedded in two sides of the vehicle structure, with the same geometric center ratio of the agricultural mobile robot. After data acquisition, image and signal processing techniques are applied for non homogeneous region segmentation, and pattern recognition through statistical classifiers. Such techniques are programmed in MATLAB and OpenCV, embedded in a computer platform. Cognitive classifiers that perform pattern and classes matching are intended on a combination of weighted data fusion techniques, that during locomotion of the agricultural mobile robot, the steps of image processing and combination of parameters for classification are manipulated for analysis retrospectively, conflicting existing data with likely changes resulting in culture and biomass.

Keywords: Computer vision, Agricultural scenes, Agricultural mobile robot, Cognitive classification, Sensory fusion.

LISTA DE FIGURAS

Figura 2.1: Estrutura sequencial de um sistema de visão computacional (Adaptado de GONZALEZ e WOODS, 2007).	43
Figura 3.1: Etapas do processamento de imagens - (a) aquisição da imagem; (b) segmentação; (c) filtragem; (d) detecção de bordas; (e) discriminação dos círculos (BULANON <i>et al.</i> , 2009).	61
Figura 3.2: Diferentes tipos de irregularidades nas cascas das laranjas (Adaptado de LOPEZ <i>et al.</i> , 2009).	62
Figura 3.3: (a) Aproximação poligonal de falha em superfície – cada nível de cinza representa uma borda diferente; (b-c) Área de segmentação para dois tipos de irregularidades nos frutos (LOPEZ <i>et al.</i> , 2009).	62
Figura 3.4: Detalhes do tamanho, forma e cor para as doenças estudadas (BLASCO <i>et al.</i> , 2009).	63
Figura 3.5: Diferentes classes de segmentos - (a) segmentos completos, (b) segmentos quebrados, (c) fragmentos de segmentos ou com sementes, (d) segmentos duplos (BLASCO <i>et al.</i> , 2007a).	64
Figura 3.6: Na sequência de imagens acima, da esquerda para direita tem-se a imagem visível, imagem NIR e imagem UVFL; na sequência de imagens abaixo, da esquerda para direita tem-se a imagem do fruto com irregularidade, segmentação usando CART, e segmentação usando LDA (Adaptado de BLASCO <i>et al.</i> , 2007b).	65
Figura 3.7: Etapas de segmentação e classificação, considerando o índice de diferença normalizado, o filtro de variância, componentes Cb e Cr, e inserção de rótulo no objeto encontrado, separado do plano de fundo (PAYNE <i>et al.</i> , 2013).	70
Figura 3.8: Imagens multimodais registradas de folhas de macieiras, apresentando sete níveis de patógenos que causam irregularidades na superfície, 21 dias após inoculação. Os níveis de infecção estão classificados de acordo com a escala de notação visual (1: 0–1%, 2: 1–5%, 3: 5–10%, 4: 10–25%, 5: 25–50%, 6: 50–75%, 7: 75–100%). As colunas de 1-7 representam estas classificações: (A) imagem visível de irregularidade na folha codificada; (B) estado inicial da imagem fluorescente; (C) eficiência quântica da imagem fluorescente; (D) imagens térmicas em Kelvin (BELIN <i>et al.</i> , 2013).	71
Figura 3.9: Princípio de funcionamento do protótipo (GIL <i>et al.</i> , 2007).	74
Figura 3.10: Distribuição de área foliar em função da altura da planta (Adaptado de GIL <i>et al.</i> , 2007).	74
Figura 3.11: Distribuição espacial de deposição obtidas com a aplicação convencional (à esquerda) e com uma taxa de aplicação variável (à direita) (Adaptado de GIL <i>et al.</i> , 2007). .	75
Figura 3.12: Árvore gerada usando modelo 3D (MOTTUS <i>et al.</i> , 2006).	75

Figura 3.13: Formas axialmente simétricas de copas para diferentes valores de limiar de coroa, contendo 90% de folhagem (Adaptado de MOTTUS <i>et al.</i> , 2006).....	76
Figura 3.14: Cálculo da largura da copa (c) a partir da distância para o exterior da copa (d), medida pelos sensores de ultrassom; distância do sensor em relação ao eixo do pulverizador (e); altura da copa (b); espaçamento entre linhas de árvores (a) (SOLANELLESI <i>et al.</i> , 2006).	76
Figura 3.15: Amostragem de estratégia de replicação nos ensaios em campos de oliveiras (SOLANESSELI <i>et al.</i> , 2006).	77
Figura 3.16: Configuração do túnel de vento para testes dos sensores (Adaptado de JEONA <i>et al.</i> , 2011).....	77
Figura 3.17: Aplicação de pulverização em um campo linear típico (JEON <i>et al.</i> , 2011).....	78
Figura 4.1: Diagrama funcional da metodologia proposta.	79
Figura 4.2: Base de dados: ~1270 imagens RAW adquiridas de dosséis completos, cenas localizadas, regiões dentro da cena, e linhas de plantio. A base de dados A corresponde ao conjunto de imagens trabalhadas para o sistema de visão computacional e o mapeamento matricial por sonares. A base de dados B, dependente e contida em A, corresponde ao conjunto de imagens trabalhadas para o tratamento de imagens térmicas e a análise dos índices vegetativos das plantas.	82
Figura 4.3: Quadriciclo HONDA TRX420TM - especificações técnicas para a distribuição de massa nos suportes dianteiro e traseiro, onde são instalados os sensores e câmeras; adaptação dos gabinetes MDF nas partes dianteira e traseira. No gabinete traseiro, as quatro divisões e a parte superior são dedicadas a instalação dos sensores, câmeras, computador e acessórios. O gabinete dianteiro é dedicado a instalação de câmeras CCD/CMOS e a câmera térmica.	83
Figura 4.4: Vista isométrica do RAM, e prototipagem real. Nas laterais, os vãos e a superfície superior se adequam as instalações dos sensores, câmeras e computador (TABILE, 2012). ..	84
Figura 4.5: Projeto e partes constituintes (à esquerda): 01 – motor diesel e sistema de bombas hidráulicas; 02 – assoalho; 03 – módulo roda traseiro; 04 – chassi secundário; 05 – chassi principal; 06 – sistema de propulsão; 07 – sistema de suspensão; 08 – módulo roda dianteiro; 09 – sistema de esterçamento. À direita, os sistemas de coordenadas inercial e local (TABILE, 2012).....	85
Figura 4.6: Dimensões da plataforma (acima); Testes com o sistema de propulsão e direção da plataforma veicular agrícola <i>Agribot</i> no laboratório de referência nacional em agricultura de precisão da Embrapa.....	86
Figura 4.7: Cenas naturais com orientação paralela e diagonal às linhas de plantio.....	88
Figura 4.8: Cenas naturais com orientação ortogonal às linhas de plantio (dosséis completos).	88
Figura 4.9: Diagrama funcional para a proposta de visão computacional na inspeção de culturas agrícolas.	89

Figura 4.10: Funcionamento do algoritmo de segmentação não-supervisionado JSEG (Adaptado de LULIO, 2011).	92
Figura 4.11: Fluxograma da etapa de distribuição espacial (Adaptado de LULIO, 2011a).	94
Figura 4.12: Algoritmo customizado à classificação pelo teorema de <i>Bayes</i>	98
Figura 4.13: Termovisor FLIR E50 (FLIR SYSTEMS, 2011).	100
Figura 4.14: Cenas naturais de dosséis completos e respectivas regiões localizadas para análise e processamento termográfico. As regiões alocadas na esquerda denotam os registros realizados na primeira aquisição (<i>an</i>), as regiões alocadas na direita denotam os registros realizados na segunda aquisição (<i>bn</i>) (15 dias após).	102
Figura 4.15: Cena natural e representação termográfica 01.	103
Figura 4.16: Cena natural e representação termográfica 02.	103
Figura 4.17: Cena natural e representação termográfica 03.	103
Figura 4.18: Cena natural e representação termográfica 04.	104
Figura 4.19: Cena natural e representação termográfica 05.	104
Figura 4.20: Cena natural e representação termográfica 06.	104
Figura 4.21: Cena natural e representação termográfica 07.	105
Figura 4.22: Cena natural e representação termográfica 08.	105
Figura 4.23: Cena natural e representação termográfica 09.	105
Figura 4.24: Cena natural e representação termográfica 10.	106
Figura 4.25: Sensores ultrassônicos LV-MaxSonar EZ1 e XL-MaxSonar WRC.	108
Figura 4.26: Montagem do sensor de ultrassom (<i>XL-Maxsonar</i>) no suporte em MDF atrás do quadriciclo, nas duas laterais, na imagem à esquerda; Detalhe do mecanismo (<i>pan-tilt</i>) dos servomotores, na imagem à direita, e atrás o ultrassom da lateral direita do veículo está montado com o segundo mecanismo dos servomotores.	109
Figura 4.27: Conjunto sensor de ultrassom/mecanismo servomotor atuando na varredura cartesiana para a leitura das distâncias - na parte debaixo do suporte MDF, observa-se a placa de acionamento dos servomotores e as conexões de dados até o computador.	110
Figura 4.28: Procedimento de varredura matricial da árvore pelo sonar, com o mecanismo dos servomotores planares (<i>x</i> e <i>y</i>).	111
Figura 4.29: Módulo GPS NBoard M3 - composto por uma IMU, sendo um magnetômetro para medir o fluxo magnético como compasso/bússola (3 eixos), um acelerômetro para medir a aceleração linear (3 eixos) e um giroscópio para medir a variação angular (3 eixos).	112
Figura 4.30: Correspondência da cena da árvore 01 com a matriz de distâncias gerada.	113

Figura 4.31: Correspondência da cena da árvore 02 com a matriz de distâncias gerada.	114
Figura 4.32: Correspondência da cena da árvore 03 com a matriz de distâncias gerada.	115
Figura 4.33: Correspondência da cena da árvore 04 com a matriz de distâncias gerada.	116
Figura 4.34: Correspondência da cena da árvore 05 com a matriz de distâncias gerada.	117
Figura 4.35: Correspondência da cena da laranjeira com a matriz de distâncias.	118
Figura 4.36: Geração da Matriz de Distâncias Retificadas.	119
Figura 4.37: Abertura angular entre o sensor e o alvo.	123
Figura 4.38: Montagem do sensor Crop Circle no veículo de testes.	123
Figura 4.39: Sintomas de deficiências em pomares: (a) zinco , (b) manganês, (c) boro, (d) ferro, (e) cobre, (f) molibdênio, (g) enxofre, (h) cálcio, (i) magnésio, (j) potássio, (k) fósforo, (l) nitrogênio.	124
Figura 4.40: Diagrama de blocos funcional do processo de classificação geral cognitiva com atribuição de pesos na fusão sensorial.	127
Figura 4.41: Diagrama de blocos expandido do processo de classificação geral cognitiva ponderada, com a discriminação dos dados de entrada e saída para as duas etapas do classificador.	128
Figura 4.42: Diagrama de blocos de um classificador <i>Fuzzy</i> : (<i>EP</i> : <i>entradas precisas</i> ; <i>SP</i> : <i>saídas precisas</i>).	129
Figura 4.43: Sistema de inferência <i>fuzzy</i> para a primeira abordagem do classificador CgCP.	131
Figura 4.44: Funções-membro para a entrada <i>VHim</i> , quanto ao grau de pertinência (eixo das ordenadas) e estado de inferência (eixo das abscissas).	132
Figura 4.45: Funções-membro para a entrada <i>VMVir</i> , quanto ao grau de pertinência (eixo das ordenadas) e estado de inferência (eixo das abscissas).	133
Figura 4.46: Funções-membro para a entrada <i>VnMD</i> , quanto ao grau de pertinência (eixo das ordenadas) e estado de inferência (eixo das abscissas).	134
Figura 4.47: Funções-membro para a entrada <i>VmIV</i> , quanto ao grau de pertinência (eixo das ordenadas) e estado de inferência (eixo das abscissas).	134
Figura 4.48: Funções-membro para as saídas PC3, PC2a, PC2b e PC1, quanto ao grau de pertinência (eixo das ordenadas) e estado de inferência (eixo das abscissas).	135
Figura 4.49: Modelo de neurônio artificial <i>McCulloch e Pitts</i>	136
Figura 4.50: Topologia RNA aplicada as quatro abordagens.	138

Figura 5.1: Grupo de cenas de pomares originais (coluna 1), cores quantizadas (coluna 2) e segmentadas (coluna 3) - em RGB.	142
Figura 5.2: Grupo de cenas de pomares originais (coluna 1), cores quantizadas (coluna 2) e segmentadas (coluna 3) - em HSV.	143
Figura 5.3: Grupo de cenas de fileiras de cultivo (coluna 1), cores quantizadas (coluna 2) e segmentadas (coluna 3) - em RGB.	144
Figura 5.4: Grupo de cenas de fileiras de cultivo (coluna 1), cores quantizadas (coluna 2) e segmentadas (coluna 3) - em HSV.	145
Figura 5.5: Histograma e interpolação linear de contorno para cena com linhas de plantio, em RGB.	146
Figura 5.6: Histograma e interpolação linear de contorno para cena com detalhes do pomar, em RGB.	147
Figura 5.7: Histograma e interpolação linear de contorno para cena com linhas de plantio, em HSV.	148
Figura 5.8: Histograma e interpolação linear de contorno para cena com detalhes do pomar, em HSV.	149
Figura 5.9: Quantidade de dimensões a cada conjunto - linhas de plantio RGB.	152
Figura 5.10: Quantidade de dimensões a cada conjunto - linhas de plantio HSV.	153
Figura 5.11: Quantidade de dimensões a cada conjunto – laranja RGB.	153
Figura 5.12: Quantidade de dimensões a cada conjunto – laranja HSV.	154
Figura 5.13: Parâmetros à mistura do treinamento – Linhas de plantio RGB.	156
Figura 5.14: Parâmetros à mistura do treinamento – Linhas de plantio HSV.	157
Figura 5.15: Parâmetros à mistura do treinamento – Pomares RGB.	158
Figura 5.16: Parâmetros à mistura do treinamento – Pomares HSV.	158
Figura 5.17: Quantificação 01 – (a) mapas de classe por <i>Bayes ingênuo</i> , (b) métricas circulares próximas do limiar geométrico 1,0, (c) áreas e centróides para a localização de frutos (RGB – esquerda; HSV – direita).	161
Figura 5.18: Quantificação 02 – (a) mapas de classe por <i>Bayes ingênuo</i> , (b) métricas circulares próximas do limiar geométrico 1,0, (c) áreas e centróides para a localização de frutos (RGB – esquerda; HSV – direita).	162
Figura 5.19: Quantificação 03 – (a) mapas de classe por <i>Bayes ingênuo</i> , (b) métricas circulares próximas do limiar geométrico 1,0, (c) áreas e centróides para a localização de frutos (RGB – esquerda; HSV – direita).	163

Figura 5.20: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5, em imagem RGB, com detalhes da deformação nos frutos centrais.	165
Figura 5.21: Resultados das imagens termográficas das cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5.	166
Figura 5.22: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 em níveis de cinza.....	167
Figura 5.23: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 segmentadas por gradiente de contorno e segmentação por <i>Sobel</i>	168
Figura 5.24: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com a magnitude de gradiente da transformada de <i>watershed</i>	169
Figura 5.25: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com aplicação de erosão seguida de dilatação (abertura morfológica).	170
Figura 5.26: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com aplicação de erosão seguida de reconstrução morfológica.	171
Figura 5.27: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com aplicação de remoção de manchas escuras (fechamento morfológico).	172
Figura 5.28: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com aplicação das técnicas de reconstrução de regiões.	173
Figura 5.29: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com aplicação dos marcadores de máximo regional nos elementos do primeiro plano.	174
Figura 5.30: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com regiões de máxima sobrepostos na imagem original.	175
Figura 5.31: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com regiões de máxima modificados para refinamento dos elementos de primeiro plano, sobrepostos na imagem original.....	176
Figura 5.32: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com limiarização de exclusão dos marcadores do segundo plano.	177
Figura 5.33: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com morfologia matemática <i>skeleton</i>	178
Figura 5.34: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com sobreposição dos marcadores do primeiro plano na imagem original.	179
Figura 5.35: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com a matriz rótulo colorida da transformada de <i>watershed</i> na identificação das regiões de interesse à classificação.....	180
Figura 5.36: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com sobreposição de transparência de cores na imagem original.....	181

Figura 5.37: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 comparadas com as regiões de sobreposição, parametrizadas como entradas no classificador por modelos de mistura de <i>Gaussianas</i> .	184
Figura 5.38: Inicialização randômica/arbitrária da média e desvio padrão para as covariâncias globais.	186
Figura 5.39: Agrupamentos/ <i>clusters</i> das regiões classificadas, nas cenas a1, a2, a3, a4, a5, b1, b2, b3, b4, b5.	189
Figura 5.40: Linearidade da convergência da máxima-verossimilhança do segmento-alvo.	191
Figura 5.41: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 pós classificação por modelos de mistura de <i>Gaussianas</i> . Na coluna esquerda têm-se as imagens termográficas de cada cena, com respectivamente, a sobreposição <i>Watershed</i> do processo de segmentação dos objetos-alvo (coluna central), e os resultados dos mapas de classe, relacionando os objetos-alvo com as regiões classificadas (coluna direita).	193
Figura 5.42: Cena 1: gráfico de intensidades pelo histograma (distribuição das barras indica a incidência de <i>pixels</i> naquela região); gráfico da área de contorno (quanto mais fria a cor, mais próximo é o objeto); gráfico da distribuição de <i>pixels</i> em cada ponto de leitura; gráficos de superfície e contorno (linear e total).	194
Figura 5.43: Cena 2: gráfico de intensidades pelo histograma (distribuição das barras indica a incidência de <i>pixels</i> naquela região); gráfico da área de contorno (quanto mais fria a cor, mais próximo é o objeto); gráfico da distribuição de <i>pixels</i> em cada ponto de leitura; gráficos de superfície e contorno (linear e total).	195
Figura 5.44: Cena 3: gráfico de intensidades pelo histograma (distribuição das barras indica a incidência de <i>pixels</i> naquela região); gráfico da área de contorno (quanto mais fria a cor, mais próximo é o objeto); gráfico da distribuição de <i>pixels</i> em cada ponto de leitura; gráficos de superfície e contorno (linear e total).	196
Figura 5.45: Cena 4: gráfico de intensidades pelo histograma (distribuição das barras indica a incidência de <i>pixels</i> naquela região); gráfico da área de contorno (quanto mais fria a cor, mais próximo é o objeto); gráfico da distribuição de <i>pixels</i> em cada ponto de leitura; gráficos de superfície e contorno (linear e total).	197
Figura 5.46: Cena 5: gráfico de intensidades pelo histograma (distribuição das barras indica a incidência de <i>pixels</i> naquela região); gráfico da área de contorno (quanto mais fria a cor, mais próximo é o objeto); gráfico da distribuição de <i>pixels</i> em cada ponto de leitura; gráficos de superfície e contorno (linear e total).	198
Figura 5.47: Séries 01 à 25 da cena natural 1.	202
Figura 5.48: Gráfico da superfície de contorno para a cena natural 1 - cada célula ($n \times m$), representa 12088 <i>pixels</i> , correspondentes da cena natural em RGB/HSV (3664 x 2062).	202
Figura 5.49: Gráfico de dispersão total, contendo as 25 séries, para a cena natural 1.	203
Figura 5.50: Gráfico das 25 séries tridimensionais empilhadas para a cena natural 1.	204

Figura 5.51: Séries 01 à 25 da cena natural 2.....	207
Figura 5.52: Gráfico de dispersão total, contendo as 25 séries, para a cena natural 2.	208
Figura 5.53: Gráfico da superfície de contorno para a cena natural 2 - cada célula ($n \times m$), representa 12088 <i>pixels</i> , correspondentes da cena natural em RGB/HSV (3664 x 2062).	208
Figura 5.54: Gráfico das 25 séries tridimensionais empilhadas para a cena natural 2.	209
Figura 5.55: Séries 01 à 25 da cena natural 3.	212
Figura 5.56: Gráfico de dispersão total, contendo as 25 séries, para a cena natural 3.	213
Figura 5.57: Gráfico da superfície de contorno para a cena natural 3 - cada célula ($n \times m$), representa 12088 <i>pixels</i> , correspondentes da cena natural em RGB/HSV (3664 x 2062).	213
Figura 5.58: Gráfico das 25 séries tridimensionais empilhadas para a cena natural 3.	214
Figura 5.59: Séries 01 à 25 da cena natural 4.	217
Figura 5.60: Gráfico de dispersão total, contendo as 25 séries, para a cena natural 4.	218
Figura 5.61: Gráfico da superfície de contorno para a cena natural 4 - cada célula ($n \times m$), representa 12088 <i>pixels</i> , correspondentes da cena natural em RGB/HSV (3664 x 2062).	218
Figura 5.62: Gráfico das 25 séries tridimensionais empilhadas para a cena natural 4.	219
Figura 5.63: Séries 01 à 25 da cena natural 5.	222
Figura 5.64: Gráfico de dispersão total, contendo as 25 séries, para a cena natural 5.	223
Figura 5.65: Gráfico da superfície de contorno para a cena natural 5 - cada célula ($n \times m$), representa 12088 <i>pixels</i> , correspondentes da cena natural em RGB/HSV (3664 x 2062).	223
Figura 5.66: Gráfico das 25 séries tridimensionais empilhadas para a cena natural 5.	224
Figura 5.67: Aproximação polinomial (linhas de tendência) das séries 01 até 25 da cena natural 1 (a), cena natural 2 (b), cena natural 3 (c), cena natural 4 (d), cena natural 5 (e).	225
Figura 5.68: Gráfico da superfície tridimensional da cena natural 01.....	226
Figura 5.69: Gráfico de superfície tridimensional com a estimativa do volume da cena natural 01.	227
Figura 5.70: Gráfico da superfície tridimensional da cena natural 02.....	228
Figura 5.71: Gráfico de superfície tridimensional com a estimativa do volume da cena natural 02.	228
Figura 5.72: Gráfico da superfície tridimensional da cena natural 03.....	229
Figura 5.73: Gráfico de superfície tridimensional com a estimativa do volume da cena natural 03.	229

Figura 5.74: Gráfico da superfície tridimensional da cena natural 04.....	230
Figura 5.75: Gráfico de superfície tridimensional com a estimativa do volume da cena natural 04.	231
Figura 5.76: Gráfico da superfície tridimensional da cena natural 05.....	232
Figura 5.77: Gráfico de superfície tridimensional com a estimativa do volume da cena natural 05.	232
Figura 5.78: Árvore 1 - imagem em RGB para aquisição dos índices de refletância.	233
Figura 5.79: Árvore 2 - imagem em RGB para aquisição dos índices de refletância.	234
Figura 5.80: Árvore 3 - imagem em RGB para aquisição dos índices de refletância.	235
Figura 5.81: Árvore 4 - imagem em RGB para aquisição dos índices de refletância.	236
Figura 5.82: Árvore 5 - imagem em RGB para aquisição dos índices de refletância.	237
Figura 5.83: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena natural 01.	239
Figura 5.84: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena natural 02.	239
Figura 5.85: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena natural 03.	240
Figura 5.86: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena natural 04.	240
Figura 5.87: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena natural 05.	240
Figura 5.88: Médias dos índices de refletância para cada árvore.....	242
Figura 5.89: Variação dos estados de inferência das entradas e saídas, pela base de regras <i>fuzzy</i>	244
Figura 5.90: Matrizes de confusão (treinamento, validação e teste) para 25% dos conjuntos.	246
Figura 5.91: Matrizes de confusão (treinamento, validação e teste) para 50% dos conjuntos.	246
Figura 5.92: Matrizes de confusão (treinamento, validação e teste) para 75% dos conjuntos.	247
Figura 5.93: Matrizes de confusão (treinamento, validação e teste) para 100% dos conjuntos.	247

Figura 5.94: Taxa de verdadeiros positivos (VP) pela taxa de falsos positivos (FP) (treinamento, validação e teste) para 25%, 50%, 75% e 100% dos conjuntos.	248
Figura 5.95: EQM (treinamento, validação e teste) para 25% dos conjuntos.	249
Figura 5.96: EQM (treinamento, validação e teste) para 50% dos conjuntos.	250
Figura 5.97: EQM (treinamento, validação e teste) para 75% dos conjuntos.	250
Figura 5.98: EQM (treinamento, validação e teste) para 100% dos conjuntos.	251
Figura 5.99: Estado de treinamento por <i>scaled conjugate gradient</i> para 25% dos conjuntos.	251
Figura 5.100: Estado de treinamento por <i>scaled conjugate gradient</i> para 50% dos conjuntos.	252
Figura 5.101: Estado de treinamento por <i>scaled conjugate gradient</i> para 75% dos conjuntos.	252
Figura 5.102: Estado de treinamento por <i>scaled conjugate gradient</i> para 100% dos conjuntos.	253
Figura 5.103: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por mapa de classe EM termográfico) - cena 01 (região posicionada no dossel) - integração inicial da <i>fusão relacional</i>	255
Figura 5.104: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas) - cena 01 - (região do dossel preenchida pela matriz) - integração da <i>fusão quantitativa</i>	256
Figura 5.105: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas, e mapas de classe EM termográficos) - cena 01 - (região posicionada no dossel e preenchida pela matriz) - integração final da <i>fusão relacional</i>	257
Figura 5.106: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por mapa de classe EM termográfico) - cena 02 (região posicionada no dossel) - integração inicial da <i>fusão relacional</i>	258
Figura 5.107: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas) - cena 02 - (região do dossel preenchida pela matriz) - integração da <i>fusão quantitativa</i>	259
Figura 5.108: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas, e mapas de classe EM termográficos) - cena 03 - (região posicionada no dossel e preenchida pela matriz) - integração final da <i>fusão relacional</i>	260
Figura 5.109: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por mapa de classe EM termográfico) - cena 03 (região posicionada no dossel) - integração inicial da <i>fusão relacional</i>	261

Figura 5.110: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas) - cena 03 - (região do dossel preenchida pela matriz) - integração da <i>fusão quantitativa</i>	262
Figura 5.111: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas, e mapas de classe EM termográficos) - cena 03 - (região posicionada no dossel e preenchida pela matriz) - integração final da <i>fusão relacional</i>	263
Figura A.1: Cena natural RGB-a - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.....	269
Figura A.2: Cena natural RGB-b - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.....	269
Figura A.3: Cena natural RGB-c - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.....	270
Figura A.4: Cena natural HSV-a - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.....	270
Figura A.5: Cena natural HSV-b - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.....	271
Figura A.6: Cena natural HSV-c - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.....	271
Figura B.1: Cena natural RGB-a - cena de dossel completo com cena regional termográfica.	273
Figura B.2: Cena natural RGB-a - cena de dossel completo com cena regional termográfica.	273
Figura B.3: Cena natural RGB-a - cena de dossel completo com cena regional termográfica.	273
Figura B.4: Cena natural RGB-a - processo de segmentação <i>Watershed</i>	274
Figura B.5: Cena natural RGB-b - processo de segmentação <i>Watershed</i>	275
Figura B.6: Cena natural RGB-c - processo de segmentação <i>Watershed</i>	276
Figura C.1: Cena natural RGB-a - composição da cena pelo gráfico de superfície.	277
Figura C.2: Cena natural RGB-a - Séries da cena e gráfico tridimensional de superfície.	278
Figura C.3: Cena natural RGB-b - composição da cena pelo gráfico de superfície.....	279

Figura C.4: Cena natural RGB-b - Séries da cena e gráfico tridimensional de superfície.	280
Figura C.5: Cena natural RGB-c - composição da cena pelo gráfico de superfície.	281
Figura C.6: Cena natural RGB-c - Séries da cena e gráfico tridimensional de superfície.	282
Figura D.1: Cena regional RGB-a - imagem em RGB para aquisição dos índices de refletância.	283
Figura D.2: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena regional RGB-a.	284
Figura D.3: Cena regional RGB-b - imagem em RGB para aquisição dos índices de refletância.	284
Figura D.4: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena regional RGB-b.	285
Figura D.5: Cena regional RGB-c - imagem em RGB para aquisição dos índices de refletância.	285
Figura D.6: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena regional RGB-c.	286

LISTA DE TABELAS

Tabela 2.1: Atributos dos descritores gráficos no processamento de imagens, para reconhecimento de padrões (FORSYTH & PONCE, 2002; HILL, 2002; GONZALEZ & WOODS, 2007; LULIO, 2011a).	48
Tabela 3.1: Matriz de confusão das classificações para os limiares dos canais R/G (BLASCO <i>et al.</i> , 2007a).	64
Tabela 3.2: Comparação do custo de tempo de processamento das culturas analisadas para as três variações do método de Otsu (Adaptado de YIN <i>et al.</i> , 2008).	66
Tabela 4.1: Elementos químicos e características na inspeção de folhas, colmos e frutos.	123
Tabela 4.2: Relação entre valores dos índices vegetativos RE, R_{NIR} e R, e diagnoses.	125
Tabela 5.1: Distribuição dos vetores de características às classes de Pomares em RGB e HSV.	151
Tabela 5.2: Distribuição dos vetores de características às classes na localização de frutos em RGB e HSV.	151
Tabela 5.3: Probabilidade <i>a priori</i> estimadas dos conjuntos de treinamento de pomares.....	155
Tabela 5.4: Probabilidade <i>a priori</i> estimadas dos conjuntos de treinamento de laranjas.....	155
Tabela 5.5: Equações polinomiais de cada série para a cena natural 01.	226
Tabela 5.6: Equações polinomiais de cada série para a cena natural 02.	227
Tabela 5.7: Equações polinomiais de cada série para a cena natural 03.	228
Tabela 5.8: Equações polinomiais de cada série para a cena natural 04.	230
Tabela 5.9: Equações polinomiais de cada série para a cena natural 05.	231
Tabela 5.10: Índices vegetativos obtidos e calculados da árvore 1.	233
Tabela 5.11: Índices vegetativos obtidos e calculados da árvore 2.	234
Tabela 5.12: Índices vegetativos obtidos e calculados da árvore 3.	235
Tabela 5.13: Índices vegetativos obtidos e calculados da árvore 4.	236
Tabela 5.14: Índices vegetativos obtidos e calculados da árvore 5.	237
Tabela 5.15: Índices vegetativos RE, R_{NIR} e R e resultados das medidas.	238
Tabela 5.16: Média dos índices vegetativos para cada árvore.	241
Tabela 5.17: Base de regras para as entradas e saídas.	243
Tabela 5.18: Resultados das quatro classes/percentuais na classificação das saídas pretendidas.	254

Tabela 5.19: Resultados das quatro classes/percentuais na classificação das saídas pretendidas.....	264
Tabela D.1: Índices vegetativos obtidos e calculados para a cena regional RGB-a.....	283
Tabela D.2: Índices vegetativos obtidos e calculados para a cena regional RGB-b.	284
Tabela D.3: Índices vegetativos obtidos e calculados para a cena regional RGB-c.....	286

LISTA DE ABREVIACES E SIGLAS

AP	Agricultura de Preciso
AGV	<i>Autonomous Guided Vehicle</i> (veulo guiado autonomamente)
ANN	<i>Artificial Neural Network</i>
AG	Algoritmo Gentico
ANFIS	<i>Adaptive Neuro-Fuzzy Inference System</i>
CAN	<i>Controller Area Network</i>
CATI	Coordenadoria de Assistncia Tnica Integral
CDA	Centro de a (centride)
CDD	<i>Charge-Coupled Device</i>
CIE	<i>Commission International de l'Eclairage</i>
CgCP	Classificador geral Cognitivo Ponderado
CML	<i>Concurrent Mapping and Localization</i>
CMOS	<i>Complementary Metal-Oxide Semiconductor</i>
CRLB	<i>Cramer-Rao Lower Bound</i>
DSP	<i>Digital Signal Processor</i> (processador de sinais digitais)
ECU	<i>Electronic Control Unit</i> (unidade de controle eletrnico)
EM	<i>Expectation-Maximization</i>
EQM	Erro Quadrtico Mdio
FANN	<i>Fast Artificial Neural Network</i>
GLA	<i>General Lloyd Algorithm</i>
GMM	<i>Gaussian Mixture Model</i>
GPS	<i>Global Positioning System</i> (sistema de posicionamento global)
HSB	Matiz (<i>hue</i>), saturao e brilho
HSI	Matiz (<i>hue</i>), saturao e intensidade
HSL	Matiz (<i>hue</i>), saturao e luminosidade
HSV	Matiz (<i>hue</i>), saturao e valor
IA	Inteligncia Artificial
IAF	dice de a Foliar
ICP	<i>Interactive Closest Point</i>
IHPF	<i>Ideal Highpass Filter</i> (filtro ideal passa-alta)
ILPF	<i>Ideal Lowpass Filter</i> (filtro ideal passa-baixa)

iRPROP	<i>Improved Resilient Propagation</i>
JPEG	<i>Joint Photographic Experts Group</i>
LSM	<i>Least-Squares Method</i> (método dos mínimos quadrados)
LVQ	<i>Learning Vector Quantization</i> (aprendizagem por quantização vetorial)
MCP	<i>Model Predictive Control</i> (modelo controle preditivo)
ML	<i>Maximum-Likelihood</i> (máxima verossimilhança)
MLP	<i>Multilayer Perceptron</i> (Perceptron multicamadas)
MoG	<i>Mixture of Gaussians</i>
MOS	<i>Metal-Oxide Semiconductor</i>
MSE	<i>Mean Square Error</i>
NIR	<i>Near Infrared</i> (infravermelho próximo)
Nrgb	RGB normalizado
NDRE	<i>Normalized Difference Red Edge</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
PCA	<i>Principal Component Analysis</i> (análise das componentes principais)
PDF	<i>Density Probability Function</i> (função densidade de probabilidade)
PDFc	PDF conjunta
PDI	Processamento Digital de Imagens
PGF	<i>Peer Group Filtering</i> (filtragem por grupo de pares)
RAM	Robô Agrícola Móvel
RAW	Formato de imagem sem alterações, provido pelo sensor de captura
RBPF	<i>Rao-Blackwellised Particle Filter</i>
RE	<i>Red Edge</i>
RGB	<i>Red, Green, Blue</i>
RM	Robótica Móvel
RNA	Redes neurais artificiais
RSS	<i>Root Sum Squares</i>
SEIF	<i>Sparse Extended Information Form</i>
SFM	<i>Structure from Motion</i> (estrutura por movimento)
SIFT	<i>Scale Invariant Feature Transformation</i>
SSE	<i>Sum of Squared Errors</i>
SVM	<i>Support Vector Machine</i>
VC	Visão Computacional
VRT	<i>Variable Rate Technology</i> (taxa de variação tecnológica)

LISTA DE SÍMBOLOS

b	Distância focal
b	Imagem discretizada
R	Comprimento de onda da componente R do espaço de cores RGB
G	Comprimento de onda da componente G do espaço de cores RGB
B	Comprimento de onda da componente B do espaço de cores RGB
S_R	Filtro da componente R (red/vermelho)
S_G	Filtro da componente G (green/verde)
S_B	Filtro da componente B (blue/azul)
λ	Comprimento de onda
$E(\lambda)$	Energia luminosa
r	Componente R normalizada
g	Componente G normalizada
b	Componente B normalizada
H	Componente H (hue/matiz) do espaço de cores HSI
S	Componente S (saturação) do espaço de cores HSI
I	Componente I (intensidade) do espaço de cores HSI
B	Componente B (brilho) do espaço de cores HSB
L	Componente L (luminosidade) do espaço de cores HSL
V	Componente V (valor) do espaço de cores HSV
Y	Componente Y (luminosidade) do espaço de cores YIQ
I	Diferença entre alaranjado e ciano do espaço de cores YIQ
Q	Diferença entre verde e magenta do espaço de cores YIQ
P_g	Probabilidade do k-ésimo nível de cinza da imagem
N_k	Número de <i>pixels</i>
$d_i(n)$	Distância euclidiana intra- <i>pixels</i>
$J(i)$	Estimação de <i>pixels</i> para a região de bordas
$f_i(n)$	Grau de ruído da filtragem por grupo de pares da imagem
w_i	Pesos gaussianos da filtragem por grupo de pares da imagem
$P(n)$	Soma ponderada de <i>pixels</i>
G_x	Gradiente de detecção de bordas vertical
G_y	Gradiente de detecção de bordas horizontal

$\mathbf{R}$	Imagem segmentada
$P(R_i)$	Critério de homogeneidade
$s_{(k)}$	Descritor de <i>Fourier</i>
A	Autovetores de matriz de correlação em transformação linear
k	Número total de classes em probabilidade condicional
y_k	Saída desejada para a rede neural artificial
$\varphi(.)$	Função de ativação de rede neural artificial
$E(n)$	Função erro da regra Delta na retro-propagação de RNA
B_{ij}	Distância de <i>Bhattacharyya</i>
M_{ij}	Vetor de média para distância Mahalanobis
C_{ij}	Matriz de covariância das médias para distância Mahalanobis
J_{ij}	Distância de Jeffries-Matusita
D	Distorção global de regiões segmentadas
J	Valor J da quantização de cores da segmentação JSEG
S_T	Soma dos pontos quantizados na imagem
S_W	Medida de distâncias entre os mapas de classe
T_J	Limiar de segmentação das regiões homogêneas
D	Distância entre dois pontos de coordenadas
G_d	Medida em graus do GPS
D_{ret}	Valor de distância retificado da matriz de profundidade
D_{min}	Distância mínima armazenada da matriz de profundidade
DC_{max}	Distância máxima da matriz de profundidade
DC	Distância corrigida pertencente à matriz de profundidade
R_{VIS}	Fluxo radiante refletivo no vermelho
R_{NIR}	Refletância de banda infravermelho

SUMÁRIO

1. INTRODUÇÃO	35
1.1. Considerações iniciais.....	35
1.2. Problema de pesquisa e motivação	36
1.3. Objetivos	39
2. AMBIENTES AGRÍCOLAS E VISÃO COMPUTACIONAL.....	41
2.1. Visão computacional.....	42
2.1.1. Segmentação de imagens.....	44
2.1.2. Reconhecimento de padrões	46
2.2. Considerações finais	53
3. REVISÃO BIBLIOGRÁFICA.....	55
3.1. Revisão bibliográfica em agricultura de precisão	55
3.1.1. Gerenciamento da AP	56
3.1.2. Tecnologias empregadas.....	57
3.2. Revisão bibliográfica em visão computacional aplicada à agricultura	60
3.3. Revisão bibliográfica de sonares aplicados ao mapeamento de ambientes agrícolas	72
3.4. Considerações finais	78
4. METODOLOGIA PROPOSTA.....	79
4.1. Robôs móveis agrícolas e plataforma experimental por veículo guiado	83
4.2. Métodos propostos em visão computacional aplicada a imagens RGB	86
4.2.1. Etapa de pré-processamento e representação gráfica	90
4.2.2. Etapa de segmentação em cenas naturais	91
4.2.3. Etapa de extração e normalização dos vetores de características	95
4.2.4. Etapa de reconhecimento de padrões por modelos <i>Bayesianos</i>	97
4.3. Métodos propostos em visão computacional aplicada a imagens térmicas	99
4.3.1. Etapa de processamento de imagens térmicas por <i>Watershed</i>	106
4.3.2. Etapa de classificação estatística por Misturas de <i>Gaussianas</i> (<i>MoG</i>)	107

4.4.	Métodos propostos para a estimação do volume de dosséis por sonares.....	108
4.5.	Métodos propostos para a caracterização da refletância, NDVI e instrumentação..	119
4.6.	Proposta para classificação geral cognitiva na fusão sensorial óptica.....	125
4.7.	Considerações finais	140
5.	RESULTADOS EXPERIMENTAIS	141
5.1.	Resultados em visão computacional aplicada a imagens RGB	141
5.1.1.	Resultados da etapa de segmentação por regiões não-homogêneas	141
5.1.2.	Resultados da etapa de extração e normalização de características	145
5.1.3.	Resultados da etapa de reconhecimento de padrões por modelos <i>Bayesianos</i> ..	154
5.1.4.	Resultados da etapa de pós-processamento na criação de mapas de classe	159
5.2.	Resultados em visão computacional aplicada a imagens térmicas	164
5.2.1.	Resultados da etapa de segmentação de imagens térmicas por <i>Watershed</i>	164
5.2.2.	Resultados da etapa de classificação estatística por <i>MoG</i>	182
5.3.	Resultados da estimação do volume de dosséis por sonares	194
5.4.	Resultados da caracterização da refletância, NDVI e instrumentação	233
5.5.	Resultados da classificação geral cognitiva na fusão sensorial óptica	242
5.5.1.	Resultados da etapa 01 do CgCP (<i>lógica fuzzy</i>)	242
5.5.2.	Resultados da etapa 02 do CgCP (RNA).....	245
5.5.3.	Resultados finais do classificador geral cognitivo ponderado	253
5.6.	Considerações finais	264
6.	CONCLUSÕES	267
	APÊNDICE A - Segmentação e classificação na proposta de visão computacional.....	269
	APÊNDICE B - Processamento de imagens termográficas	273
	APÊNDICE C - Matrizes de distância pelo sonar e características.....	277
	APÊNDICE D - Índices vegetativos das plantas pelo sensor de refletância.....	283
7.	REFERÊNCIAS BIBLIOGRAFICAS	287

ESTRUTURA E CONTEÚDO

Esta tese de doutorado acadêmico está organizada em sete capítulos, iniciando pela temática introdutória defendida, seguida da fundamentação teórica sobre visão computacional e mapeamento de ambientes agrícolas, revisão bibliográfica das aplicações de VC e demais sensores ópticos na agricultura de precisão, metodologia proposta, resultados experimentais, conclusões e contribuições, e finalizando com as referências bibliográficas e quatro apêndices relevantes para a consulta, *a posteriori*, durante o desenvolvimento.

Capítulo 1 - Introdução: são apresentadas as justificativas e os objetivos para a realização deste trabalho.

Capítulo 2 - Ambientes agrícolas e visão computacional: são apresentados os conceitos e fundamentos sobre as etapas de processamento de imagens digitais e reconhecimento de padrões.

Capítulo 3 - Revisão bibliográfica: são apresentadas as revisões bibliográficas sobre agricultura de precisão e fusão sensorial por visão computacional aplicada a robótica agrícola, bem como a aplicação de sonares e demais sensores para o mapeamento de cenas naturais.

Capítulo 4 - Metodologia proposta: neste capítulo são definidas as estratégias de trabalho para a aquisição de imagens e dados do ambiente externo, manipulação e processamento, classificação, interpretação e relação dos dados com os resultados das cenas naturais em visão computacional, matrizes de distância por sonares, algoritmos dedicados a análise de imagens térmicas e índices vegetativos da biomassa, pelo sensor de refletância. Ainda, é apresentada e desenvolvida a proposta de classificação geral por modelos cognitivos, baseada em fusão sensorial ponderada, para cada pré-resultado de entrada com pesos de processamento computacional.

Capítulo 5 - Resultados experimentais: neste capítulo são apresentados os resultados finais obtidos através do desenvolvimento e aplicação das técnicas para a metodologia proposta no tratamento de imagens RGB/HSV e termográficas, como algoritmos de VC e reconhecimento de padrões por modelos estatísticos, resultados da estimação do volume de copas e outros dados para o mapeamento matricial das árvores pelo sonar, resultados da manipulação estatística dos índices vegetativos que qualificam o estado dos pomares e da biomassa, e resultados da classificação geral cognitiva ponderada, que integra, de forma procedural e analítica, os dados de diferentes naturezas físicas para a análise qualitativa e quantitativa da citricultura.

Capítulo 6 - Conclusões: conclusões e as principais contribuições deste trabalho para o tema defendido.

Capítulo 7 - Referências bibliográficas: lista apresentada em ordem alfabética e contém todos os documentos referenciados no decorrer deste trabalho.

1. INTRODUÇÃO

Neste capítulo são apresentadas informações iniciais sobre o contexto da Agricultura de Precisão (AP) em aplicações envolvendo robótica móvel agrícola na inspeção de lavouras e análise de culturas, pelo método de aquisição de dados em sistemas de informação geográfica e, como a abordagem deste trabalho de pesquisa direciona-se na resolução de problemas com dados bidimensionais, apresentando uma metodologia de classificação de dados qualitativos e quantitativos sobre as linhas de plantio, frutos e biomassa.

Os objetivos acerca dos propósitos geral e específicos deste trabalho, assim como a caracterização do problema de pesquisa e as motivações, também são apresentados.

1.1. Considerações iniciais

A Agricultura de Precisão (AP) obteve, no decorrer de alguns anos passados, melhorias significativas nas adequações e aplicações de tecnologias em sistemas eletrônicos embarcados, aumentando gradativamente seu desenvolvimento na pesquisa científica, voltada a implementos agrícolas de alto desempenho, fusão sensorial para análise de parâmetros peculiares no cultivo de lavouras, identificação, parametrização e classificação de culturas, auxílio em sistemas automatizados para locomoção autônoma de veículos agrícolas, entre outros (LULIO, 2011a, LULIO *et al.*, 2012a).

Estas abordagens aplicam-se discriminadas a eventos reais, em que os veículos agrícolas e a tecnologia embarcada proveem informações do ambiente em questão, que podem ser submetidas a análises de maior interação com os dados estimados para a navegação do veículo, e paralelamente a aquisição de dados de culturas de interesse.

Sistemas de informação geográfica (SIG) aplicados na AP são mais evidentes e necessitam auxílio por parte de novas tecnologias, cujas informações gráficas fornecidas em base de imagens aéreas apresentam dados muitas vezes imprecisos, com baixa quantidade de informações das próprias culturas, por serem bidimensionais (OLIVEIRA, 2012). Por outro lado, trabalhos mostram sua eficiência em determinadas aplicações, como: gestão de propriedades agrícolas, aplicação de fertilizantes, distribuição das linhas de irrigação, entre outros (BRASE, 2005; EMMI, *et al.*, 2013; SARKATE, KAYANKAR & KHANALE, 2013), uso de mapas geográficos para discriminação de ervas daninhas, controle de crescimento de culturas e monitoramento de produtividade (BACKES & PLUMER, 2003; CLAY & SHANAHAN, 2011; WILES, 2011; SALEEM *et al.*, 2011; LAINI *et al.*, 2012). Todavia,

como é explicado em Oliveira (OLIVEIRA, 2012), os mapas apresentados por SIG são bidimensionais, não provendo informações dos elementos e entidades do ambiente numa terceira dimensão de espaço. Logo, o uso da realidade virtual (RV) tende a resolver esta questão, com auxílio à visualização das imagens tridimensionais e interação do usuário com o ambiente virtual projetado.

Contudo, não apenas a visualização das imagens tridimensionais é relevante, mas os detalhes de aspectos qualitativos e quantitativos que a fusão de dados sensoriais permite, pós-classificação. Considerando esta última premissa, técnicas e métodos computacionais devem ser estudados e concebidos, aplicados à fusão sensorial, para adquirir e processar dados obtidos de imagens em RGB/HSV das cenas naturais, dados de distância por sonares, imagens térmicas das laterais das linhas de plantio, e índices vegetativos da biomassa, os quais, combinados, são processados por algoritmos dedicados à classificação das informações de maior relevância para o cultivo da cultura estudada.

1.2. Problema de pesquisa e motivação

Considerando o contexto apresentado, o problema de pesquisa deste trabalho é direcionado à classificação conjunta dos dados processados nas cenas naturais para análise qualitativa e quantitativa de frutos. Recursos computacionais, tempo de processamento, e a abstração das características geométricas dos elementos que compõem a cena real, são atributos que devem ser considerados para a manipulação dos dados pós classificados. A modelagem também agrega as informações da geometria dos objetos reais, como as linhas de plantio, árvores, detalhes das culturas, folhas, galhos e outras entidades que fazem parte do modelo geométrico tridimensional (ESTEBAN, DIJK & GROEN, 2010; CHENG *et al.*, 2011; WENG, ZHAO & HE, 2010). Ainda, como é abordado em Oliveira (OLIVEIRA, 2012), ambientes virtuais construídos a partir de cenas naturais, envolvem parâmetros como posição, orientação, tamanho, geometria, textura, composição, disposição cartesiana, e outros, que atendam várias aplicações conjuntas da realidade virtual e sistemas de informação geográfica (STROTHOFF *et al.*, 2011; HONG-WEI *et al.*, 2011; BINNEY & SUKHATME, 2009; MOORTHY *et al.*, 2007; ZHU *et al.*, 2009). Com a classificação conjunta de dados de sensores distintos, não apenas a quantificação de frutos, mas também a disposição destes na cena natural da árvore e os elementos da biomassa, são considerados com maior detalhamento.

Com isso, a motivação para a realização deste trabalho dá-se pela necessidade do estudo e desenvolvimento de uma metodologia de classificação de dados ponderada,

associados a linhas de plantio, com detalhes intrínsecos da cultura examinada (frutos - citricultura), suas observações por imageamento e outros dados ópticos, agrupados em informações de distância do ponto de aquisição, fluxo óptico que caracteriza as distâncias entre estas classes, além de folhas, ramos e galhos.

Com tal quantidade de elementos processados na fusão sensorial, o modelo tridimensional provê mais opções de análise, comparação, interação, alteração, e detalhes de suas características para análises qualitativa e quantitativa, *a posteriori*.

Tal análise é sustentada pelo crivo técnico de especialistas consultados de empresas e órgãos responsáveis pela administração e supervisão agrícola nacional, como a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) em São Carlos/SP, o Fundo de Defesa da Citricultura (FUNDECITRUS) em Araraquara/SP, a Secretaria de Agricultura e Abastecimento do Estado de SP e a Coordenadoria de Assistência Técnica Integral (CATI), regional de São José do Rio Preto/SP, os quais fundamentam aspectos relevantes de fitotecnia, necessários ao conhecimento direto do citricultor/agricultor.

Tais especialistas destacam que três níveis de abrangência são essenciais ao conhecimento qualitativo e quantitativo do cultivo de citros, uma vez que, como os sensores usados para a aquisição de dados tratam as informações de forma visual e gráfica (óptica), o emprego de processamento digital de imagens é feito para a quantificação de produção, quantificação de frutos, e diagnoses (qualidade/nutrição e doenças) dos frutos:

(a) *Quantificação da produção*: em estimativa de safra, direta ou indiretamente, em determinados momentos, para modular valores de comércio, estocagem, colheita, entre outros. Discriminar quantos frutos são produzidos no talhão, pomar, linha de plantio.

Normalmente, para 10 talhões, numa fazenda de 100 hectares, cada um provê um histórico de variedade (uniforme), época de plantio, época de colheita e características do solo. Com isso, a quantificação também atende a contagem de plantas, pela linha de plantio, se apresentam o mesmo tamanho, para conferência e verificação de variação de planta por planta e para diferenciar o grau de uniformidade da linha de plantio.

Como frutos cítricos são clones de plantas paralelas, a conferência deve verificar a regularidade das plantas, pelas medidas vertical e horizontal, variação de indivíduo a indivíduo, por inserção de adubo, fatores químicos e biológicos que discriminam tamanhos diferentes.

(b) *Quantificação dos frutos*: Discriminar pelo formato cônico e esférico, bem como a massa de frutos, contínua de vegetação, com as plantas se sobrepondo. Conforme a idade do

pomar, pode-se ter a caracterização quanto ao tamanho, projeção de copa que chega a tocar o solo, a tocar entre si, e a se sobrepor.

Ainda, a identificação de grupo de frutos, numa categoria de alta produtividade, com classificação por imagem, apresenta potencial histórico de ~1000 frutos por planta (potencial da cultura). Uma média de frutos por árvore (independente do teor do suco - uma vez que a qualidade é determinada em laboratório, via processo químico, ou por ressonância caracterizada pela água e açúcar, sem ser destrutivo ao fator biológico do fruto) produz 80Kg de frutos, dividido pela massa de um fruto ~220g, aproximadamente 370 frutos finais. Assim, o intervalo biológico é entre 300 e 500 frutos para cada árvore.

Como estimar os frutos não detectados no *foreground* da imagem também é uma das preocupações. Com isso, deve-se estimar o percentual sempre ao limite de frutos por árvore, mantendo a média e diminuindo o erro de análise.

Quanto maior a produtividade de frutos no interior do dossel, maior distanciamento da estimativa. Assim, é de interesse comparar a contagem obtida pela análise de imagens, com a derrubada de frutos (calibração do valor real com o estimado).

A produtividade também é determinada pelos elementos visuais no processamento, que são conjugados pela cor, formato, textura e esfericidade para uma estimativa de safra confiável. Ainda, deve-se analisar o formato bidimensional do fruto, calibração da cor de acordo com o clima, tamanho relativo entre 5cm e 7cm de altura, capturar ou emular a esfericidade, com até 30% de área verde e amarela, 'x' grau de acerto de maturação, 50% ou 70% a colheita está mais próxima ou menos próxima.

(c) *Diagnoses (qualidade/nutrição e doenças) dos frutos*: Coletar imagens de folhas devidamente expostas e compor a análise das características, estimando o fator de nutrição e a qualidade, uma vez que vários sintomas convivem na mesma planta, se confundindo, e em porções bastante restritas.

As doenças são setorizadas nas plantas. Dentro do fruto, deve-se caracterizar padrões visuais, e não dos ramos e galhos (análise biológica). Algumas manchas não uniformes podem ser confundidas com doenças, mas a referência de análise é dada pela esfericidade do fruto (até 50% de leitura do raio, como informação inicial de análise).

Outro fator que auxilia na diagnose é a verificação do nascimento biológico do fruto (pecíolo e ovário - aspectos biológicos) - um fruto normal começa a amadurecer de baixo para cima, do estíolo para o pecíolo. Um fruto com *Huanglongbing*/HLB (*Greening*) fica menor, com 60% aproximadamente do normal, e amadurece de cima pra baixo, mudando a esfericidade.

Estes três níveis de abrangência são, criteriosamente, investigados por análise, *a posteriori*, em laboratório, com maior nível de resolução e detalhamento biológico. Contudo, a proposta deste trabalho é agregar resultados trabalhados com sensores ópticos, que demandam alto nível de programação na obtenção de resultados visuais, o que identifica soluções estimadas, quando classificadas pela fusão de dados na quantificação e qualidade do fruto.

Ainda, a pesquisa desenvolvida no NEPAS (Núcleo de Ensino e Pesquisa em Automação e Simulação), do Departamento de Engenharia Mecânica da Escola de Engenharia de São Carlos (EESC/USP), sobre robótica móvel agrícola motiva a aplicação de tais técnicas de fusão sensorial (para locomoção/navegação e análise de culturas) com dois robôs móveis agrícolas experimentais RAM (Robot Agrícola Móvel) e Agribot, além de uma plataforma veicular de testes.

1.3. Objetivos

O objetivo geral deste trabalho é desenvolver uma metodologia de classificação conjunta de dados, por fusão sensorial ponderada, para análise qualitativa e quantitativa de frutos/produção, a partir de cenas naturais distintas de ambientes agrícolas, descrevendo características peculiares durante o período de plantio, maturação, conservação e colheita de culturas (citros/frutos) em épocas diferentes, mas de um mesmo talhão e variedade uniforme (*valência*).

As etapas que contemplam o objetivo geral são descritas a seguir:

- desenvolvimento de métodos e técnicas de aquisição de imagens perspectivas das linhas de plantio, através de câmeras posicionadas na proporção cinemática lateral dos veículos autônomos (câmeras VGA/CMOS com ajuste de orientação e posição) (*D-Link DCS-5635 N H.264 PTZ*);
- determinação de parâmetros para segmentação das regiões de interesse nas imagens térmicas, pela aquisição de sensor termográfico óptico, e correlação com as características de temperatura de reflexão, distância do objeto refletido e umidade relativa da cena natural (termógrafo FLIR série E-50);
- implementação de técnicas de pré-processamento e segmentação de imagens baseada em regiões não homogêneas;
- extração e normalização dos vetores de características das imagens RGB/HSV e térmicas por PCA (*Principal Component Analysis*) através dos histogramas de cada canal dos espaços de cores e dos parâmetros topológicos dos segmentos;

- desenvolvimento de técnicas de extração de características, e construção de matrizes de distâncias, pela aquisição de sinais por sonares (*XL-MaxSonar WRC MB7067*) - mapas de profundidade, e estimação do modelo espacial;
- desenvolvimento e aplicação de técnicas de tratamento de dados obtidos do sensor de refletância, para informações sobre índices vegetativos da planta;
- desenvolvimento de métodos para a classificação e identificação de aspectos geométricos dos objetos de interesse e fusão sensorial dos dados obtidos pelas imagens RGB/HSV, imagens térmicas, matrizes de distâncias e índices vegetativos, relacionando tamanho, forma, localização, posição e orientação, além de estimativas sobre a qualidade dos frutos.

2. AMBIENTES AGRÍCOLAS E VISÃO COMPUTACIONAL

Neste capítulo, são apresentadas as áreas científicas responsáveis pela manipulação, tratamento e processamento de dados em cenas agrícolas, que fomentam este projeto, como as etapas de um sistema de visão computacional (características e técnicas de processamento de imagens digitais, problemas de classificação e reconhecimento de padrões), bem como as aplicações destas áreas na robótica móvel agrícola. As pesquisas bibliográficas usadas como referências a este trabalho são abordadas, inicialmente pelo histórico de desenvolvimento e o atual estado da arte da agricultura de precisão, relacionando às tecnologias para aplicações em sensoriamento de parâmetros agrícolas, uso de sensores exteroceptivos como sonares para detecção de matrizes de distâncias e fluxo óptico para mapas de profundidade, e os trabalhos envolvendo visão computacional na robótica móvel agrícola para detecção, quantificação, análise e inspeção de culturas agrícolas, como parte da fusão sensorial pretendida.

Visão computacional é definida na literatura como a ciência que desenvolve as bases matemáticas e algorítmicas pelas quais informações de alto nível do ambiente são extraídas de imagens (entrada de dados) para análise e processamento (descrição ou interpretação da saída de dados), com uso de sensores ópticos (BOYLE & SMITH, 1970; DUDA & HART, 1970; EASTMAN, 2001), técnicas de processamento digital de imagens (CYGANNEK & SIEBERT, 2009), reconhecimento de padrões por métodos analíticos e estatísticos, e aplicações de Inteligência Artificial (IA) (FORSYTH & PONCE, 2002; SEBE *et al.*, 2005).

As informações analisadas em imagens digitais devem contextualizar as seguintes características: dimensão e representação espacial/geométrica, cor, textura e informação temporal para a aquisição dinâmica de imagens. As técnicas e operações aritméticas dedicadas ao estudo e análise das informações de tais imagens contemplam a área de Processamento Digital de Imagens (PDI), cuja aplicação busca a melhoria e realce de determinados aspectos da imagem tratada.

O processamento de imagens digitais é direcionado para funções e finalidades específicas, uma vez que o tempo de processamento, características e informações de entrada, e base de armazenamento devem ser considerados, para que possam ser aplicados em tempo-real ou manipulados de acordo com a necessidade temporal. No primeiro caso, para imagens complexas, que apresentam informações como elementos gráficos de forma, tamanho, cor e textura variadas, em cenas de distintas intensidades luminosas, e dependentes dos locais de aquisição, são utilizados algoritmos e técnicas sofisticadas de síntese, processamento, análise,

classificação e reconhecimento, envolvendo métodos analíticos e estatísticos para tais, em conjunto com a abordagem de Inteligência Artificial (IA). IA é definida como o estudo de agentes que percebem características do ambiente e executam ações específicas à percepção (FLORCZYK, 2005; RUSSELL & NORVIG, 2009). Em cada ação, é definida uma sequência de funções de percepção sensorial de um dado agente. Assim, estas funções de percepção são representadas por modelagens intrínsecas ao problema proposto, seja um sistema de produção, sistema de controle, sistema reativo e que desempenham a interpretação do ambiente estudado, por técnicas de aprendizagem. Tais técnicas são aplicadas nos módulos de visão computacional voltados à caracterização, classificação e reconhecimento de padrões.

Neste aprendizado, as informações que apresentam ruídos e incertezas qualitativas, causadas pelas adversidades naturais, durante a aquisição das imagens e pelas limitações dos sensores ópticos usados, são corrigidas com técnicas probabilísticas de estimação de estados recursivos, com aplicação de filtros não-paramétricos, gaussianos e robustos (THRUN *et al.*, 2005). Mesmo assim, deve-se considerar a natureza ambígua do processo de visão, cuja interpretação destas é distinta ao modo perceptivo de cada modelo de aquisição.

Na agricultura de precisão, a visão computacional expande-se em várias etapas e funções desta área, desde coleta e análise de dados de determinada lavoura, inspeção e localização de culturas agrícolas, até a navegação guiada e/ou autônoma de veículos, localização, mapeamento e planejamento de trajetórias por fusão sensorial. Por isso, são aplicados critérios para a efetiva automação entre robôs móveis e visão computacional na agricultura de precisão, com informações de entidades de interesse do agricultor: racionalização controlada na aplicação de herbicidas contra plantas invasoras, localizando e identificando somente os locais caracterizados pela invasão, reduzindo os custos de aplicação uniforme na plantação; automação de tarefas (substituição de mão de obra) para a colheita automática de culturas, com auxílio de fusão de sistemas computacionais, opto-sensores e manipuladores robóticos, através da guiagem automática de robôs móveis.

2.1. Visão computacional

A integração de processos e representações gráficas usadas para a percepção visual define de forma técnica a Visão Computacional (VC), que também pode ser entendida como a ciência que caracteriza informações de interesse numa imagem, envolvendo as seguintes etapas sequenciais de aplicação: aquisição, pré-processamento, segmentação, extração de características e reconhecimento (GONZALEZ & WOODS, 2007), mostradas na figura 2.1.

Figura 2.1: Estrutura sequencial de um sistema de visão computacional (Adaptado de GONZALEZ & WOODS, 2007).

Como mostrado na figura 2.1, as etapas sequenciais que contemplam a estrutura de um sistema de visão computacional são: aquisição, pré-processamento, segmentação, normalização das características de interesse, classificação e reconhecimento de padrões, aplicadas à resolução do problema, todas interligadas a uma base de conhecimento dos resultados obtidos. A estrutura sequencial das etapas presentes no sistema de VC se divide ainda em três estágios: visão em baixo nível (aquisição e pré-processamento); visão em nível intermediário (segmentação, extração e normalização de características); visão em alto nível (classificação, reconhecimento e correspondência). Nestes estágios, a modelagem e representação da imagem de entrada com o correspondente na base de conhecimento, através de interpretação, decisão ou descrição dos classificadores, são definidas como (FORSYTH & PONCE, 2002):

- a) *Imagens generalizadas*: são icônicas e atendem pelas propriedades físicas da cena;
- b) *Imagens segmentadas*: são classificadas pelos segmentos ou regiões de interesse;
- c) *Imagens geométricas*: atendem pela disposição geométrica da cena, para simulação de efeitos entre as componentes envolvidas no formato bidimensional ou tridimensional;
- d) *Imagens relacionais*: são estruturadas em interpolação de componentes dentro da cena, cujo interesse do problema a ser solucionado baseia-se na sua inter-relação.

Desta forma, o procedimento destas etapas no processamento de imagens digitais para o propósito deste trabalho, assim como a representação de imagens monocromáticas e coloridas, elementos de aquisição de imagem, o pré-processamento em realce de imagens, são

detalhados em Lulio (LULIO, 2011a). Todavia, a segmentação de imagens e reconhecimento de classes e padrões, como são prioritárias na aplicação do tema proposto, são detalhados a seguir.

2.1.1. Segmentação de imagens

Nesta etapa, são realizadas operações de processamento, como a redução de ruídos e extração de bordas das regiões de interesse dentro da imagem, e o reconhecimento de padrões para a interpretação de cenas (EGMONT-PETERSEN *et al.*, 2002; FORSYTH & PONCE, 2002; GONZALEZ & WOODS, 2007). Os elementos de interesse são separados do restante da imagem, para a extração de informações que serão usadas em sua caracterização.

Assim, os elementos são extraídos pelas discontinuidades das propriedades de *pixels* com o restante da cena na imagem, e também podem ser particionados em regiões homogêneas com propriedades internas semelhantes ou distintas entre si.

Define-se matematicamente a segmentação de imagens (CHENG *et al.*, 2001). Seja $P()$ o critério de homogeneidade definido em determinados *pixels* interconectados. O mesmo critério é particionado em um novo conjunto, ou imagem, R sobre outros subconjuntos de *pixels* ($R_1, R_2, R_3, \dots, R_n$), dado pela equação 01.

$$R = \bigcup_{i=1}^n R_i \rightarrow R_i \cap R_j = \emptyset, (i \neq j) \quad (01)$$

Logo, o critério de homogeneidade $P(R_i)$ será verdadeiro para todas as regiões e $P(R_i \cup R_j)$ quando houver vizinhança entre R_i e R_j , e $i \neq j$. As regiões obtidas através da segmentação devem manter relação condizente com as regiões de interesse ao critério de homogeneidade $P(R_i)$, uma vez que nem todos os algoritmos de segmentação não se aplicam à mesma imagem, tampouco um algoritmo apenas é aplicado a várias imagens adequadamente. Por isso, determinados sistemas de visão computacional operam em domínios distintos de imagens, relacionando-as de forma mais simples em estruturas definidas, ou complexas, devido às características do ambiente desconhecido.

A classificação dos algoritmos de segmentação obedece à técnica usada para criar os segmentos de interesse na imagem, e são relatadas a seguir (LEVINE, 1985; LUCCHESI & MITRA, 2001; LUCCHESI & MITRA, 2004; GONZALEZ & WOODS, 2007). Mais detalhes podem ser obtidos na revisão feita em Lulio (LULIO, 2011a).

Segmentação por detecção de pontos, linhas e bordas: As principais características são os pontos isolados, as linhas e as bordas, baseado na detecção de mudanças locais abruptas de intensidade. Os *pixels* são extraídos das bordas pela mudança abrupta da

intensidade de uma função imagem, e seus segmentos são conjuntos destes *pixels* convexos. Determina as fronteiras (bordas) das regiões de interesse. Se aplicada em detecção paralela de bordas, considera um conjunto de *pixels* pertencentes a uma borda. Se aplicada em detecção sequencial de bordas, o conjunto de *pixels* pertencentes a uma borda influencia os demais *pixels* vizinhos, sendo implementada por buscas heurísticas de estados.

Segmentação por limiarização de histogramas: São analisados os vales e picos em histogramas para a relação de limiares que definam as regiões das imagens analisadas, prevalecendo os tons de cinza, quando regiões de interesse são apropriadamente separadas, uma vez que o grau computacional aplicado é baixo. Tal técnica, quando estendida a imagens coloridas, apenas é viável quando o histograma tridimensional é calculado por partes, segundo as componentes analisadas.

Segmentação por regiões: A característica da imagem usada como informação de entrada é a disposição espacial dos *pixels*, cujas manipulações são feitas em cores não uniformes e em texturas, através do crescimento de regiões (seleção de um *pixel* ou pequena região que crescerá agrupando os *pixels* que satisfazem um critério customizado), divisão de regiões (partição de regiões não homogêneas em regiões homogêneas com o decréscimo de área dividida) e fusão de regiões (combinação de crescimento e divisão de regiões).

Segmentação por formação de agrupamentos no espaço de características: Os parâmetros do espaço de cores usado são usados para a extração da informação cromática, em que a classe de algoritmos exige que a imagem formada por regiões detenha somente cores uniformes. Aplicados como algoritmos não supervisionados (*k-means* e *fuzzy c-means*), e para algoritmos supervisionados (MLP e *k-vizinhos mais próximos*). A análise destes agrupamentos é feita através de concentrações de cores semelhantes em determinados grupos, então os *pixels* de um mesmo grupo recebem o mesmo rótulo, caracterizando-o como um segmento.

Segmentação por watersheds morfológicas: Inspeção topográfica da imagem, sendo as três dimensões gráficas que caracterizam as coordenadas espaciais e a intensidade. Pontos desta inspeção são analisados como pertencentes a um mínimo regional, os que identificam *watermarks* (marcas d'água) em um mínimo simples e os pontos que identificam a mesma probabilidade de *watermarks* em um mínimo simples.

Segmentação por lógica difusa (nebulosa/fuzzy) e redes neurais artificiais (RNA): A primeira é baseada na teoria dos conjuntos difusos para a manipulação de incertezas e ambigüidades, como classificadores de regiões por funções-membro pela relação do grau de pertinência com o estado de inferência dos estados nebulosos, destacando as regiões de

interesse. A segunda é relacionada a base do conhecimento por treinamento de dados na rede neural, em que os segmentos são classificados e relacionados a determinados neurônios ativos, e estes dependem de características dos dados armazenados, como a tolerância a ruídos e desempenho de processamento computacional. Como as redes neurais artificiais são estruturadas em diferentes arquiteturas, podem-se realizar agrupamentos de cores homogêneas por rede de *Kohonen*, como também aprimorar o critério de homogeneidade por rede de *Hopfield*, e *Perceptron* multicamadas direcionadas a aplicações envolvendo segmentação supervisionada, que são relatadas em trabalhos iniciais de processamento de imagens com aplicação de técnicas cognitivas de Eegmont-Petersen (EGMONT-PETERSEN *et al.*, 2002).

Para a avaliação dos algoritmos são relatadas duas abordagens: subjetiva e objetiva. A abordagem subjetiva (WEI *et al.*, 2009), avalia se os segmentos são coerentes com a imagem, através da inspeção visual da imagem segmentada, o que a torna suscetível a erros. Na abordagem objetiva (ZHANG *et al.*, 2005; 2008; 2009), dois modelos são aplicados:

- *modelo analítico*: considera a complexidade e propriedades do algoritmo, mas não de forma precisa na segmentação.

- *modelo empírico*: avalia indiretamente o algoritmo através das imagens segmentadas e, a partir destes, são calculados os índices de qualidade da segmentação em relação a algum critério estabelecido, como a adequabilidade (adotados critérios que medem a uniformidade dos segmentos, o contraste entre os mesmos ou a região geométrica de divisão, prescrevendo sua auto-avaliação de forma subjetiva) e discrepância (adotados critérios para avaliar os segmentos reais da segmentação ideal, através de imagens artificiais, o que os tornam objetivos e quantitativos, pois estabelecem a relação do número de *pixels* atribuídos incorreta ou corretamente para determinado segmento).

2.1.2. Reconhecimento de padrões

Padrão é considerado como uma forma básica de arranjo, o qual é caracterizado pela ordem dos elementos e suas características inerentes, que nele são constituídos (WIENER, 1942; GONZALEZ & WOODS, 2007). Tal arranjo é constituído de descritores, referenciados por conjuntos de características, e uma classe de padrões é uma família ou agrupamento de padrões que possuem propriedades comuns, indicadas por $\omega_1, \omega_2, \dots, \omega_m$, sendo ω o número de classes.

A identificação de objetos na cena, num modelo em visão computacional, é feita por meio dos descritores quantitativos, baseada no conteúdo registrado, como chave de busca para que o sistema retorne imagens semelhantes (CHANG *et al.*, 2010; NANDEDKAR, 2010;

RATLE *et al.*, 2010). A relação de reconhecimento de padrões na visão computacional se estende desde aplicações em nível industrial para a manipulação física de peças ou objetos reais, através de robôs industriais articulados (TRONCO, 1999; PEDRO, 2008a; PEDRO *et al.*, 2008b; PEDRO & CAURIN, 2008c), como no reconhecimento de culturas agrícolas, identificando irregularidades em frutos, plantas e obtenção de ângulos de guiagem pelas linhas de plantio (BLASCO *et al.*, 2007a; BULANON *et al.*, 2009; SLAUGHTER *et al.*, 2009; WANG *et al.*, 2009; WEI *et al.*, 2009).

O reconhecimento categoriza os objetos de relevância, seja em uma imagem, som, ou qualquer taxonomia física na geração de uma referência, com qualidades comuns que são agrupados de forma que os grupos tenham significado/semântica. Assim, tais objetos podem ser denominados casos, unidade de dados, observações, eventos, indivíduos, entidades, relações e taxonomias operacionais, criando-se uma hierarquia de informações organizadas, (o que em visão computacional relaciona a quantidade em *bits* para sua representação e de sua classe).

No reconhecimento de padrões, ainda, são conceituadas as características dos objetos representados por valores numéricos, cujos agrupamentos formam vetores de características (*feature vectors*) para descrições quantitativas, *strings* e árvores para descrições qualitativas estruturais. A implementação do algoritmo de classificação tem como objetivo a divisão do espaço formado pelos vetores de características em regiões associadas às classes dos objetos, que são n -dimensionais, denominados espaços de características. A quantidade de características é calculada por n .

A discriminação dos aspectos relacionados com as etapas de desenvolvimento a um classificador de padrões e classes de padrões aplicados em imagens, é condicionada pela composição das características dos elementos das imagens; normalização, extração e classificação de tais características; seleção, avaliação e validação do classificador; proporção da redução da dimensionalidade; erro e regra da decisão de *Bayes* em modelos estatísticos para classes gaussianas de padrões (LULIO, 2011a).

a) Composição das características dos elementos que compõem uma imagem

A estimativa das características que representam os objetos de interesse, deve obedecer como os vetores formados por estas estarão dispersos no espaço de características, e são relacionadas pelos seguintes estágios:

- i. Relacionar características distintas entre as classes, evitando ambigüidades;
- ii. Evitar características correlacionadas, uma vez que são redundantes;

- iii. Evitar discrepâncias de padrão em objetos pertencentes às mesmas classes (*outliers*);
- iv. Adotar quantidade mínima de características para a redução do custo associado ao processo de obtenção e classificação das mesmas;
- v. Relacionar características invariantes, com descritores quantitativos.

A organização dos dados para a representação do padrão estimado deve atribuir a criação de dados de dispersão com informações das projeções dos vetores de características, pertencentes a um espaço n -dimensional, que no caso da visão computacional, são considerados os objetos com atributos formados por matrizes numéricas com valores de intensidade da luz e cores, no espaço de cores analisado, e as características de contorno ou os *pixels* de preenchimento dos elementos, como descritores gráficos, listados na tabela 2.1:

Tabela 2.1: Atributos dos descritores gráficos no processamento de imagens, para reconhecimento de padrões (FORSYTH & PONCE, 2002; HILL, 2002; GONZALEZ & WOODS, 2007; LULIO, 2011a).

Atributo	Descrição
<i>Excentricidade</i>	<i>Razão entre o comprimento do eixo-maior e eixo-menor. Este último é a reta perpendicular ao eixo-maior com comprimento igual a um dos lados do retângulo que envolve todo elemento. O outro lado do retângulo é do mesmo tamanho do eixo-maior, e chamado de retângulo básico.</i>
<i>Curvatura</i>	<i>Taxa de variação de inclinação da curva definida pelo contorno, localmente ondulado, onde são realizadas medidas diferentes de curvatura, através da diferença da inclinação entre dois segmentos adjacentes do contorno. Este descritor depende da relação entre o comprimento total e o comprimento do trecho a ser analisado..</i>
<i>Número de formas</i>	<i>São calculados a partir da primeira diferença do código de cadeia para que seja a primeira posição da sequência, de forma circular. Os números de formas são independentes da rotação, mas não da orientação da grade formada pelos pixels, que pode ser alinhada com o retângulo básico, para a normalização da orientação. A quantidade de divisões da grade de pixels é determinada pela ordem do número de formas, representando os valores na cadeia.</i>
<i>Comprimento/Perímetro</i>	<i>Número de pixels do contorno da imagem ou código de cadeia, que é representado através de segmentos com tamanho fixo e direção variável. São usados para aproximar o contorno original, e cada segmento associa-se a um valor representativo de direção. O código de cadeia delimita a sequência destes valores. Assim, o comprimento da região de contorno é calculado pela soma entre quantidade de segmentos na vertical, na horizontal, e pelo produto da quantidade de segmentos na diagonal por $\sqrt{2}$.</i>
<i>Diâmetro</i>	<i>Distância mínima entre dois pontos pertencentes à borda de dado elemento, cuja reta que interliga tais pontos é denominada de eixo-maior, considerada como característica.</i>
<i>Momentos estatísticos</i>	<i>Dados pela média, variância e outros momentos, descrevem contornos representados por assinaturas. Estas simbolizam uma função com</i>

	<i>imagem unidimensional. A amplitude da função de assinatura é dada como variável aleatória, para o cálculo dos momentos. São descritores insensíveis a rotação e são normalizados com relação ao tamanho.</i>
<i>Descritores de Fourier</i>	<i>A interpretação do contorno de um elemento é dada por uma função com imagem complexa, onde os valores reais e imaginários representam as coordenadas dos pixels da borda.</i>
<i>Área</i>	<i>Os elementos avaliados por este descritor não sofrem transformações de escala, evitando distorções. Os elementos são discretizados pela relação da grade envoltória, e sua área é dada pelo preenchimento de cada quadrado, representando os pixels.</i>
<i>Compacidade</i>	<i>O descritor de compactação é dado pela relação dos descritores da área e do perímetro (comprimento). A razão entre o quadrado dos valores destes últimos fornece o valor do descritor de compactação.</i>
<i>Topologia</i>	<i>Estudo das propriedades das imagens sem deformações, para a representação global das características, independentes de medidas de distâncias, tais como: buracos de elementos, número de elementos conectados e número de Euler (dado pela diferença entre o número de componentes e o número de buracos).</i>
<i>Textura</i>	<i>Descritores caracterizados pela suavidade, regularização e direção. São extraídos de forma estatística (momentos estatísticos a partir dos histogramas dos tons de cinza, fornecendo texturas suaves ou granulares, sem considerar a informação espacial), estrutural (regras sintáticas para a criação de texturas com características mais complexas) e espectral (transformada de Fourier para analisar a textura à direção principal e ao período fundamental, representado pelo espectro polar).</i>

b) Extração e normalização de características - redução da dimensionalidade

A composição de cada padrão apresenta características interdependentes e pode não discriminar as classes entre si, sendo necessária a redução do conjunto de dados de entrada do sistema de reconhecimento de padrões para um conjunto mínimo pré-estabelecido por critérios ótimos. Considerando não apenas o fator computacional, como característica desfavorável ao trabalho com espaço de características de dimensionalidade muito alta, há ainda a “maldição/mal da dimensionalidade”, que torna o espaço de características esparso e proporcional para o número de padrões em treinamento e número de dimensões, comprometendo a classificação (GONZALEZ & WOODS, 2007).

A redução da dimensionalidade então, é aplicada a um tipo de pré-processamento aos padrões do classificador, considerando algumas medidas invariantes a rotação e mudanças de escala, em que suas informações proveem características mais adequadas. Assim, na extração de características, estas podem não originar espaços onde a dispersão dos vetores não mantenha proporcionalidade com a classificação, dificultando a discriminação das classes.

Logo, são usadas técnicas para a redução do número de dimensões, projetando vetores n -dimensionais para o conjunto de características sobre os elementos, evidenciando o espaço de características mais apropriado. Tais técnicas podem afetar o espaço da forma e influenciar na dispersão das classes, assim deve-se avaliar o classificador final para a produção de resultados satisfatórios (COSTA & CESAR JÚNIOR, 2001).

As unidades das características influenciam a dispersão dos vetores no espaço, calculado em relação a uma referência, como maior valor dos dados, para a normalização das características, dada por $(F(i,j))$, na equação 02.

$$F(i, j) = \frac{f(i, j) - \mu_j}{\sigma_j} \quad (02)$$

No resultado, o conjunto de dados terá média (μ_j) igual a zero e desvio padrão (σ_j) igual a um, sendo $f(i,j)$ o valor da característica j do vetor i .

Após a normalização, é feita a análise de componentes principais (PCA - *Principal Component Analysis*), com a transformação linear na minimização da covariância e maximização da variância. As características encontradas pela PCA são não-correlacionadas, evitando a redundância entre as características, o que significa que estas são relacionadas pelos maiores tamanhos de informações contidas nos dados, reduzindo assim, o número de dimensões (HAYKIN, 2008).

A PCA é calculada, para uma matriz $Z_{m \times n}$ (cada coluna representa um vetor m -dimensional), apresentando a matriz A (equação 03) com a projeção de Z sobre as componentes principais e Q é a matriz de transformação linear, composta pelos autovetores da matriz de correlação Z , que são organizados em ordem decrescente.

$$A = Z^T Q \quad (03)$$

O cálculo dos autovetores q_j e autovalores λ_j são encontrados pela relação de $R = E[ZZ^T]$, como a matriz de correlação de Z e $j = 1, \dots, m$. Já a matriz Q é obtida pela reescrita da equação de correlação, sendo $Q = [q_1, q_2, \dots, q_m]$ e $A = \text{diag}[\lambda_1, \lambda_2, \dots, \lambda_m]$.

c) Classificação das características

Na classificação de padrões, é feita a divisão espacial de características em regiões, com vetores pertencentes a determinadas classes, isto é, as fronteiras das classes são definidas, através de pesos intrínsecos a cada característica de acordo com um critério estabelecido. O método e o critério são modelos que descrevem os dados e suas classes, como

medidas de similaridade e dissimilaridade, estatísticas e limiares, critérios perto ou longe, probabilidade e níveis pressupostos.

Com isso, três técnicas discriminam o tipo de classificação de padrões, de acordo com as pré-definições e necessidades de correspondência: *classificação por critério imposto* (as classes dos objetos são conhecidas *a priori*, sendo necessária somente a extração de características); *classificação por exemplos* (supervisão de classes, iniciada pela análise do conjunto de exemplos ou conjunto de treinamento de dados – o método e/ou critério e parâmetros associados a um modelo são denominados, e depois comparados com os modelos de classificação existentes na base de dados); *classificação por critério aberto* (conjunto de treinamento como etapa de aprendizagem inexistente, dividido em classes pré-estabelecidas, e tampouco são conhecidos os dados que serão classificados, tornando o método não-supervisionado).

d) Seleção e avaliação/validação dos classificadores

Para que se comprove a eficácia e eficiência do classificador, os modelos de dados são criados em classes ou agrupamentos de interesse, apresentando incertezas intrínsecas ao método de classificação, o que torna necessário a validação dos resultados. Na generalização de um modelo de dados adequado, observa-se a estimação coerente da classe de um vetor não-supervisionado, e sua capacidade associada a complexidade das características envolvidas no modelo, como o número de parâmetros ajustados durante o treinamento. A complexidade do modelo fomenta a adaptação de dados organizados, mas não generaliza, o que certifica a validação de modelos equilibrados, para tanto generalizar, quanto aprender novos dados estruturalmente elaborados.

As técnicas que selecionam e validam os modelos de classificação, são definidas inicialmente pelo erro esperado do teste e o erro real de treinamento. Considerando $X \in RP$ um vetor aleatório e $Y \in R$ uma variável aleatória de saída, o modelo estima Y , tal que X seja dado pela função $g(X)$. A função $\hat{g}(X)$ é a predição de $g(X)$ encontrada através do aprendizado. O erro entre Y e $\hat{g}(X)$, é denotada por $L(Y, \hat{g}(X))$, na equação 04.

$$L(Y, \hat{g}(X)) = (Y - \hat{g}(X))^2 = |Y - \hat{g}(X)| \quad (04)$$

Se o modelo generalizar, o menor erro de teste será perceptível, após o treinamento, pois quanto mais complexo o modelo, menor será o erro do treinamento e maior será o erro do teste (*overfitting*). Logo, o erro de treinamento e o erro de teste (estimado de generalização) são dados a seguir, respectivamente, pelas equações 05 e 06.

$$\overline{erro} = \frac{1}{N} \sum_{i=1}^N L(y_i, \hat{g}(x_i)) \quad (05)$$

$$Erro = E[L(Y, \hat{g}(X))] \quad (06)$$

O erro de teste que estima a generalização dos dados, define a complexidade do modelo em sua seleção, analiticamente. O modelo com menor erro de teste é validado com o conjunto de testes, que representa um agrupamento de dados separados e não mais utilizado durante o treinamento. Depois, a avaliação para o classificador adequado passa pela etapa de treinamento, para a aproximação do modelo, a validação, para a seleção do modelo e o teste, para o erro de generalização. Outro método para avaliar o classificador consiste na matriz de confusão quadrada, onde as linhas e colunas representam as classes. As linhas denotam a classe de um padrão pertencente e as colunas denotam a classe estimada pelo classificador. Os valores associados aos elementos da matriz representam a quantidade de objetos já classificados, onde se verifica a distribuição do erro entre as classes, isto é, a existência de falsos positivos ou falsos negativos, para que seja calculada a matriz diagonal – proporcionalmente equilibrada (COSTA & CESAR JÚNIOR, 2001; FIGUEIREDO & JAIN, 2002; HASTIE *et al.*, 2003).

e) Erro estimado e decisão de Bayes

Santos (SANTOS, 2006) *apud* Lulio (LULIO, 2011a) fez a seguinte afirmação sobre a estimação do erro de *Bayes*;

"O erro estimado de Bayes calcula a perda de informações quando os dados são submetidos a uma transformação, em que a complexidade de um problema é reduzida durante a classificação. Trata-se da diferença entre o erro de Bayes das medidas iniciais e o erro de Bayes das características transformadas. Caso o problema não apresente PDF matematicamente em termos de parâmetros, são usados métodos não paramétricos para sua estimação, como a estimação de densidade de *Parzen* e estimação de densidade do *k*-ésimo vizinho mais próximo. Ambos medem localmente a densidade do espaço de características, e a vizinhança considerada é limitada pela distância (*Parzen*) ou limitada pelo número de vizinhos (*k*-ésimo vizinho)."

Dessa forma, o cálculo do erro de estimação é feito, em respeito às funções de densidade de probabilidade que representam a distribuição estatística dos padrões. O erro de *Bayes* é calculado para duas classes, dado pela equação 07.

$$P(erro | x) = \min[P(\omega_1 | x), P(\omega_2 | x)] \quad (07)$$

A probabilidade do erro para a classe ω_i ($i = 1$ ou $i = 2$) é calculado pelo teorema de *Bayes* (probabilidade condicional ou marginal, *a priori* ou *a posteriori*, respectivamente). O

teste da decisão de *Bayes* retorna a classe mais provável, comparando-se a taxa de máxima verossimilhança $l(x)$, a qual se for maior que a razão das probabilidades acima, entre as classes ω_1 e ω_2 , esta última terá mais chances de ser a correta, do contrário a classe 1 é considerada, e se ambas as classes forem equivalentes, compara-se $l(x)$ com 1, como apresentadas nas equações 08 e 09.

$$P(\omega_i | x) = \frac{p(x | \omega_i) P(\omega_i)}{p(x)} \quad (08)$$

$$l(x) = \frac{p(x | \omega_1)}{p(x | \omega_2)} \rightarrow \frac{P(\omega_1)}{P(\omega_2)} \quad (09)$$

2.2. Considerações finais

Neste capítulo foram revisados conceitos sobre visão computacional e reconhecimento de padrões, relevantes como fundamentação teórica para a base de estudo e pesquisa do referido trabalho, principalmente nos aspectos relacionados a classificação de dados/padrões para os casos específicos durante o desenvolvimento, como os estatísticos e cognitivos.

3. REVISÃO BIBLIOGRÁFICA

Neste capítulo são apresentadas as revisões bibliográficas clássicas e em estado da arte, para os temas relacionados com a proposta de desenvolvimento do referido projeto, iniciando por tecnologias empregadas no gerenciamento de agricultura de precisão, visão computacional aplicada à agricultura em geral, e trabalhos dedicados ao uso de sonares e demais sensores no mapeamento de ambientes agrícolas.

3.1. Revisão bibliográfica em agricultura de precisão

A Agricultura de Precisão (AP) agrega várias abordagens existentes relacionadas ao tema, como referências à coleta massiva de dados, sistemas georreferenciados, geração de mapas, implementos e aplicação de insumos a taxa variável. Entretanto, essas operações, quando realizadas de forma isolada, ou sem gerenciamento adequado, não fornecem ganhos efetivos como também podem gerar informações desencontradas.

Como abordado em trabalhos acadêmicos específicos da área (PEREIRA, 2008; TABILE, 2012), a AP deve integrar técnicas para o gerenciamento da produção agrícola, que tem o objetivo de reduzir as incertezas das tomadas de decisões para o melhor entendimento e gerenciamento das variáveis do campo, para prover tal método gerencial, que formaliza a multidisciplinaridade entre ciências agrárias, engenharias, geoestatística, ciências matemáticas e computação (McBRATNEY *et al.*, 2005; SRINIVASAN, 2006). A quantidade de dados processados, que são manipulados numa multiplataforma de gerenciamento para tomadas de decisão deve garantir eficiência e integridade às funções que a AP é submetida.

Ainda, a AP é descrita como o elenco de tecnologias e procedimentos utilizados para que as lavouras e o sistema de produção sejam otimizados, tendo como elemento chave o gerenciamento da variabilidade espacial da produção e dos fatores a ela relacionados (MOLIN, 2001; MENEGATTI & MOLIN, 2004). Complementando, é definida como uma metodologia de gestão à produção agrícola, cujas abordagens tecnológicas evidenciam a variabilidade espacial de seus fatores lógicos, para que a lavoura e sistemas de automação embarcados empregados sejam otimizados e customizados a determinados problemas (LULIO, 2011a). Estendem-se até a aquisição e tratamento para a coordenação homogênea das ações de intervenção cultural da lavoura (GODOY, 2007; 2011; GOZDOWSK & SAMBORSKI, 2007; TANGERINO, 2009). Para sua aplicação em sistemas automatizados, bem como mecanismos de coleta e processamento de dados, para novas práticas agrícolas, tais

como navegação e inspeção de culturas (LULIO, TRONCO & PORTO, 2009a; 2009b; 2010), são adaptados modelos matemáticos e computacionais que proveem à plataforma agrícola outras funções, como redes de comunicação, fusão de sensores, sistemas de posicionamento global, sistemas de informação geográfica, ente outros, a fim de analisar a variabilidade espacial por meio de sensoriamento remoto, e autonomia de máquinas agrícolas para práticas de manejo em culturas de interesse (AUERNHAMMER & SPECKMANN, 2006; GOZDOWSKI & SAMBORSKI, 2007; PEREIRA, 2008; TANGERINO, 2009; LEE *et al.*, 2010; AHAMED *et al.*, 2011).

Assim, os componentes computacionais instalados em máquinas e implementos agrícolas demandam elevado nível de processamento para a realização de tarefas complexas no âmbito agrário. Estes componentes definem um conjunto de instrumentação de alta tecnologia com o uso de um sistema computacional centralizado, denominado Unidade de Controle Eletrônico – UCE (*Electronic Control Unit – ECU*) (PEREIRA, 2008; NISSEN & HENNINGER, 2008). Todavia, a aplicação da UCE torna-se complexa à medida que o grau de dificuldade do problema envolvido no processamento e comunicação de dados aumenta e, conseqüentemente, requer a necessidade de se implantar um sistema computacional similar e distribuído, em respeito a normativas técnicas e protocolo específicos, que apresente as características ideais de implementação: robustez, confiabilidade, redução de conexões físicas e expansão de subsistemas modulares (PEREIRA, 2008).

Como sistemas distribuídos requerem interconexões definidas e com relativo grau de transmissões confiáveis de dados, o protocolo usado na automação de sistemas agrícolas denomina-se *Controller Area Network* (CAN), cuja estabilidade de comunicação é validada em camadas de baixo nível por processamento em tempo-real (AUERNHAMMER & SPECKMANN, 2006; PORTILLO *et al.*, 2006; SUVINEN & SAARILAHTI, 2006). Neste tipo de processamento, é necessário o emprego de sistemas eletrônicos de coleta de dados, bem como aplicadores de insumos que variam à taxa de aplicação (*Variable Rate Technology – VRT*) (SOUZA, 2002).

3.1.1. Gerenciamento da AP

Com o crescimento de áreas cultivadas, a eficiência da produtividade agrícola é aumentada pela incorporação da tecnologia da informação, para que as tomadas de decisão no ambiente agrícola considerem de forma homogênea dados adquiridos entre as cenas, solo e culturas, para gerenciar insumos e operações, tal qual a aplicação adotada (TABILE, 2012).

Várias práticas e tecnologias existentes e que ainda surgem atualmente, devem considerar a dinâmica de evolução e direcionamento em que a AP é discriminada, refinando os testes e resultados obtidos para outras aplicações em que a viabilidade dependa técnica e economicamente, mas ainda em função das características base que a contemplam (GOZDOWSK & SAMBORSKI, 2007; TABILE, 2012):

- Aquisição de dados por meio eletrônico-digital (automatizada e de baixo custo);
- Aquisição de dados com mais detalhes e menos abstração de informação;
- Informações, provenientes das operações de campo ou amostras do solo/produtos agrícolas, como entradas de dados da produção agrícola;
- Interpretação e análises dos dados formais e analíticas;
- Implementação da resposta localizada e adequada;
- Desempenho de sistemas de gerenciamento alternativo quantitativamente avaliado.

3.1.2. Tecnologias empregadas

A multidisciplinaridade formada pelas áreas que englobam a Tecnologia da Informação caracteriza o desenvolvimento de novas ferramentas, mecanismos, técnicas e métodos providos a Agricultura de Precisão, em que a dinâmica dos processos aplicados em funções distintas promove pesquisas em variáveis agrícolas, como propriedades físicas e químicas do solo, aspectos da nutrição vegetal, biomassa, doenças/pragas, inspeção de culturas, quantificação, manejo de implementos, e outros.

Para tal, os recursos usados nestas funções incluem conjunto de sensores exteroceptivos, visão de máquina (monocular, correspondência estéreo, omnidirecional), sistemas de informação geográfica, acesso remoto aéreo multiespectral, imagens com gradação térmica, variabilidade do ambiente, entre outros (ADRIAN, *et al.*, 2005; CORWIN & PLANT, 2005; HATFIELD *et al.*, 2008; SCHELLBERG *et al.*, 2008; LEE *et al.*, 2010; AHAMED *et al.*, 2011; AQEEL UR *et al.*, 2011; TABILE, 2012).

Assim, cada recurso será abordado em subitens para corresponder suas aplicações conjuntas interdisciplinares na AP.

a) Análise de imagens de alta resolução: A análise de informações de variáveis topográficas, descrevendo um mapa de produtividade de determinadas lavouras é importante para o manejo, cultivo e conservação de culturas de interesse, em que os dados podem ser obtidos através de meios convencionais, porém restritos como - monitores instalados nas colhedoras, durante o período de colheita (a informação é usada para análise *a posteriori*, sem

uso na safra atual); imagens de satélites na estimação de áreas amplas (a informação depende de condições climáticas favoráveis na captura de imagem, além de não serem aplicadas a áreas de cultivo menores, pelo custo elevado e baixa resolução temporal e espectral).

Como alternativa, imagens de alta resolução espacial/temporal e multiespectral são obtidas por meio do uso de veículos aéreos não tripulados, com capacidade de fácil atualização dos sistemas de controle e aquisição de dados, manobrabilidade e direção aplicáveis a aerodinâmica dependente do tipo de cultura, são de baixo custo, e permitem associação de sensores com máquinas agrícolas terrestres para maximizar a coleta de informações (LEON *et al.*, 2003; KHOSLA *et al.*, 2008; THAMRIN *et al.*, 2012; HE, CHU & CAMARGO, 2012; HUNG, BRYSON & SUKKARIEH, 2012).

Outra solução para este tipo de análise, é a correlação de dados multiespectrais na estimação de variáveis agrícolas (TUCKER *et al.*, 1980; YE *et al.*, 2008; VIÑA *et al.*, 2011), como índice vegetativo que informa a produtividade com percentuais possíveis de deficiência, aplicadas em culturas perenes e atuais. São combinações de espectro como: Infravermelho Próximo e o Vermelho (*NIR/Red*) (JORDAN, 1969); Índice Vegetativo por Diferença Normalizada (*Normalized Difference Vegetation Index - NDVI*) (ROUSE *et al.*, 1973); Índice Vegetativo Solo-Ajustado (*Soil-Adjusted Vegetation Index - SAVI*) (HUETE, 1988); Infravermelho Próximo e o Verde (*NIR/Green*); Índice Vegetativo Diferencial Normalizado baseado em Verde (*Green Normalized Difference Vegetation Index – GNDVI*) (YANG *et al.*, 2000; 2006). As variáveis agrícolas podem ser correlacionadas, pela análise de regressão em imagens.

b) Visão de máquina e termografia para detecção de linhas de plantio e análise foliar:

No capítulo seguinte, será tratado o tema de visão computacional por uma análise técnica, relacionando suas etapas de implementação, como aquisição da imagem, pré-processamento, segmentação, extração e normalização de características, reconhecimento e interpretação de classes e padrões. Da mesma forma, a revisão bibliográfica em estado da arte para análise, inspeção, localização e culturas agrícolas, é descrita como subitem deste capítulo. Assim, neste subitem são relacionadas algumas aplicações de visão de máquina com uso dedicado a agricultura de precisão, como tecnologias associativas embarcadas.

Através do uso de câmeras monoculares/estéreo (monocromáticas ou RGB/HSV) a análise gráfica bidimensional (digital) é mais uma fonte de dados para sistemas de visão computacional, que agregam informações sobre a percepção visual das cenas naturais. São suscetíveis a variação de fatores físicos (sombras, reflexão, oclusão, variação da luminosidade) em ambiente externos durante a aquisição, mas técnicas de processamento de

imagens são usadas para solucionar problemas intrínsecos à lavoura, como detecção de plantas invasoras, detecção de linhas de plantio para navegação e guiagem autônomas, detecção de culturas, colheita automatizada e estimativa de produção. (NIEUWENHUIZEN *et al.*, 2007; LULIO, TRONCO & PORTO, 2009a; 2009b; 2010; LEE *et al.*, 2010).

Trabalhos que realizam a detecção de plantas invasoras operam em modelos de interceptação da luz para diferenciar a presença ou a ausência de uma planta no solo, ou a recorrência a métodos probabilísticos de reconhecimento de padrões, usando parâmetros de refletância no espectro visível e não visível, textura, cor, formato geométrico e posição das plantas na imagem. São duas linhas de pesquisa que tratam deste assunto, como a diferenciação de plantas invasoras da cultura de interesse (verificação das características de ambas as plantas), e a identificação da planta invasora na seleção de herbicida e dosagem adequados (relação de características entre um conjunto maior de plantas) (NIEUWENHUIZEN *et al.*, 2007; TILLET *et al.*, 2008).

Para a verificação de doenças, relação de nutrientes, estrutura química que caracterizam a qualidade e desenvolvimento específicos da planta, é realizada a análise foliar. As técnicas variam conforme a aplicação, mas todas visam identificar áreas ou plantas contaminadas por determinada doença, provindas de fungos, bactérias ou vírus. São técnicas sob imagens no espectro visível e infravermelho, termografia óptica, foto reflexão e fluorescência. Na fluorescência, a detecção de doenças é feita nos estágios iniciais, mesmo antes de alterações visíveis no tecido da planta, todavia a acurácia é dependente da intensidade luminosa; a foto reflexão identifica o fator de estresse foliar, mas é eficiente somente após o aparecimento visível dos sintomas e sensível a descoloração da folha; a termografia detecta doenças relacionadas com a hidratação foliar, mas é dependente de iluminação, baixa acurácia em climas instáveis e na identificação das espécies (LAMB *et al.*, 2007; KUCKENBERG *et al.*, 2009; NAIDU *et al.*, 2009).

c) Volume de biomassa e características do solo:

Como é relatado em Tabile (TABILE, 2012), a definição de aplicações de insumos, fertilizantes, herbicidas, irrigação, saúde e vigor da planta é atribuída ao volume de biomassa, que pode ser obtida através de varredura óptica por nuvem de pontos *laser*, ultrassom, imagens aéreas e intensidade da luz solar no dossel. Ainda, a cultura pode influenciar no rendimento e qualidade do produto final, tanto para culturas anuais, quanto perenes, para a estimação da biomassa (JAHN, 1979; HASELGROVE *et al.*, 2000; EHLERT *et al.*, 2008; BALSARI *et al.*, 2008).

Paralelamente à verificação da taxa de biomassa, fatores correspondentes a ligações químicas e propriedades físicas/biológicas do solo são relevantes durante o desenvolvimento da cultura. Por conta disso, métodos tradicionais que são aplicados em análise laboratorial *a posteriori* podem não ser viáveis, dada a resolução amostral não ser definida. Assim, são estudadas maneiras e técnicas de análise remota e por sensores de macronutrientes do tipo *on-the-go*. Tabile (TABILE, 2012) destaca que a espectroscopia de refletância para análise de solos é estudada desde 1960, que se baseia na análise de espectros com ultravioleta, espaço de cores RGB, infravermelho e NIR. São relacionados trabalhos que investigam as propriedades de matéria orgânica do solo, carbono e umidade. Da mesma forma para elementos químicos como o fosfato, fósforo, cálcio, magnésio, sódio, zinco, areia, pH e tamanho de partículas (FREITAG *et al.*, 1970; WISMER & LUTH, 1974; KRISHNAN *et al.*, 1980; KANO *et al.*, 1985; BOGREKCI & LEE, 2006; FROEHLICH, 1934 *apud* LEE *et al.*, 2010; LADONI *et al.*, 2010; ZHANG *et al.*, 2011).

3.2. Revisão bibliográfica em visão computacional aplicada à agricultura

Este subitem reúne trabalhos em estado da arte que apresentam técnicas, métodos, funções e aplicações da visão computacional na robótica móvel agrícola, para análise, inspeção e localização de culturas, tanto por processamento de imagens bidimensionais obtidas por câmeras CCD/CMOS, como por termovisores (imagens térmicas).

Trabalhos que lidam com a análise e inspeção de culturas agregam métodos e técnicas dedicadas a cada situação, avaliando as condições da cultura, sua relevância, fatores característicos e externos que influenciam desde o plantio, conservação até a colheita. Logo, são relacionados trabalhos neste âmbito, descritos e revisados, baseados na revisão recente sobre tais tópicos em (LULIO, 2011a).

-Imagens coloridas nRGB:

Na identificação e localização de laranjas, foi desenvolvido uma plataforma robótica para colher frutos (BULANON *et al.*, 2009). Os autores apontaram que este sistema deve lidar com as seguintes situações: grande amplitude de iluminação; elementos parcialmente ocultos; incertezas relacionadas com a forma do fruto; espaço limitado de operação e restrições de tempo-real. Na figura 3.1, são mostradas as etapas realizadas no referido trabalho.

Figura 3.1: Etapas do processamento de imagens - (a) aquisição da imagem; (b) segmentação; (c) filtragem; (d) detecção de bordas; (e) discriminação dos círculos (BULANON *et al.*, 2009).

Ainda, os autores inicialmente transformaram os *pixels*, que têm as cores representadas no modelo de cores RGB para níveis de cinza. Desta forma, as laranjas foram destacadas dos demais elementos da cena, que eles definem como ROI (*region of interest* - região de interesse). As laranjas foram encontradas quando os *pixels* foram classificados após as etapas de segmentação, filtragem, detecção de bordas e discretização de círculos, pela relação entre o número de frutas visíveis ao observador humano, em determinada cena i , pelo número total de frutas dentro da ROI, o que resulta na visibilidade de frutos desta cena.

Em trabalho similar, Lopes (LOPEZ *et al.*, 2009) aprimorou a classificação de *pixels* das laranjas após processo de segmentação por máscara de gradiente de Sobel, por extração de características em relação a média, variância, curtose (achatamento) e classes.

Os autores destacaram em três etapas o procedimento da proposta: inicialmente ocorre a segmentação por detecção de bordas (máscara de gradiente de Sobel), para localizar a possível correspondência de irregularidades; logo, ocorre a extração de características da região tentativa de irregularidade na textura do fruto (segmentada) - são atribuídos 5 parâmetros dentro do espaço de cores RGB (média, variância, curtose ou achatamento, classe de regiões e assimetria); por fim, são empregados dois classificadores, um baseado na relação de distâncias e outro por redes neurais artificiais.

Na figura 3.2, são apresentados os diferentes tipos de irregularidades nas cascas/superfícies das laranjas.

Figura 3.2: Diferentes tipos de irregularidades nas cascas das laranjas (Adaptado de LOPEZ *et al.*, 2009).

Na figura 3.3, observa-se a aproximação poligonal de falhas em superfície do fruto, com a representação por bordas, e a segmentação das áreas para irregularidades encontradas nas laranjas.

Figura 3.3: (a) Aproximação poligonal de falha em superfície – cada nível de cinza representa uma borda diferente; (b-c) Área de segmentação para dois tipos de irregularidades nos frutos (LOPEZ *et al.*, 2009).

Outros trabalhos foram desenvolvidos em sistemas de visão computacional similares para localizar e avaliar o tamanho de laranjas (LI *et al.*, 2009; RAO & YING, 2009; STORY *et al.*, 2010). As imagens foram digitalizadas com resolução espacial de 256×256 pixels e 256 níveis de cinza. Os autores, nos dois trabalhos, adotaram exemplos de laranjas com diversos diâmetros, os quais foram usados na operação de correlação e morfologia matemática, a qual foi feita no espaço das frequências devido à restrição temporal. O erro causado pela distância da câmera e da laranjeira foi corrigido utilizando-se um modelo de laranja com tamanho conhecido, para o reconhecimento de classes.

Para não envolver este modelo analítico, outros autores (BLASCO *et al.*, 2009) propuseram a adaptação da inspeção automática de frutos, não apenas quanto ao tamanho, mas quanto à disparidade entre os tipos de doenças presentes em tais frutos, aplicando refletância infravermelha e informação espectral por indução ultravioleta. A análise morfológica das irregularidades é realizada pela extração do perímetro dos objetos de interesse (contorno próximo), que são formados por *pixels* pertencentes a vizinhança parte da região em *background*. O centróide de área é calculado como a média das coordenadas x e y , dos *pixels* dentro deste perímetro, e a área é calculada como o número de *pixels* dentro do perímetro. O histograma da imagem por fluorescência denota que os pontos mais altos correspondem aos *pixels* da casca da laranja sem irregularidades, e os pontos mais baixos, os *pixels* das regiões com irregularidades.

Na figura 3.4, a seguir, são apresentados os detalhes do tamanho, forma e cor para as doenças estudadas (*chilling injury*, *p.digitatum*, *lycopersicon esculentum*, *ceratitis*, *anthracnose*, *stem-end injury*, *scarring - scirtothrips citri*, *thrips scarring - moulton*, *sooty mould - ascomycete*, *fitotoxidade*, *oleoscellosis*).

Figura 3.4: Detalhes do tamanho, forma e cor para as doenças estudadas (BLASCO *et al.*, 2009).

Em trabalhos anteriores, Blasco (BLASCO *et al.*, 2007a; 2007b), apresentou um método para separação e identificação de regiões irregulares em frutos (laranjas), como os arilos (cobertura das sementes a partir do funículo - falso fruto). Os algoritmos foram aplicados no espaço de cores RGB, com aquisição de cada imagem por 40ms, fazendo com que a inspeção de cada cena é processada em paralelo com a aquisição seguinte. A região em *background* é removida por um limiar no canal R (*red*), uma vez que a cor vermelha do arilo contrasta com o formato das correias que fazem o transporte no mecanismo de seleção. Logo, cada região é rotulada como objeto de interesse, e tem seu centróide calculado pela média das coordenadas cartesianas dos *pixels* em RGB. A média das coordenadas das cores são usadas para classificar em 4 opções pré-definidas na matriz de confusão dos limiares R/G.

Com essa relação, também foi possível para que os autores atribuíssem denominações de segmentos distintos para cada arilo (figura 3.5), dada a matriz de confusão (tabela 3.1), correspondendo as classes de segmentos completos, quebrados, duplos e fragmentos de segmentos/com sementes.

Figura 3.5.: Diferentes classes de segmentos - (a) segmentos completos, (b) segmentos quebrados, (c) fragmentos de segmentos ou com sementes, (d) segmentos duplos (BLASCO *et al.*, 2007a).

Tabela 3.1: Matriz de confusão das classificações para os limiares dos canais R/G (BLASCO *et al.*, 2007a).

Atual/Classificado	Branco	Rosa	Vermelho	Marrom	Outros
Arilo branco	92,0%	4,0%	0,0%	2,7%	1,3%
Arilo rosa	1,5%	91,4%	1,5%	5,6%	0,0%
Arilo vermelho	0,0%	2,3%	89,2%	8,5%	0,0%
Arilo marrom	0,8%	4,7%	5,5%	89,0%	0,0%
Outros	1,7%	0,0%	0,0%	0,0%	98,3%

Usando a informação de cores, o sistema pode processar as imagens com tempo considerável, desde que a detecção seja processada junto com a etapa de segmentação. E para tal, os autores realizaram a obtenção de imagens por três sistemas distintos: câmera RGB, sensor de refletância por infravermelho próximo (NIR) e sensor de fluorescência por ultravioleta induzida (UVFL). Os três são combinados por um classificador *Bayesiano* que calcula a probabilidade da região de interesse nas imagens segmentadas, pelas coordenadas cartesianas dos *pixels* daquela região, e pela extração de características morfológicas de cada imagem obtida para cada sistema. Ainda, são usadas duas técnicas de segmentação distintas (CART e LDA). A primeira (*Classification and Regression Trees*) lida com alvo de classificação e regressão, em que ocorre particionamento das variáveis recursivas dentro da região de interesse, como lógica regressiva. A segunda (*Latent Dirichlet Allocation*) adota o modelo de distribuição de *Dirichlet*, como produto estatístico da região de interesse e a região latente passível de ser segmentada. Detalhes podem ser vistos na figura 3.6.

Figura 3.6: Na sequência de imagens acima, da esquerda para direita tem-se a imagem visível, imagem NIR e imagem UVFL; na sequência de imagens abaixo, da esquerda para direita tem-se a imagem do fruto com irregularidade, segmentação usando CART, e segmentação usando LDA (Adaptado de BLASCO *et al.*, 2007b).

Seguindo a mesma metodologia de Blasco (BLASCO *et al.*, 2007b), porém com aplicação distinta, Li (LI *et al.*, 2007) desenvolveu um sistema de detecção automática, com a preocupação em classificar laranjas com tonalidades e cores diferentes (alaranjado e amarelo), bem como seu crescimento. A abordagem usada neste trabalho foi por agrupamento de classes baseado na distância *Mahalanobis*, para a detecção dos frutos, após a translação e revolução em escala de nível cinza, com trabalho similar também em Rao e Ying (RAO & YING, 2009).

Em Lekhal (LEKHAL *et al.*, 2008), os autores desenvolveram um sistema de visão computacional para estimar o número de frutos em pomares de laranjas. A identificação dos

frutos foi feita através das seguintes operações: binarização (utilizando a matiz e a saturação), limiarização (considerando-se a área dos elementos), dilatação, erosão, preenchimento e extração das características. As laranjas foram contadas considerando-se o número de elementos não conectados na imagem. A identificação é aprimorada com a classificação de texturas e a implementação de algoritmo genético (AG). Shiigi (SHIIGI *et al.*, 2008) modificou as técnicas acima com a implantação de um sistema de visão com três câmeras coloridas (visão estéreo e central) para, além de localizar os frutos, manipulá-los através de um robô articulado com 3 graus de liberdade, e verificar a inclinação e consistência do pedúnculo de determinado fruto.

A segmentação de frutos para a quantificação também foi tema de trabalho em Yin (YIN *et al.*, 2008). O tamanho dos frutos foi estimado com auxílio de um sensor de ultrassom. As cores das imagens eram representadas originalmente no espaço de cores RGB, e posteriormente convertidas para o espaço de cores HSL, para a obtenção de melhores resultados. As imagens foram segmentadas através da classificação dos *pixels* e, posteriormente, estas foram pré-processadas para a remoção de ruídos. Foram construídos três classificadores: bayesiano, baseado em RNA e baseado na discriminação linear de Fisher. Os *pixels* foram classificados considerando-se a matiz (H) e a saturação (S). As funções de densidade de probabilidade condicionais foram estimadas pelos histogramas dos valores dos *pixels*, que foram quantizados novamente em valores distintos. Os autores ainda aprimoraram as técnicas de segmentação de *pixels* para outras quatro derivações: método de segmentação por limiar dinâmico, método de Otsu, método de Otsu combinado com algoritmo genético e segmentação adaptativa baseada na rede LVQ (Quantização Vetorial por Aprendizagem).

Na tabela 3.2, é mostrada a comparação do custo do tempo de processamento entre os métodos tradicional, estendido e aprimorado de Otsu, combinados com algoritmo genético (YIN *et al.*, 2008).

Tabela 3.2: Comparação do custo de tempo de processamento das culturas analisadas para as três variações do método de Otsu (Adaptado de YIN *et al.*, 2008).

Métodos		Otsu tradicional	Otsu estendido	Otsu aprimorado
Custo de tempo de processamento/s	Maça	0,016	0,032	0,031
	Tomate	1,031	0,062	0,047
	Morango	0,016	0,032	0,029
	Laranja	0,047	0,089	0,063

A classificação de plantas invasoras foi tema de trabalho de Savakar e Anami (SAVAKAR & ANAMI, 2009), que o fizeram por um sistema de visão computacional na classificação em duas classes segundo o tipo de folha. Os autores adotaram esta abordagem, pois a escolha do herbicida depende do tipo da folha e não da espécie da planta invasora, o que simplifica o classificador de padrões. As imagens digitais usadas apresentam resolução espacial de 640×480 pixels e resolução cromática de 24-bits, com espaço de cores RGB adotado. As imagens foram feitas em ambiente aberto, assim com o objetivo de minimizar a influência dos pixels que representam o solo na análise das folhas, a imagem foi segmentada utilizando a limiarização, ajustada de forma empírica, do índice de excesso de verde modificado. Os valores obtidos foram normalizados (vetores de características de treinamento) e a norma do número complexo foi calculada. O classificador adotado foi o Perceptron multicamadas, treinado com o algoritmo Backpropagation, agregando informações das características morfológicas, texturas e cores.

No trabalho de Wei (WEI *et al.*, 2009), os autores desenvolveram um sistema de reconhecimento de maçãs baseado em SVM (Support Vector Machine). O filtro vetorial mediano é aplicado primeiramente na remoção de ruídos de imagens coloridas das frutas. Em seguida, é realizada a segmentação de imagens baseada no método de crescimento de regiões, caracterizando as propriedades das cores segmentadas. Por conseguinte, tais propriedades das cores e também do formato das maçãs são extraídas, para a classificação das imagens usando SVM (ZHAO *et al.*, 2008; WANG *et al.*, 2009).

Outro trabalho na área de reconhecimento de frutos, que aborda métodos analíticos é relatado em Shou (SHOU *et al.*, 2009). Neste trabalho, os autores comentaram a dificuldade em se realizar a detecção de bordas, segmentação e recuperação de contornos em frutos para imagens coloridas, e propuseram uma nova abordagem na detecção de contornos no espaço de cores RGB numa metodologia rápida e eficaz, baseada no modelo Chan-Vese (JIANYUAN & CHONGYANG, 2009; MEWADA & PATNAIK, 2009; WANG *et al.*, 2010). Neste modelo, os autores customizaram o algoritmo de ordenação de frutos, por apresentar relativa precisão na detecção de bordas das formas geométricas dos frutos, sendo desnecessária qualquer etapa de pré-processamento, mesmo para imagens com ruídos e desfocadas.

Si (SI *et al.*, 2009) e Lee (LEE *et al.*, 2009) propuseram um trabalho de reconhecimento de maçãs baseado no método analítico por clustering (algoritmo k-means) (MALYSZCO & STEPANIUK, 2009; 2010; YE *et al.*, 2009) para diferenciar maçãs verdes de folhas com a mesma textura. As imagens possuem blocos definidos com resolução espacial de 8x8 pixels para a implementação distinta de cada algoritmo k-means. As componentes R e

B do espaço de cores RGB foram escolhidas para a caracterização de cores e o valor médio, ao passo que para a caracterização de texturas foram escolhidos o desvio padrão e entropia em imagens com níveis de cinza para a posterior extração de características. Os experimentos de reconhecimento foram conduzidos à aplicação do algoritmo em 200 amostras de imagens adquiridas sob variações de iluminação distintas, e os autores garantem que, por este método, a percentagem de certeza no reconhecimento é superior a 80%.

Liming e Tanchao (LIMING & TANCHAO, 2010) desenvolveram um sistema de classificação de morangos, considerando três características: forma, tamanho e cor. Neste sistema, os autores comprovaram a obtenção das características da forma geométrica através da manipulação das linhas de contorno e a classificação pelo algoritmo k-means e entropia (SIMION *et al.*, 2009; VERMA *et al.*, 2009; ZHANG *et al.*, 2009).

A cor do morango foi caracterizada pelo método de cor dominante e o tamanho descrito pelo maior diâmetro encontrado. A automação deste sistema de classificação gera problemas de multicaracterísticas de cores, tamanhos e formas, sendo sua resolução baseada na adaptação de um sistema físico, com uma correia de transmissão, uma câmera, dois sensores fotoelétricos e parafuso de avanço acionado por um motor. Tal sistema é controlado por um microcontrolador e realiza a aquisição da imagem conforme o fruto é conduzido pela correia. Os resultados, segundo os autores, denotaram que o erro na detecção do tamanho dos morangos não passa dos 5%, sendo a precisão na classificação de cores em 89% e a precisão na classificação de formas superior a 90%. A média de tempo na classificação para as três características é de 3s.

A extração de características dos morangos dá-se pela conversão do espaço de cores RGB em níveis de cinza, cujos valores associados ao pedúnculo e receptáculo floral do fruto são maiores que o resto da cena. Para delimitar a região do morango, foram usadas características do tamanho, forma e cor do fruto. A característica da forma foi obtida pelo contorno e a normalização do comprimento das sequências lineares para eliminar a influência de um padrão de tamanho para este tipo de fruto. Assim, a geometria atende a vários tipos de formas de morango, auxiliado também pelo algoritmo k-means para a determinação do centróide de área para a classificação da forma do fruto.

Em Lü (LÜ *et al.*, 2010), os autores usaram a diferença G-B de cores em imagens em tons de cinza, para a aplicação do algoritmo Otsu (GAO *et al.*, 2010; XIA & FENG, 2010) na segmentação de imagens de frutos cítricos maduros e a textura no fundo das imagens. As imagens que apresentam frutas sobrepostas foram separadas pelo método Watershed (MEURIE *et al.*, 2010; ZHANG *et al.*, 2009) com a transformação da distância, e foram

retificadas com o algoritmo de fecho convexo (*Convex Hull*) (CHEN & CHAN, 2009; SIRAKOV & USHKALA, 2009). Após a extração das linhas de contorno das imagens, foi realizada a filtragem da média dos mínimos quadrados com a função de peso e profundidade *Tukey*, e assim foram obtidas as coordenadas de centróide e do raio da imagem. A base de imagens para a realização dos experimentos apresenta 87 imagens, para o reconhecimento de 592 frutos, com taxa de precisão em 87%, e a acima de 80% para as imagens de frutos sobrepostos.

Em Payne (PAYNE *et al.*, 2013) os autores apresentaram uma abordagem para a quantificação de frutos (mangas), em cada árvore. Os *pixels* nestas imagens foram segmentados nos objetos pretendidos e no plano de fundo, realizado nos espaços de cores RGB e YCbCr. Eles destacaram as dificuldades durante a aquisição das imagens, pelo efeito da oclusão da biomassa e intensidade luminosa, em que as mangas estavam atrás de elementos como caules e galhos, ramos e folhas, ou os quatro em algumas cenas, da mesma forma como a sombra influenciava nestas condições. A aquisição era feita em RGB, posteriormente, com a segmentação do canal R e do canal G, e depois convertida em YCbCr, com a seleção dos canais Cb e Cr (componente cromático de azul diferencial / componente cromático de vermelho diferencial). A identificação acontecia quando o canal Cr apresentava 150 *pixels* ou mais naquela região segmentada (objeto) e o canal Cb apresentava menos que 150 *pixels* (plano de fundo). Na figura 3.7, são apresentadas as etapas de PDI.

Figura 3.7: Etapas de segmentação e classificação, considerando o índice de diferença normalizado, o filtro de variância, componentes Cb e Cr, e inserção de rótulo no objeto encontrado, separado do plano de fundo (PAYNE *et al.*, 2013).

Trabalhos semelhantes foram feitos em Guzman e Nayeli (GUZMAN *et al.*, 2013; RIVERA, *et al.*, 2014) que lidam também com mangas e azeitonas, porém trabalhadas com segmentos de quadrantes da forma geométrica de cada cultura. São auxiliadas por comparação em imagens NIR, e combinadas pela seleção de características por PCA (*Principal Component Analysis*).

Outros trabalhos científicos clássicos, anteriores a 2005 estão descritos e detalhados em Lulio (LULIO, 2011a).

- Imagens por termografia óptica:

Com parâmetros similares às imagens visíveis (RGB) e infravermelho próximo (NIR), imagens térmicas (TIR - *thermal infrared*) contém informação espacial do objeto retratado. As diferenças clássicas entre elas, consistem na informação sobre a energia emitida em forma de ondas *eletromagnéticas* (comprimento de onda de 3 até 12 μ m) pela superfície do corpo, nas imagens TIR, enquanto que as imagens RGB e NIR contém informação sobre a energia refletida (comprimento de onda de 0,35 até 1,0 μ m) pela superfície do corpo. Imagens RGB estão relacionadas com o pigmento absorvido (composição química), imagens NIR estão relacionadas com a dispersão (estrutura geométrica celular) e imagens TIR estão relacionadas com propriedades termodinâmicas, emissividade e situação do arredor (LEE *et al.*, 2010; TABILE, 2012).

Na detecção de irregularidades na textura de maçãs (como manchas e crostas), os autores em Belin (BELIN *et al.*, 2013) propuseram um método de comparação entre termografia e imagens por fluorescência óptica para identificar imperfeições na textura de folhas de macieiras. Destacaram que as vantagens das imagens térmicas em relação ao método de correlação pela distância *Bhattacharrya*, e curvas ROC na quantificação do

percentual detectado, passível de irregularidades, podem melhorar a análise de patogenicidade, manchas naturais e pragas específicas da biomassa.

Na figura 3.8 são apresentadas as imagens multimodais de folhas de macieiras, com os sete níveis de patógenos, causadores de irregularidades/deformidades na superfície. Os níveis de infecção são classificados por uma representação de escalas em notação visual, como 'visível de irregularidade na folha codificada', 'estado inicial da imagem fluorescente', 'eficiência quântica da imagem fluorescente' e 'imagens térmicas em Kelvin'.

Figura 3.8: Imagens multimodais registradas de folhas de macieiras, apresentando sete níveis de patógenos que causam irregularidades na superfície, 21 dias após inoculação. Os níveis de infecção estão classificados de acordo com a escala de notação visual (1: 0–1%, 2: 1–5%, 3: 5–10%, 4: 10–25%, 5: 25–50%, 6: 50–75%, 7: 75–100%). As colunas de 1-7 representam estas classificações: (A) imagem visível de irregularidade na folha codificada; (B) estado inicial da imagem fluorescente; (C) eficiência quântica da imagem fluorescente; (D) imagens térmicas em Kelvin (BELIN *et al.*, 2013).

Uma das aplicações da termografia óptica é a estimativa do número de frutas em pomares (BULANON *et al.*, 2008; WACHS *et al.*, 2009). A detecção é baseada na suposição de que a temperatura do fruto é diferente dos arredores da cena. Essa suposição é confirmada em muitos casos, uma vez que as propriedades termodinâmicas do fruto são diferentes dos elementos adjacentes. Tanto frutos como biomassa (folhas, ramos e galhos) são constituídos basicamente de água, mas como a massa é usualmente diferente, isto faz com que a resposta do transiente termodinâmico seja diferente. Uma série de fatores interferem nos dados, tais como insolação, umidade relativa do ar, velocidade do vento, temperatura ambiente e taxa de

emissividade. Nestes trabalhos, as aplicações são voltadas também para a fusão de imagens multimodais.

Outra aplicação que é associada à análise de imagens térmicas lida com o estado hídrico das plantas, detecção e mapeamento de doenças e vetores (JACKSON *et al.*, 1981; ZYL, 1986). A temperatura do dossel das plantas é reconhecida como uma medida do estado de hidratação destas, embora não deve ser considerada como o único parâmetro de indicador hídrico, uma vez que esta é influenciada pelas condições meteorológicas (ZHANG *et al.*, 2007; WANG *et al.*, 2010). Sendo assim, recomenda-se o uso de um índice normalizado (CWSI - Crop Water Stress Index) (CLAWSON *et al.*, 1989; IDSO *et al.*, 1981), baseado na diferença entre a temperatura encontrada em uma superfície úmida, seca e a planta analisada. A aquisição das imagens pode ser feita por uso de veículos aéreos não tripulados (MERON *et al.*, 2010), ou combinada com a fusão de imagens RGB, NIR, TIR e GLCM (*Grey-Level Co-occurrence Matrix*) (MOLLER *et al.*, 2007).

3.3. Revisão bibliográfica de sonares aplicados ao mapeamento de ambientes agrícolas

Sonares também são usados para corresponder as medidas de distância adquiridas pela reflexão da onda sonora emitida, formando assim, uma matriz de distâncias ou mapas de profundidade. Como a literatura técnica da área traz poucos artigos relacionados com o uso de sensores de ultrassom para mapeamento de objetos (plantas) presentes em cenas agrícolas, são apresentadas as principais referências bibliográficas abordando tais aplicações, relacionados entre 1995 e 2010, e outros mais clássicos anteriores.

Técnicas de pulverização ambientalmente seguras têm sido desenvolvidas para reduzir o uso de produtos fito-farmacêuticos (PFF) e aplicá-los apenas quando e onde necessário com redução do impacto ambiental. Neste sentido, tecnologias são desenvolvidas para ajustar a dosagem nas características de cada tipo de cultura (DORUCHOWSKI & HOLOWNICKI, 2000). Estes autores destacaram que sensores de ultrassom e ópticos podem ser usados com pulverizadores convencionais, à base de fluxo de ar. Sinais obtidos a partir dos sensores, juntamente com os dados sobre a velocidade de deslocamento do pulverizador e a distância entre os sensores e os bocais de pulverização são usados em um algoritmo otimizado para abrir e fechar bicos individuais de acordo com a presença ou ausência de plantas na área visitada pelo pulverizador, dentro da cultura.

Dados obtidos com o uso do LIDAR (*Light Detection and Ranging*) permitem concluir que a densidade por área e altura da planta são parâmetros essenciais de estrutura da cultura no uso para a definição de um método otimizado de pulverização. As diferentes formas, cores

e tamanhos encontrados em culturas arbóreas, mesmo durante o período de crescimento, exigem um ajuste contínuo da dose de produtos químicos aplicada, para otimizar a eficiência de aplicação de nebulizador e para reduzir a contaminação ambiental (SOLANELLES *et al.*, 2002; WALKLATE *et al.*, 2006). Trabalhos que lidam com pulverização eletrônica são abordados em Giles (GILES *et al.*, 1987; 1988). O sistema foi desenvolvido com base em transdutores de ultrassom e foi montado em um pulverizador de pomar, com bico de ar. Os testes realizados pelos autores mostraram que as medidas de distância do pulverizador até a folhagem da árvore (copa) não sofreram variações em função da velocidade de deslocamento do pulverizador. No segundo trabalho, de 1988, os autores desenvolveram técnicas para controlar o fluxo de pulverização em função da presença/ausência de vegetação.

Gil (GIL *et al.*, 2007) utilizou sensores de ultrassom para ajustar, contínua e dinamicamente, as doses de produtos químicos aplicados em videiras durante a fase de crescimento das árvores. O autor usou um pulverizador com múltiplos bicos de pulverização a ar, equipado com três sensores de ultrassom e três eletro-válvulas para alterar dinamicamente e em tempo real, em função da variabilidade de largura da cultura, a taxa de fluxo dos bicos. Uma taxa de aplicação constante foi comparada com uma aplicação em taxa variável usando o princípio do volume de árvore por linha. A taxa de fluxo total pulverizada pelos bocais foi modificada de acordo com as variações de largura da cultura medidos pelos sensores de ultrassom. O autor mostra que os resultados obtidos implicam na redução, em média, de 58% do volume de líquido pulverizado, em comparação com a aplicação à velocidade constante. Uma análise detalhada da economia indica as diferenças entre a parte inferior, do meio e superior da cultura, de acordo com a distribuição de área foliar com a altura das culturas. Não foram detectadas diferenças significativas entre tratamentos em uniformidade de distribuição de líquido e capacidade de alcançar as partes internas da colheita.

Os mesmos autores utilizaram e avaliaram metodologia alternativa que aplicasse uma taxa de volume ideal com base na estrutura da árvore da cultura e volume de linha, em comparação com a tradicional metodologia baseada na quantidade de produto por unidade de área do terreno. Para tal, desenvolveram um sistema eletrônico para determinar a variabilidade da estrutura da cultura em vinhedos e avaliaram a qualidade da aplicação do novo sistema em comparação com metodologias convencionais. O dispositivo eletrônico desenvolvido permite a medição de alterações na estrutura da cultura e modificação do volume total aplicado de acordo com essas mudanças. Um pulverizador a ar foi equipado com seis conjuntos individuais e ajustáveis de bicos (três em cada lado da máquina), Três sensores de ultrassom foram montados em uma haste.

Ainda sobre o protótipo de Gil (GIL *et al.*, 2007), o pulverizador apresentou desempenho baseado na estimativa do volume de copa em todas as seções transversais a cada 10cm e em três diferentes alturas, com taxa apropriada e por fluxo proporcional ao volume medido. O funcionamento é demonstrado na figura 3.9.

Figura 3.9: Princípio de funcionamento do protótipo (GIL *et al.*, 2007).

A distância entre o sensor e a cultura foi medida por cada sensor, obtendo-se a largura das culturas para cada terço da altura total da cultura. Estas medidas foram trabalhadas através de um algoritmo que calculou a taxa de fluxo correspondente para cada conjunto de bicos. Na figura 3.10, é apresentada a distribuição da área foliar em função da altura da planta.

Figura 3.10: Distribuição de área foliar em função da altura da planta (Adaptado de GIL *et al.*, 2007).

Ainda, a distribuição espacial de deposição obtida com a aplicação convencional pela taxa de aplicação variável é apresentada na figura 3.11.

Figura 3.11: Distribuição espacial de deposição obtidas com a aplicação convencional (à esquerda) e com uma taxa de aplicação variável (à direita) (Adaptado de GIL *et al.*, 2007).

Um trabalho que relaciona sensores ópticos variantes do LAI-2000 *canopy analyzer*, foi proposto em Mottus (MOTTUS *et al.*, 2006). Os autores aderiram seu uso para obter resultados semelhantes àqueles obtidos com o uso de sensores de ultrassom para modelar estocasticamente árvores. Copas foram modeladas como elipsóides. Na figura 3.12, é ilustrado o mapeamento tridimensional do referido trabalho.

Figura 3.12: Árvore gerada usando modelo 3D (MOTTUS *et al.*, 2006).

As copas também foram projetadas em 3D para identificar os vários tipos possíveis de coroa, como demonstrado na figura 3.13.

Figura 3.13: Formas axialmente simétricas de copas para diferentes valores de limiar de coroa, contendo 90% de folhagem (Adaptado de MOTTUS *et al.*, 2006).

No trabalho de Solanellesi (SOLANELLESI *et al.*, 2006), os autores desenvolveram um protótipo de um sistema eletrônico baseado em sensores de ultrassom e válvulas solenóides proporcionais para controle de um pulverizador, possibilitando a aplicação de produtos proporcional à largura da copa das árvores de diversas culturas. O ajuste da taxa de fluxo foi baseado na relação entre a largura árvore real medida pelos sensores de ultrassom e a largura máxima da árvore do pomar. O protótipo foi testado em culturas de oliveiras, pereiras e macieiras, para avaliar o desempenho do sistema em geometrias de culturas diferentes. A distribuição de taxas de pulverização foi medida em comparação com as técnicas convencionais. Os resultados mostraram uma economia de 70%, 28% e 39% respectivamente, para oliveiras, pêra e maçãs, em comparação com aplicações convencionais.

A seguir, é demonstrado o procedimento para o cálculo da largura da copa, com aspectos geométricos, na figura 3.14, assim como a amostragem de replicação nos ensaios em campos de oliveiras, na figura 3.15.

Figura 3.14: Cálculo da largura da copa (c) a partir da distância para o exterior da copa (d), medida pelos sensores de ultrassom; distância do sensor em relação ao eixo do pulverizador (e); altura da copa (b); espaçamento entre linhas de árvores (a) (SOLANELLESI *et al.*, 2006).

Figura 3.15: Amostragem de estratégia de replicação nos ensaios em campos de oliveiras (SOLANESSELI *et al.*, 2006).

Foram medidas também a deposição por pulverização sobre a copa das árvores de oliveiras, peras e macieiras, após a aplicação proporcional (valores depositados de pulverização são estimados pela quantidade de líquido por unidade de área foliar).

Em outra aplicação de sensores de ultrassom para pulverização em taxas variáveis, os autores utilizaram os sensores para obter uma estimativa do tamanho do dossel, através da medição da distância para a copa em várias elevações acima do solo. Foram realizados testes em diversas condições climáticas e durante vários meses, na presença de nuvens de poeira e de ventos fortes. Não houve variabilidade nas medidas dos sensores, comprovando a eficácia do método. Além disso, vários sensores-sincronizados foram testados para avaliar sua estabilidade de medição e precisão (devido a possíveis erros de leituras cruzadas) quando montados em um protótipo pulverizador (JEON *et al.*, 2011). Na figura 3.16, é demonstrada a configuração do túnel de vento para testes dos sensores.

Figura 3.16: Configuração do túnel de vento para testes dos sensores (Adaptado de JEON *et al.*, 2011).

Na figura 3.17, a aplicação de pulverização em um campo linear, correspondente a configuração do túnel de vento, é apresentada.

Figura 3.17: Aplicação de pulverização em um campo linear típico (JEON *et al.*, 2011).

Outros trabalhos clássicos e em estado-da-arte sobre a aplicação do uso de sonares para mapeamento de superfícies em cenas agrícolas, é encontrado em Tronco (TRONCO, 2013).

3.4. Considerações finais

Neste capítulo foram descritos os conceitos aplicados em visão computacional, de acordo com suas etapas sequenciais (pré-processamento, técnicas de segmentação, classificação e reconhecimento de padrões).

Também foram revisados textos e publicações sobre as aplicações em estado-da-arte e clássicas de como a agricultura de precisão é implementada pelos parâmetros que a envolve, como as tecnologias empregadas e o modo de gerenciamento. Ainda, trabalhos que lidam com a detecção, separação e quantificação de culturas agrícolas também foram analisadas, destacando os métodos e propostas de cada trabalho, adequando a visão computacional na agricultura e suas ferramentas por obtenção em RGB/NIR/TIR e outros meios ópticos. Por fim, trabalhos clássicos usando sensores de ultrassom foram revisados e comentados.

4. METODOLOGIA PROPOSTA

Neste capítulo são detalhados os materiais e métodos usados para a elaboração de uma arquitetura integrada de visão computacional e fusão de sensores para aquisição de dados sob culturas de interesse em cenas naturais agrícolas, para análise quantitativa e qualitativa do citros e biomassa. Ainda, são descritos os métodos de classificação e reconhecimento de padrões para cada tipo de dado processado, bem como na fusão de dados sensoriais ponderada, para o classificador geral.

O diagrama funcional da metodologia proposta é mostrado na figura 4.1:

Figura 4.1: Diagrama funcional da metodologia proposta.

As seguintes etapas, de acordo com o diagrama funcional da proposta, são relacionadas abaixo:

- a) Aquisição de dados (caracterização e pré-processamento): imagens RGB/HSV (orientação das cenas em paralela/oblíqua - linhas de plantio de pomares, ortogonal - inspeção de frutos), imagens térmicas (orientação ortogonal da copa e detalhes das árvores), matrizes de distâncias (plano cartesiano contendo dados dos detalhes das árvores e o ponto geométrico referencial dos sonares, e orientação ortogonal da copa), índices vegetativos da planta pelo sensor de refletância;
- b) Algoritmos de segmentação: JSEG (baseado em regiões não homogêneas) aplicados nas imagens RGB; *Watershed*, modelo de mistura de *Gaussianas* (*MoG*) e *Expectation Maximization* (EM) aplicadas nas imagens térmicas.
- c) Algoritmos de construção das matrizes de distância dos dados sonares e estimativa dos mapas de profundidade, pela distribuição angular, radial e altura do dossel, e a densidade de espalhamento de frutos;
- d) Algoritmos de estimação de densidade e distribuição dos índices vegetativos da planta (R, Borda Vermelho, NIR, NDVI, NDRE) para a análise qualitativa.
- e) Extração e normalização de características dos segmentos/objetos (comparação de histogramas tridimensionais, fusão de máscaras e PCA), pré-classificação estatística e reconhecimento de padrões dos objetos das cenas normalizadas (Modelos *Bayesianos/Gaussianos*) - regiões classificadas dos mapas de classe, para a detecção dos padrões alvos, análise de elementos geométricos e quantificação de objetos para a inspeção visual das culturas, e elementos que compõem a cena (folhas, ramos e galhos);
- f) Classificação baseada em modelos cognitivos (Lógica *Fuzzy* e RNA) na identificação dos dados qualitativos e quantitativos por fusão de dados (correlação) ponderada, relacionando aspectos geométricos, formas, tamanhos, localização, posição, orientação e estimativas da diagnose dos citros.

As etapas não são processadas em tempo real, uma vez que o objetivo da inter-relação entre a segmentação das cenas, fusão de dados normalizados/classificados e quantidade de informações parametrizadas para o modelo final, compreende períodos de tempo em observação experimental.

No item (a), a configuração dos sensores de ultrassom (matriz de profundidade), refletância, fluxo óptico, e câmeras TIR e CCD-IP/RGB deve prover relação proporcional

quanto a posição e orientação cinemáticas do robô móvel agrícola usado, nas duas laterais, uma vez que a cena de observação deve ser comum a todos os meios de aquisição. O veículo guiado quadriciclo Honda TRX420TM é usado para estes testes, sendo que suas características dinâmicas e cinemáticas são similares e proporcionais às da plataforma veicular agrícola *Agribot*, e ao RAM (robô agrícola móvel) nos testes finais - como referências a aplicação em campo. Por isso, o sistema de aquisição sensorial pode ser adaptado a qualquer veículo agrícola com respeito às características base dos veículos comentados.

No item (b), o processo de segmentação é implementado com algoritmos em C/C++ e customizado a bibliotecas de parâmetros em *OpenCV*, para imagens em RGB/HSV e algoritmos de segmentação *Watershed* e mistura de *Gaussianas* (MATLAB) para imagens térmicas - *dados quantitativos e qualitativos*; no item (c), são implementados algoritmos no MATLAB para a caracterização dos elementos que compõem a formação do dossel, através da distribuição correlacional angular, radial e altura - *dados quantitativos*; no item (d) são aplicados algoritmos e cálculos estatísticos (C/C++/MATLAB) para os índices vegetativos da planta - *dados qualitativos*; no item (e) a extração dos vetores de características, assim como a etapa de normalização são processadas no ambiente MATLAB, com rotinas elaboradas para a comparação de histogramas tridimensionais nos espaços de cores RGB e HSV, fusão de máscaras e por PCA, além da pré-classificação de cada dado por classificadores estatísticos; no item (f) técnicas de classificação e fusão de dados, de forma ponderada, são aplicadas no ambiente MATLAB, relacionando modelos cognitivos combinados, por Lógica *Fuzzy* e RNA.

Ademais, a configuração de hardware dos computadores de uso do NEPAS usados para os testes com tais algoritmos atende a requisitos de processador de quatro e oito núcleos (quadcore/octocore) com frequência de operação entre 2,00GHz e 3,50GHz para sistemas operacionais Windows/Linux de 32/64 bits, memória volátil RAM de 8/16GB, memória não-volátil HDD de 1TB e suporte a interfaces GigaBit Ethernet, USB 3.0 e Firewire para conexões diretas com os periféricos.

Para os quatro sensores envolvidos, as imagens e dados foram obtidos nas plantações de pomares de laranja pertencentes a fazenda Santa Elisa (21°50'03,2"S 47°50'15,6"O), na região de São Carlos/SP. A plantação é dividida em áreas por categorias e variedades da laranja, como *valência*, *pera rio*, *natal*, *shamout*, *lima*, *hamlin*/*westin*, em um total de 749,9has. Dentre cada plantação, o veículo guiado quadriciclo auxilia a locomoção entre as fileiras de cultivo para a aquisição de imagens. Foram feitas seis concentrações de base de dados (divididas em seis semestres - 2013, 2014 e 2015), em mesmo talhão (*valência*), mas

com condições climáticas e períodos temporais diferentes, para obtenção de uma base de dados geral concisa e robusta.

As concentrações de base de dados de imagens são as mesmas usadas para os quatro sensores (câmeras VGA/CMOS, termógrafo, sonares e sensor de refletância), uma vez que para o classificador geral ponderado, a relação entre cada conjunto de características dos dados processados parcialmente pelas pré-classificações, deve se confundir para que a fusão de dados estabeleça critérios aceitáveis no reconhecimento de padrões. A base de dados inicial para a proposta em visão computacional contempla 1270 imagens (dosséis completos, cenas localizadas, linhas de plantio), para a proposta de tratamento de imagens térmicas contempla 700 imagens (cenas localizadas), para a proposta de estimação de volume de copas (mapeamento) contempla 220 imagens/cenas matriciais (dosséis completos), e para a proposta de caracterização da refletância e índices vegetativos das plantas contempla 220 imagens (cenas localizadas). Assim, a base de dados para a proposta de visão computacional e a proposta de mapeamento por sonares, é a mesma (base de dados **A** - macro), e a base de dados para a proposta de termografia óptica e a proposta da caracterização dos índices vegetativos das plantas, é a mesma (base de dados **B** - micro), sendo a base de dados **B** contida na base de dados **A**, pela dependência do tratamento de regiões localizadas em toda a cena do dossel. Na figura 4.2, é apresentado o diagrama esquemático das interdependências entre as bases de dados A e B.

Figura 4.2: Base de dados: ~1270 imagens RAW adquiridas de dosséis completos, cenas localizadas, regiões dentro da cena, e linhas de plantio. A base de dados A corresponde ao conjunto de imagens trabalhadas para o sistema de visão computacional e o mapeamento matricial por sonares. A base de dados B, dependente e contida em A, corresponde ao conjunto de imagens trabalhadas para o tratamento de imagens térmicas e a análise dos índices vegetativos das plantas.

A média para a estimação pretendida dos dados na fusão sensorial para o classificador geral ponderado é dada pelas 220 imagens comuns às quatro bases de dados, e por percentuais entre 10%, 20%, 30%, 40%, 50%, 75% e 100% para que a validação do classificador geral apresente e mantenha regularidade e convergência durante sua aplicação. Em toda a documentação deste trabalho são apresentadas algumas imagens testes, com cenas localizadas destas, para a representação do total da classificação geral ponderada.

4.1. Robôs móveis agrícolas e plataforma experimental por veículo guiado

A aplicação deste projeto é voltada à robótica móvel agrícola, uma vez que as adaptações dos sensores e câmeras são dispostas nas laterais do veículo guiado/autônomo para a locomoção entre as linhas de plantio, durante a aquisição dos dados. Logo, dois robôs móveis de uso do NEPAS/EESC/USP são usados para os testes (RAM e Agribot), além de um quadriciclo Honda TRX420TM, para testes em campo, com uso independente de cada sistema sensorial (os módulos de tração, direção, manobrabilidade e estabilidade simulam os sistemas dos robôs móveis agrícolas).

O quadriciclo Honda TRX420TM simula adequadamente as situações de estabilidade e manobrabilidade em terrenos modificados, irregulares e, às vezes de difícil acesso, entre as linhas de plantio e paralelo a estas. As dimensões do veículo são: 2,055m de comprimento, 1,172m de largura/1,148m de altura - estas medidas proveem a adaptação de dois gabinetes em MDF na frente e atrás para a instalação dos sensores, câmeras, acessórios e computadores, para os testes em campo. O sistema de suspensão é composto por um modelo monoamortecido traseiro, dando estabilidade homogênea a carga que está atrás, e duploamortecido dianteiro, dedicado a manobrabilidade e frenagem, durante o percurso e esterçamentos entre as linhas de plantio. Na figura 4.3, é apresentado o quadriciclo HONDA TRX420TM com suas especificações técnicas.

Figura 4.3: Quadriciclo HONDA TRX420TM - especificações técnicas para a distribuição de massa nos suportes dianteiro e traseiro, onde são instalados os sensores e câmeras; adaptação dos gabinetes MDF nas partes dianteira e traseira. No gabinete traseiro, as quatro divisões e a parte superior são dedicadas a instalação dos sensores, câmeras, computador e acessórios. O gabinete dianteiro é dedicado a instalação de câmeras CCD/CMOS e a câmera térmica.

Denominado robô agrícola móvel (RAM), sendo a segunda versão de um projeto anterior, dado por veículo agrícola autônomo (VAA), desenvolvido em parceria com a Escola de Engenharia de São Carlos e Embrapa Instrumentação Agropecuária, apresentou em sua

versão inicial alguns problemas, como a baixa potência dos motores de tração do sistema de navegação, necessidade de adaptações na estrutura mecânica, e baixa autonomia relacionada ao tipo de baterias utilizadas como forma de alimentação. Assim, a segunda versão obteve aperfeiçoamento da estrutura mecânica, e consequente robustez da plataforma, permitindo a utilização de novos equipamentos e sensores propostos. A inserção de motores de guiagem de maior torque, e dirigibilidade baseada na geometria de *Ackermann*, bem como o novo sistema de controle dos motores, proporcionaram ao sistema de navegação maior confiabilidade e precisão, contribuindo com o deslocamento eficiente do robô durante a aquisição em massa dos dados em campo, mesmo sem um sistema de amortecimento/estabilidade. Tais modificações são resultados de dois projetos de pesquisa: MCT/CNPq 15/2007 – Universal; Embrapa Macroprograma 3 2008-2010 (TABILE, 2012). O referido robô agrícola móvel é mostrado na figura 4.4.

Figura 4.4: Vista isométrica do RAM, e prototipagem real. Nas laterais, os vãos e a superfície superior se adequam as instalações dos sensores, câmeras e computador (TABILE, 2012).

A continuidade dos estudos em robôs agrícolas dados pela Embrapa Instrumentação Agropecuária e pela Escola de Engenharia de São Carlos, resultou em um novo projeto intitulado “Desenvolvimento de uma plataforma robótica modular e multifuncional para aquisição de dados em agricultura de precisão” (FINEP/CT-AGRO - Agricultura de Precisão 01/2008). A proposta deste projeto é caracterizada pela combinação de módulos na plataforma, capaz de se locomover em ambientes típicos da área agrícola, com a finalidade de aquisição de dados e pesquisa de novas tecnologias para o sensoriamento remoto. As principais características desta plataforma são a robustez do sistema de direção e navegação, o sistema de propulsão e manobrabilidade, elevada capacidade operacional e autonomia de trabalho, dedicadas a operações de inspeção nas culturas usuais do Estado de SP, como laranja, milho e cana, inicialmente. A plataforma robótica base apresenta uma característica multifuncional, o que permite o acoplamento de módulos de aquisição de dados em campo

para estudo da variabilidade espacial por meio de sensores e equipamentos portáteis, maximizando as características específicas do meio agrícola para atuação em culturas perenes, semi-perenes e anuais.

A plataforma, denominada *Agribot*, é composta de dois subsistemas principais, a plataforma robótica base e os módulos complementares. A primeira é um subsistema constituído por uma estrutura com sistemas mecânicos e eletrônicos, capaz de se locomover com eficiência em ambientes agrícolas adversos. A estrutura e os componentes mecânicos foram fornecidos pela cooperação com a empresa Máquinas Agrícolas Jacto S/A (TABILE, 2012).

Figura 4.5: Projeto e partes constituintes (à esquerda): 01 – motor diesel e sistema de bombas hidráulicas; 02 – assoalho; 03 – módulo roda traseiro; 04 – chassi secundário; 05 – chassi principal; 06 – sistema de propulsão; 07 – sistema de suspensão; 08 – módulo roda dianteiro; 09 – sistema de esterçamento. À direita, os sistemas de coordenadas inercial e local (TABILE, 2012).

A estrutura da plataforma foi definida em formato retangular, onde o lado de maior comprimento é paralelo às fileiras de cultivo. O sistema de tração foi acomodado de forma a se deslocar no espaço entre fileiras de cultivo. Esta configuração oferece uma grande estabilidade e permite que o sistema de tração dianteiro e traseiro percorra o mesmo percurso, o que diminui a resistência a rolagem, além de prover deslocamentos sobre determinadas culturas, durante a época de plantio, ciclo de crescimento e colheita. A estrutura atende em formato pórtico com 1,80 m de distância entre o solo e a base do chassi. Devido à elevada altura do robô agrícola móvel, a distância entre eixos deve ser proporcionalmente definida, para transpor aclives e declives. Ainda, melhora a manobrabilidade do veículo. Tais características são apresentadas na figura 4.5, e as dimensões da plataforma e testes reais são apresentados na figura 4.6, a seguir.

Para que fosse possível operar em fileiras de cultivo com diferentes dimensões foi escolhido um chassi onde a bitola lateral é ajustada. O valor mínimo que se pode alcançar é de

2,25m e a abertura máxima vai até 2,40m. O sistema foi projetado com a integração de um chassi principal e os módulos, com estabilidade lateral de 33° e frontal de 40°.

Figura 4.6: Dimensões da plataforma (acima); Testes com o sistema de propulsão e direção da plataforma veicular agrícola *Agribot* no laboratório de referência nacional em agricultura de precisão da Embrapa.

4.2. Métodos propostos em visão computacional aplicada a imagens RGB

Os métodos propostos para o sistema de visão computacional são dedicados ao problema de localização e inspeção de culturas agrícolas, e à demarcação de limites entre linhas de plantio (fileiras de cultivo frontal ou diagonal). Nestas duas abordagens são relatadas as seguintes etapas:

- a) Obtenção, caracterização e pré-processamento das imagens para a inspeção de frutos, parâmetros da biomassa nos dosséis, e a delimitação das áreas de plantio de pomares;
- b) Processo de segmentação, extração e normalização de características dos segmentos alvos, classificação estatística por *Bayes* e *Bayes ingênuo*, para a quantificação e inspeção visual das culturas, detecção de folhas, ramos, galhos, e aspectos estruturais de cada copa, validação dos classificadores aplicados;
- c) Pós-processamento das regiões classificadas dos mapas de classe, para a detecção dos padrões alvos, análise de elementos geométricos e quantificação de objetos - modelos parciais de objetos reais.

A arquitetura modular para o sistema de VC foi testada com duas câmeras CCD GigE *Basler piA1600 35gm/gc* e *piA2400 17gm/gc* na obtenção de imagens estáticas e dinâmicas em campo (em RGB) e câmeras IP/RGB *D-Link DCS-5635 N H.264 PTZ*, com ajuste *pan-tilt*, provendo flexibilidade de orientação e posição da captura da cena (copa da árvore), sem a adaptação destas no robô móvel agrícola, apenas no veículo guiado quadriciclo.

A distância das câmeras é determinada no intervalo em que o veículo guiado se locomove entre as fileiras de cultivo, de 0,70m à 1,40m. Para a identificação e inspeção de laranjas, as imagens adquiridas foram estabelecidas para as imagens que lidam com o pomar inteiro, e concentração de folhas, frutos e galhos - o eixo de captura das câmeras está ortogonal às fileiras de cultivo (90°). Outras duas orientações das câmeras com as imagens que atendem a localidades com o corredor central de separação destas linhas e onde circulará o robô móvel - o eixo de captura das câmeras está paralelo as fileiras de cultivo (0°), parte do corredor e plantação à direita, parte do corredor e plantação à esquerda, e concentração do solo para ambos os lados de plantação - o eixo de captura das câmeras está diagonal às fileiras de cultivo ($\sim 45^\circ$).

As características de obtenção das imagens são: resolução espacial de 3664×2062 *pixels* com resolução cromática de *24-bits*, armazenadas em arquivo do tipo JPEG/JPG adquiridas no espaço de cores RGB. A base de dados para as cenas de pomares, atende a um conjunto de 1270 imagens dividido em dois conjuntos: pomares completos individuais e em conjunto (linhas de plantio), e áreas locais de incidência de frutos.

O primeiro grupo de imagens para as cenas de pomares completos individuais e em conjuntos apresenta o plantio de cada árvore a 2m (perspectiva lateral) e das linhas de plantio (perspectiva frontal), com a representação baixa de *pixels* para frutos, sendo estes parcialmente ocultos por folhas e galhos, submetidos a condições de variação da intensidade luminosa, e dependendo da textura dos frutos, a reflexão da luz natural incide gerando focos brancos e aberrações cromáticas entre os *pixels* da região de contorno das laranjas. Outro problema na caracterização de cenas *outdoor* é a reflexão da luz devido a regiões que denotam sujeiras ou suspeitas de doença encontradas nos frutos. Como a abordagem lida com a segmentação também dos componentes da biomassa, deve-se considerar o crescimento desordenado dos galhos de cada pomar para delimitar sua área (irregular) de plantio, o que influencia a iluminação da copa para regiões com muita ou pouca sombra, e muita ou pouca incidência de iluminação. O solo nestas imagens (não relevante para o processo de segmentação), é coberto em sua maioria por vegetação rasteira e muitas folhas e frutos caídos, e nas áreas descobertas apresenta uma mistura de cores entre alaranjado, vermelho e

marrom, com incidências diferentes de luz, e ao fundo, o céu é dependente das condições climáticas de cada momento de captura. Nas figuras 4.7 e 4.8, são apresentados os grupos.

Figura 4.7: Cenas naturais com orientação paralela e diagonal às linhas de plantio.

O segundo grupo de imagens direcionado as cenas de incidência local de frutos mostra o plantio de árvores individuais, desde a concepção do caule até a copa, pela representação em perspectiva frontal, a distâncias de 4m a 2m, e detalhes de partes das árvores. Apresenta baixa representatividade de *pixels* para os frutos, cobertos parcialmente pelas folhas e galhos, que compõem as cenas também, de copas esparsas, e crescimento irregular dos galhos, folhas e ramos. As cenas naturais correspondentes à laranja são analisadas quanto a sua distribuição não linear em cada árvore, tendo como parâmetros de identificação as informações topológicas do fruto, como o centróide de área, região de contorno (estimativa do volume), a variação de cor apresentada durante a conservação do fruto, e deformidades de textura ocasionadas por aberrações cromáticas e intensidade de luz incidente.

Figura 4.8: Cenas naturais com orientação ortogonal às linhas de plantio (dosséis completos).

O diagrama funcional da proposta de visão computacional é mostrada na figura 4.9.

Figura 4.9: Diagrama funcional para a proposta de visão computacional na inspeção de culturas agrícolas.

A aquisição de imagens em RGB passa pelo pré-processamento na transformação para o espaço de cores HSV. Na etapa de segmentação, baseada em regiões não homogêneas, a aplicação dá-se tanto para RGB, quanto para HSV, com o objetivo de comparar os resultados de agrupamento de regiões nos dois casos.

Na etapa de classificação dos segmentos, o prévio conhecimento das características deve ser conhecido. As características extraídas podem ser classificadas por critério imposto (situações em que os segmentos são membros de determinada classe), por exemplos (situações em que não se conhece a relação dos segmentos com uma classe específica) ou critério aberto (situações em busca de agrupamentos desconhecidos).

A metodologia adotada atende à seguinte sequência: aquisição das imagens; pré-processamento para redução de resolução espacial e limiarização na transformação do espaço de cores RGB para HSV; segmentação das imagens; cálculo das características dos segmentos para a extração (análise das componentes principais dos vetores de características); classificação dos segmentos; geração dos mapas de classe para os padrões segmentados em ambos os espaços de cores; geração dos modelos reais para o primeiro caso.

4.2.1. Etapa de pré-processamento e representação gráfica

A precisão na etapa de segmentação de objetos é relativamente alta, considerando a resolução espacial das imagens originais (3664 x 2062), como também é o tempo de processamento e o custo computacional. Como esta análise é dispendiosa, cada imagem teve sua resolução espacial reduzida em uma proporção de 4x1 para linhas e 6x1 para colunas (852 x 480 *pixels*). Nesta nova dimensão, os *pixels* que representam as culturas foram mantidos em maior densidade de regiões, favorecendo estimativas mais convergentes de sua localização, compondo uma base de dados homogênea e correspondência com as mesmas características de resolução, sem comprometer os detalhes dos objetos de interesse. As imagens com as novas dimensões foram pré-processadas no espaço de cores RGB, em fator de escala para valores individuais na intersecção de cada *pixel* em todas as linhas e colunas, pelo método de interpolação bilinear-convolução (BITTENCOURT, 1998), o qual assinala ao valor do pixel da imagem de saída, uma média ponderada dos *pixels* em vizinhança 4x4 mais próxima.

Assim, as imagens de cenas naturais em RGB, sujeitas à variação de luminosidade, reflexão e oclusão, são transformadas para o espaço de cores HSV, uma vez que os canais S e V (saturação/valor) separam as informações cromáticas relevantes à discriminação dos padrões de segmentos desejados destes ruídos. O cálculo da transformação é dado pela equação 10.

$$\begin{aligned}
H &= \arctan\left(\frac{\sqrt{3}(G-B)}{(R-G)(R-B)}\right); \\
S &= 1 - \frac{\min(R,G,B)}{I}; \\
V &= \max(R,G,B);
\end{aligned} \tag{10}$$

Os resultados das imagens pré-processadas com a redução da resolução espacial e no espaço de cores HSV, para as cenas de incidência local de frutos que mostra o plantio de árvores individuais, desde a concepção do caule até a copa, pela representação em perspectiva frontal, e com a área das fileiras de cultivo em paralelo, pela representação em perspectiva lateral, são aplicáveis no espaço de cores HSV.

A conversão do espaço de cores RGB para HSV é fundamental para o processo de segmentação, uma vez que os canais de saturação, valor e matiz convergem para combinações predominantemente homogêneas dos objetos pretendidos, presentes na cena, e que sofrem influência direta de ruídos em ambientes externos. Outros espaços de cores, como CMYK, YIQ e YCbCr são relevantes como pré-processamento para imagens que apresentam altas frequências de luminâncias em escalas de cinza e componentes que guardam informações sobre a crominância dos objetos presentes nas imagens, bastante usados em imagens microscópicas, todavia não tendo a mesma eficiência de discriminação de regiões como o HSV para imagens de cenas naturais em ambientes externos.

4.2.2. Etapa de segmentação em cenas naturais

Na etapa de segmentação de cenas naturais, a distinção de cores entre as variedades das culturas e os demais entes naturais como folhas, galhos e ramos, além da textura, devem ser priorizados, uma vez que é possível encontrar regiões de cor não homogênea. Imagens coloridas com regiões homogêneas são segmentadas através de um algoritmo de agrupamentos que os separa no espaço de cores pré-processado, isto é, classes de diferentes magnitudes na distribuição espectral, com intensidade específica da radiação eletromagnética visível em vários comprimentos de onda. As imagens analisadas, tanto para cenas de árvores, detalhes de partes da copa, quanto para as fileiras paralelas de cultivo apresentam componentes físicos naturais, mas com relativa desambiguidade de agrupamentos de cores em cada situação. Nestes casos, tratam de regiões com separação regular de *pixels* em regiões consideradas homogêneas, isto é, são características da cena perspectiva frontal, as linhas de plantio, denotando variação de tonalidades à cor verde e amarela, e os espaços entre as linhas, denotando a variação de cor e textura do solo.

Segmentação não-supervisionada baseada em regiões não-homogêneas (JSEG)

Como descrito e detalhado em Lulio (LULIO, 2011a), a segmentação de imagens texturizadas deve considerar o agrupamento espacial de *pixels* em crescimento de regiões não-homogêneas, tornando-as segmentos homogêneos, através da relação distinta entre as escalas no espaço de cores tratado. Quando aplicado em cenas naturais, a técnica é não-supervisionada para regiões texturizadas e coloridas, a qual é apropriada na verificação de homogeneidade em padrões de regiões com estas características, e computacionalmente mais viável e eficaz que modelos de estimação de parâmetros. São consideradas então, para análise da imagem adquirida, as regiões homogêneas de cor e textura, a quantização das informações de cores, e a distinção de cores entre regiões vizinhas.

Desenvolvido e detalhado em diversos trabalhos (DENG *et al.*, 1999a; DENG & MANJUNATH, 1999c; DENG & MANJUNATH, 2001), o algoritmo JSEG, que objetiva o agrupamento de classes denominado como região J , apresenta duas etapas de processamento: quantização do espaço de cores (*peer-group filtering* - PGF) (DENG *et al.*, 1999b) – processo de redução de números de cores distintas na imagem, e crescimento/agrupamento de regiões com cores semelhantes. Abaixo, é mostrado na figura 4.10 o funcionamento do algoritmo JSEG.

Figura 4.10: Funcionamento do algoritmo de segmentação não-supervisionado JSEG (Adaptado de LULIO, 2011a).

Inicialmente, na primeira etapa, é efetuado com mínima degradação da homogeneidade de cores, definindo regiões em cores reduzidas, cada qual associada a uma classe. Os *pixels* na imagem original são substituídos por tais classes, formando um mapa de classes em composição de texturas (J -imagem), associada pela janela de cor quantizada,

contendo *pixels* com valores positivos e negativos (valores J) ao contorno e a texturização de suas fronteiras.

Na segunda etapa, o crescimento e agrupamento de regiões com cores semelhantes são associados na identificação da similaridade de cores e na distribuição espacial destas, delimitando as regiões de contorno da homogeneidade encontrada.

O algoritmo é dividido e organizado em três etapas de desenvolvimento, sendo a validação computacional, a técnica de distribuição espacial e a determinação e crescimento do vale das regiões J . Todas estão detalhadas em Lulio (LULIO, 2011a) e são aplicadas neste trabalho.

a) Validação computacional

Para se calcular o valor J (equação 11) de uma região candidata a ser heterogênea, Z é definido como um conjunto de pontos da imagem quantizada, logo, $z = (x,y)$ com $z \in Z$, e considerando m a média para todos os elementos Z . C é o número de classes obtido na quantização, assim, Z é classificada em classes C , e Z_i são os elementos de Z pertencentes à classe i , onde $i = 1, \dots, C$, e m_i são as médias dos elementos em Z_i . Portanto, o valor J é dado por:

$$J = \frac{S_B}{S_W} = \frac{(S_T - S_W)}{S_W} \quad (11)$$

onde:

$$\begin{aligned} S_T &= \sum_{z \in Z} \|z - m\|^2 \\ S_W &= \sum_{i=1}^C \sum_{z \in Z_i} \|z - m_i\|^2 \end{aligned} \quad (12)$$

Na equação 12, o parâmetro S_T representa a soma dos pontos quantizados na imagem, dentro de uma média em todos os elementos Z . A razão entre S_B e S_W denota as medidas de distância entre os mapas de classe, para distribuições não-lineares, o que significa que valores de J altos indicam um aumento na distância entre as classes e os pontos de cada, considerando imagens com regiões de cores homogêneas. Cada região segmentada pode ser recalculada com ajustes de parâmetros para a média $\bar{J}$ (equação 13). J_k representa o valor J calculado sobre a região k ; M_k é o número de pontos na região k , N é o número total de pontos no mapa de classes, com todas as regiões na somatória destes mapas.

$$\bar{J} = \frac{1}{N} \sum_k M_k J_k \quad (13)$$

b) *Etapa de distribuição espacial*

A etapa de distribuição espacial se inicia pela caracterização do *Mapa de classe inicial*, correspondente a imagem original de entrada, sem a discriminação de regiões homogêneas. Em seguida, para a etapa *Calcular valores J locais*, em cada região é atribuído um rótulo dimensional com a intensidade de cor no contorno destas regiões, verificando se incidência de *pixels* nas bordas é constante para aquela região. Na etapa *Crescimento de regiões*, ocorrem os processos de determinação e crescimento do vale. As regiões homogêneas são separadas através da quantização de cores (etapa *Regiões segmentadas*) e segmentadas até atingir a escala pretendida como limiar de segmentação homogênea (etapa condicional $Escala < Limiar$). A segmentação é finalizada com a distribuição espacial em regiões homogêneas. O fluxograma é mostrado na figura 4.11.

Figura 4.11: Fluxograma da etapa de distribuição espacial (Adaptado de LULIO, 2011 a).

A distribuição espacial é aplicada para o resto da imagem, com o maior limiar de escala de resolução até a especificação de um dado limiar menor, uma vez que a minimização

global de $\bar{J}$ não é prática, e a região J é representada por uma imagem em escala de níveis de cinza, cujos *pixels* são os valores J calculados sobre janelas locais centralizadas nestes *pixels*.

c) *Crescimento do vale de regiões J*

Regiões J são determinadas, quando regiões de dimensões pequenas são definidas como os padrões de crescimento iniciais. Estas regiões têm os menores valores J (vales), e seu cálculo é atribuído ao desvio padrão (σ_J) e a média de valores J (μ_J) locais na região, considerando que pontos de vale candidatos a *pixels* com valores J locais, são determinados por $T_J > J$.

No primeiro ciclo, uma segmentação inicial da imagem é obtida, após o crescimento de regiões, com áreas super-segmentadas, combinadas em suas similaridades de cor. As cores quantizadas representam os feixes dos histogramas de cor, e suas medidas de distância são calculadas pela extração de regiões (distância euclidiana entre duas regiões vizinhas). Os pares de regiões com distâncias mínimas são combinados juntos e armazenadas em uma base de dados e atualizadas quando se calcular a estimativa dos vetores de características e a região correspondente.

4.2.3. Etapa de extração e normalização dos vetores de características

Os segmentos das imagens RGB/HSV na etapa de segmentação são usados como características a cada classificador, e as regiões não pretendidas são desconsideradas, uma vez que a identificação se dá pelos elementos que compõem a cena, e estes são representados por descritores que formam as componentes de interesse ao vetor de características dos segmentos ou regiões.

Os parâmetros adotados das cores e texturas em cada espaço de cores são usados na descrição ao vetor de características, através da relação tridimensional dos canais de cores HSV e RGB para a formação de histogramas das imagens segmentadas, como descritor primário. A aplicação dos histogramas é feita automaticamente por funções ordenadas no MATLAB, formando uma matriz de histogramas normalizados, que atribuem a projeção dos *pixels* da cor de interesse em cada gráfico. São usadas todas as dimensões de cada canal dos espaços de cores HSV e RGB, agregando o valor de (256 x 3 canais = 768) à quantidade de parâmetros analisados.

As características topológicas da cena são consideradas também através da região de contorno delimitada pela matriz de pontos z , assim denominada como a interpretação dos

valores de pico em relação ao plano cartesiano da imagem bidimensional segmentado. O número de linhas de contorno e os valores são atribuídos de acordo com a representação de mínimos e máximos da cena, provendo informações estimadas de profundidade. A variação dos eixos x e y , são dadas como base pela resolução espacial da imagem segmentada em $[1:n]$ e $[1:m]$, respectivamente, onde $[m,n]$ é igual ao tamanho em módulo dos valores da matriz Z .

O parâmetro c é o valor de incidência local de mínimos e máximos, e na equação 14 deve ser atribuído de forma arbitrária, inicialmente, para a verificação de cada borda no quadrado da grade da imagem, então um contorno é desenhado através das bordas e realizada uma interpolação linear.

$$t = \frac{(c-z_0)}{(z_1-z_0)} \quad (14)$$

onde z_0 é o valor de z em um ponto de borda e z_1 é o valor de z em outro ponto. A indexação da linha de contorno é dada pela interpolação entre x e y , com $i = 1$.

$$c_x(i) = x_0 + t(x_1 - x_0) \quad (15)$$

$$c_y(i) = y_0 + t(y_1 - y_0) \quad (16)$$

A matriz c mostra as informações das linhas de contorno, em que na primeira coluna são denominados os valores (*valor1*, ...) e os vértices da linha de contorno ($v_{(x,y)}$). As demais colunas apresentam os dados em pares de coordenadas dos pontos de contorno (x_v , y_v).

$$c = \begin{bmatrix} \text{valor1} & x_v(1) & x_v(2) \\ v_{(x,y)} & y_v(1) & y_v(2) \dots \end{bmatrix} \quad (17)$$

Com os vetores de características primários formados, as porcentagens relativas das distâncias euclidianas entre os centróides de cada classe pretendida favorecem uma maior estimativa da dispersão dos vetores aos segmentos, o que aumenta significativamente a relação de atributos para a normalização e, conseqüentemente, o custo computacional. A parametrização das características neste caso é necessária, através da redução da dimensionalidade pela Análise das Componentes Principais (PCA), uma vez que as classes de entrada crescem proporcionalmente ao aumento das dimensões (maldição da dimensionalidade). Os vetores mais distantes das classes são eliminados e os conjuntos de treinamento extraídos dos vetores, evitando assim dados redundantes e dispersão de classes.

4.2.4. Etapa de reconhecimento de padrões por modelos *Bayesianos*

O classificador baseado no teorema de *Bayes* é um modelo estatístico clássico aplicado em inferências de dados relacionais que necessitam de alto grau de processamento na discriminação de características. A probabilidade do evento B pertencer à classe A , em que $P(B)$ é definida como a constante normalizadora é dada pela equação 18, de acordo com seu postulado (BAYES & PRICE, 1763; GNEDENKO, 1982).

$$P(A | B) = \frac{P(B | A)P(A)}{P(B)} \quad (18)$$

Conhecendo a probabilidade *a priori* de A ocorrer, e do evento B ocorrer para a classe A , a razão entre elas denota as probabilidades em todas as classes pretendidas, e que resultar na maior probabilidade é escolhida. Na probabilidade condicional abaixo (equação 19), o problema na resolução consiste na determinação de k (classe de B) e do conhecimento prévio de C_i (evento relacionado à classe i), $P(C_i)$ (probabilidade da classe C_i ocorrer), $P(B/C_i)$ (probabilidade de B ocorrer para a classe C_i) e k (número total de classes), para que o problema seja reformulado para as demais classes.

$$P(A | B) = \frac{P(A \cap B)}{P(A)} \quad (19)$$

A resolução da PDFc depende do número de componentes da mistura (k) e seus parâmetros (q), que são encontrados através de *maximum-likelihood* (ML) ou através da estimativa *Bayesiana* (PAALANEN *et al.*, 2006). O algoritmo descrito na figura 4.12, é customizado na adequação dos parâmetros de entrada e padrões de classificação estimados.

$$k = \arg \max_i (P(B | C_i)P(C_i)), i = 1, 2, \dots, K \quad (20)$$

Nos casos em que a probabilidade *a priori* é usada para a estimação de conjuntos de treinamento, o teorema de *Bayes* é reformulado para a função densidade de probabilidade (PDF – *probability density function*), em que $p(y/C_i)$ (equação 21) é a PDF condicional da classe i , y é um valor escalar ou vetorial, cujas variáveis aleatórias são denominadas de multivariadas com PDF conjunta (PDFc).

$$P(C_i | y) = \frac{p(y | C_i)P(C_i)}{\sum_{j=1}^K p(y | C_j)P(C_j)} \quad (21)$$

Entradas: $k_{\min}$, $k_{\max}$, ϵ , parâmetros iniciais $\hat{\theta}(0) = \{\hat{\theta}_1, \dots, \hat{\theta}_{k_{\max}}, \hat{\alpha}_1, \dots, \hat{\alpha}_{k_{\max}}\}$

Saídas: Modelo de mistura em $\hat{\theta}_{\text{melhor}}$

$T \leftarrow 0$, $k_{nz} \leftarrow k_{\max}$, $\zeta_{\min} \leftarrow +\infty$

$u_m^{(i)} \leftarrow (p(y(i) | \hat{\theta}_m))$, para $m = 1, \dots, k_{\max}$ e $i = 1, \dots, n$

enquanto $k_{nz} \geq k_{\min}$ **faça**

repita

$t \leftarrow t + 1$

para $m = 1, \dots, k_{\max}$ **faça**

$w_m^{(i)} \leftarrow \hat{\alpha}_m u_m^{(i)} \left(\sum_{j=1}^{k_{\max}} \hat{\alpha}_j u_j^{(i)} \right)^{-1}$, para $i = 1, \dots, n$

$\hat{\alpha}_m \leftarrow \max \left\{ 0, \left(\sum_{i=1}^n w_m^{(i)} \right) - \frac{N}{2} \right\} \left(\sum_{j=1}^k \max \left\{ 0, \left(\sum_{i=1}^n w_j^{(i)} \right) - \frac{N}{2} \right\} \right)^{-1}$

$\{\hat{\alpha}_1, \dots, \hat{\alpha}_{k_{\max}}\} \leftarrow \{\hat{\alpha}_1, \dots, \hat{\alpha}_{k_{\max}}\} \left(\sum_{m=1}^{k_{\max}} \hat{\alpha}_m \right)^{-1}$

se $\hat{\alpha}_m > 0$ **então**

$\hat{\theta}_m \leftarrow \arg \max \log p(Y, W | \theta)$

$u_m^{(i)} \leftarrow p(y^{(i)} | \hat{\theta}_m)$, para $i = 1, \dots, n$

senão

$k_{nz} \leftarrow k_{nz} - 1$

fim se

fim para

$\hat{\theta}(t) \leftarrow \{\hat{\theta}_1, \dots, \hat{\theta}_{k_{\max}}, \hat{\alpha}_1, \dots, \hat{\alpha}_{k_{\max}}\}$,

$\zeta[\hat{\theta}(t), Y] \leftarrow \frac{N}{2} \sum_{m: \hat{\alpha}_m > 0} \log \frac{n \hat{\alpha}_m}{12} + \frac{k_{nz}}{2} \log \frac{n}{12} + \frac{k_{nz} N + k_{nz}}{2} - \sum_{i=1}^n \log \sum_{m=1}^k \hat{\alpha}_m u_m^{(i)}$

até $\zeta[\hat{\theta}(t-1), Y] - \zeta[\hat{\theta}(t), Y] < \epsilon$ **ou** $\zeta[\hat{\theta}(t-1), Y]$

se $\zeta[\hat{\theta}(t), Y] \leq \zeta_{\min}$ **então**

$\zeta_{\min} \leftarrow \zeta[\hat{\theta}(t), Y]$

$\hat{\theta}_{\text{melhor}} \leftarrow \hat{\theta}(t)$

fim se

$m^* \leftarrow \arg \min_m \{\hat{\alpha}_m > 0\}, \hat{\alpha}_{m^*} \leftarrow 0, k_{nz} \leftarrow k_{nz} - 1$

fim enquanto

Figura 4.12: Algoritmo customizado à classificação pelo teorema de *Bayes*.

No classificador *Bayes Ingênuo* (*naive Bayes*), as características são independentes, o que caracteriza uma suposição improvável/incerta. Logo, para cada classe ou conjunto de classes, a PDF é supostamente denotada pela equação 22, em que $p(y/C_i)$ é a função de

densidade marginal condicional, estimada como a PDFc, n é o número de características. Como no teorema de *Bayes*, o treinamento e a validação são realizados da mesma forma, mas a PDF admite várias características, já que a PDFc é relacionada com apenas uma dimensão, sendo possível a integração de funções de densidade de probabilidade contínuas e discretas.

$$p(y | C_i) = \prod_{j=1}^n p(y_j | C_i) \quad (22)$$

4.3. Métodos propostos em visão computacional aplicada a imagens térmicas

Objetos que apresentam temperatura acima do zero absoluto (-273°C), emitem radiação infravermelha na sua superfície, a qual é naturalmente emitida pelos corpos, em função de sua temperatura, mas o que é medido em equipamentos termográficos é a radiação térmica, e não a temperatura, em função da lei de Stefan-Boltzmann sobre emissividade. Os equipamentos termográficos captam a radiação emitida e a radiação refletida pelos corpos, sendo a proporção entre as duas, denominada como **emissividade**. Em termografia, quanto maior a emissividade de um corpo, maior a temperatura deste corpo em função de sua área. Logo, a emissividade igual a proporção da constante de Stefan-Boltzmann (σ) pela temperatura em *Kelvin* à quarta potência (T^4), como apresentado na equação 23.

$$\varepsilon = \sigma T^4 \quad (23)$$

E a potência irradiada (equação 24) termicamente por um corpo é dada pela proporção entre a emissividade (ε), constante de Stefan-Boltzmann (σ), área do corpo e a temperatura absoluta do corpo (T):

$$P = \varepsilon \sigma A T^4 \quad (24)$$

Ainda, a emissividade é diretamente proporcional a **absorvidade**, uma vez que corpos que absorvem muita radiação, também emitem muita radiação, por consequência da **transmissividade**, que é a capacidade do corpo manter o percentual de absorção e emissão de forma proporcional. Assim:

$$a + r + t = 1 \quad (25)$$

onde a : absorvidade; r : refletividade; t : transmissividade.

Corpos muito reflexivos têm baixa emissividade, isto é, emissividade e refletividade são inversamente proporcionais.

As imagens térmicas (termogramas ou termovisíveis) são adquiridas por uma câmera termográfica que é sensível à radiação infravermelha. O sensor térmico de captura da radiação infravermelha varia de acordo com a câmera. Na etapa de aquisição de imagens térmicas, usou-se neste trabalho, o termovisor óptico FLIR E50, como mostrado na figura 4.13 (FLIR SYSTEMS, 2011). O sensor presente nesta câmera tem sensibilidade térmica de $0,05^{\circ}\text{C}$ em um intervalo de temperatura entre -20°C à 650°C (-4°F à 1202°F), gerando imagens em resolução espacial de 240×180 . Ainda, a câmera apresenta correção de janela IR (*infrared*) para compensação da perda de transmissividade; identificador de pontos médios quentes ou frios; correção mediana de temperatura refletida, temperatura ambiente, umidade relativa, distância e transmissividade IR; frequência de imagem em 60Hz; distância mínima de foco em 0,4m manual; campo de visão em $25^{\circ} \times 19^{\circ}$; fusão térmica.

Figura 4.13: Termovisor FLIR E50 (FLIR SYSTEMS, 2011).

Esta câmera converte o valor adquirido na temperatura da superfície do objeto analisado, tomando como base três componentes de radiação: a radiação emitida pelo objeto de interesse, a radiação refletida pelos objetos adjacentes e a radiação emitida pelo meio. Para a estimação da influência da radiação do meio em que estão sendo obtidas as imagens, é necessário configurar alguns parâmetros diretamente: a emissividade do objeto de interesse (laranjas - 0,95), a temperatura ambiente, a umidade relativa do ar e a distância entre a câmera e o objeto. Os algoritmos no microprocessador interno da câmera, através da relação entre emissividade e temperatura absoluta, convertem a irradiação térmica medida em uma matriz de pontos representativos da temperatura em pontos bidimensionais da cena adquirida.

A matriz de pontos formada pode representar níveis de cinza dentro do intervalo de temperaturas da cena ou em pseudocores (de acordo com a paleta de cores), e cada tom representa um intervalo dessas temperaturas. A variação de cores da paleta (limites mínimo e máximo da temperatura) é mostrada na lateral direita da imagem.

A imagem termográfica é definida como uma função tridimensional $M(i,j,t)$, onde i e j são a posição de cada elemento na matriz (linha e coluna, respectivamente) e t a temperatura naquela posição (i,j) . Esta matriz de temperatura pode ser manipulada pela aplicação proprietária *FLIR tools*, em que operações de transformação da imagem em pseudocores são realizadas, sendo cada ponto (i,j,t) indexado como um ponteiro ao mapa de cores. As paletas usuais são compostas por cento e vinte (120) cores discretas, que podem se adequar dada a graduação estimada.

Na leitura termográfica, deve-se considerar ao menos um *pixel* coberto pela radiação térmica que vem do objeto, denominada como resolução de medição do campo de visão (MFOV - *measurement field of view*), sendo três vezes o valor da resolução geométrica da imagem (IFOV - *instantaneous field of view*). IFOV é medido em *miliradianos*, e define o menor objeto que o termovisor pode distinguir dada uma distância pré-determinada, que depende do detector e da óptica. Ainda, são relacionados outros fatores na termografia, como VFOV (*vertical field of view*), HFOV (*horizontal field of view*) e a distância real até o alvo.

Obtenção das imagens de testes

As capturas de imagens foram feitas manualmente, no termovisor E50, dado o processo de obtenção por gatilho do próprio equipamento, ainda com o veículo de testes percorrendo as linhas de plantio, com os demais sensores acoplados.

As regiões registradas são partes das cenas naturais dos dosséis completos, da base de dados **A**, trabalhadas anteriormente na proposta de visão computacional, construindo assim, uma base de dados dedicada a identificação de frutos com deformações e irregularidades (base de dados **B**). Assim, as cenas naturais dos dosséis completos são referências para os registros das regiões separadas, como denota a figura 4.14, na identificação de irregularidades das superfícies dos frutos, apresentadas nas figuras 4.15, 4.16, 4.17, 4.18, 4.19, 4.20, 4.21, 4.22, 4.23 e 4.24. Assim, para cada cena natural de dossel, tem-se o registro de duas regiões localizadas, adquiridas em períodos de tempo diferentes.

Figura 4.14: Cenas naturais de dosséis completos e respectivas regiões localizadas para análise e processamento termográfico. As regiões alocadas na esquerda denotam os registros realizados na primeira aquisição (a_n), as regiões alocadas na direita denotam os registros realizados na segunda aquisição (b_n) (15 dias após).

A primeira aquisição foi no período vespertino (14h00 - 16h00), com muitas nuvens e baixa visibilidade (intensidade luminosa baixa), a temperatura ambiente estava em $\sim 20^{\circ}\text{C}$ e a umidade relativa do ar em 50%. A variedade da laranja nesta área é a *valência*, no período de pré-colheita (outubro e dezembro) - com 350 imagens registradas (base de dados A).

Figura 4.15: Cena natural e representação termográfica 01.

Figura 4.16: Cena natural e representação termográfica 02.

Figura 4.17: Cena natural e representação termográfica 03.

Figura 4.18: Cena natural e representação termográfica 04.

Figura 4.19: Cena natural e representação termográfica 05.

A segunda aquisição, também em período vespertino (16h00 - 17h00), 15 dias após a primeira, com poucas nuvens e alta visibilidade (intensidade luminosa alta, aumentando índice de reflexão das folhas e frutos), a temperatura ambiente estava em $\sim 35^{\circ}\text{C}$ e a umidade relativa do ar em 50%. A mesma variedade da laranja nesta área se manteve (*valência*), no período de pré-colheita (outubro e dezembro) - com 350 imagens registradas (base de dados A).

Figura 4.20: Cena natural e representação termográfica 06.

Figura 4.21: Cena natural e representação termográfica 07.

Figura 4.22: Cena natural e representação termográfica 08.

Figura 4.23: Cena natural e representação termográfica 09.

Figura 4.24: Cena natural e representação termográfica 10.

4.3.1. Etapa de processamento de imagens térmicas por *Watershed*

O processo de segmentação combinada entre crescimento de regiões com divisor de águas (*Watershed*) calcula o gradiente de contorno para todos os *pixels* da imagem, como uma superfície topográfica (GONZAGA, 2010). As regiões mais baixas correspondem as de menor gradiente e as mais altas as de maior gradiente. Os segmentos da operação são formados por regiões que, partindo de um mínimo local, formam uma bacia hidrográfica (divisor de águas). O agrupamento dos *pixels* é formado por mecanismos de busca de valores próximos a partir de cada mínimo local.

Tal técnica de segmentação é relevante na aplicação de imagens térmicas, para a caracterização de deformidades envoltas ao fruto, para a diagnoses de seu estado de maturação, discriminando duas das principais doenças em citros: *cancro cítrico* e *leprose*. A primeira é caracterizada por uma lesão sobressalente (de dentro para fora), na superfície do fruto, e a segunda é caracterizada por uma lesão pendente (de fora pra dentro), na superfície do fruto (FUNDECITRUS, 2015).

O algoritmo implementado no MATLAB, associa o mapeamento do gradiente de contorno nos segmentos previamente processados pela paleta de cores da imagem térmica. Das cento e vinte amostras de imagens nos dois períodos observados, o exemplo na seção 5 (Resultados experimentais) é apresentado e as demais organizadas no **APÊNDICE B**. A sequência de etapas do algoritmo é implementada da seguinte forma:

Passo 01: Pré-processamento na imagem em níveis de cinza, por gradiente de contorno e segmentação por Sobel. Os elementos mais escuros são os alvos para a segmentação, dentro da cena e especificamente sobre os frutos;

Passo 02: Processamento de marcadores em primeiro plano (foreground), por reconstrução morfológica, e erosão seguida de dilatação;

Passo 03: Processamento de marcadores em segundo plano (background), com separação dos pixels que não fazem parte de nenhum objeto;

Passo 04: Calibração do gradiente de contorno para a superposição da imagem com as localizações dos marcadores dos elementos de primeiro e segundo planos;

Passo 05: Processamento da transformada de watershed, modificando a função de segmentação para as regiões de borda entre os segmentos contornados.

4.3.2. Etapa de classificação estatística por Misturas de Gaussianas (MoG)

Misturas de *Gaussianas* são formas de modelagens de séries temporais, que consistem no agrupamento de densidades de probabilidades *Gaussianas* com características individuais. A PDF de $f(x)$ é modelada como a soma ponderada de um certo número c de densidade de probabilidade, com $c \ll n$. O modelo univariado é dado por (DAY, 1969; DEMPSTER *et al.*, 1977), apresentado na equação 26:

$$f(x) = \sum_{i=1}^c \rho_i \delta(x; \vartheta_i) \quad (26)$$

onde ρ_i representa o peso ou o coeficiente da mistura para o i -ésimo termo e $\delta(x; \vartheta_i)$ denota a densidade de probabilidade, com os parâmetros μ e σ^2 representados pelo vetor ϑ_i e x considerado como o ponto da variável que se estima a densidade. Para a mistura de *Gaussiana* multivariada a equação é formulada para:

$$\widehat{f}_{FM}(x) = \sum_{i=1}^c \widehat{\rho}_i \phi(x; \widehat{\mu}_i, \widehat{\Sigma}_i) \quad (27)$$

onde x é um vetor n -dimensional dos valores da série que se estima a densidade; $\widehat{\mu}_i$ é um vetor n -dimensional de médias e o somatório $\widehat{\Sigma}_i$ é a matriz de covariância $n \times m$ de x .

Os parâmetros da PDF, como número de *Gaussianas* (c), fator de ponderação (ρ_i), média (μ) e matriz de covariância são estimados pelo algoritmo *Expectation-Maximization*.

O algoritmo *Expectation-Maximization* de geração de estimativas de máxima verossimilhança, na mistura de *Gaussiana* é aplicado como processo iterativo para encontrar aproximações de equações não lineares a partir de um valor inicial dado, até a convergência a um valor final.

A convergência é encontrada com valores ótimos até o valor de máximo global. Como o algoritmo EM lida com agrupamentos, este requer a realização de ajustes às equações de estimativa de parâmetros, de modo que ω_i é a probabilidade de pertinência da instância i ao *cluster* A. Logo, a média e o desvio padrão para o *cluster* A são:

$$\mu_A = \frac{\omega_1 x_1 + \omega_2 x_2 + \dots + \omega_n x_n}{\omega_1 + \omega_2 + \dots + \omega_n} \quad (28)$$

$$\sigma_A^2 = \frac{\omega_1(x_1-\mu)^2 + \omega_2(x_2-\mu)^2 + \dots + \omega_n(x_n-\mu)^2}{\omega_1 + \omega_2 + \dots + \omega_n} \quad (29)$$

O algoritmo EM é aplicado na seguinte sequência:

1. *Parâmetros inseridos arbitrariamente na média e desvio padrão.*

2. *Enquanto convergência aumentar:*

2a. *Calcular probabilidade dos clusters para cada elemento de dados.*

2b. *Estimar novos valores dos seis parâmetros, baseados nos resultados estatísticos anteriores.*

Nas imagens térmicas a aplicação de um modelo de mistura de *Gaussiana* por EM e misturas adaptativas podem auxiliar a classificação dos segmentos regionais apenas das irregularidades de interesse nos frutos e da biomassa, como critérios para a extração dos objetos secundários dos modelos reais, servindo de parâmetros para análise biológica *a posteriori*, em laboratório, do que pode ser caracterizado como *cancro cítrico* e *leprose*.

4.4. Métodos propostos para a estimação do volume de dosséis por sonares

Os métodos propostos para a estimação do volume de copas de laranjeiras fazem uso de sensores ultrassônicos *MaxBotix*, modelos *LV-MaxSonar EZ1* e *XL-MaxSonar WRC*, ilustrados na figura 4.25.

Figura 4.25: Sensores ultrassônicos LV-MaxSonar EZ1 e XL-MaxSonar WRC.

Ambos operam os cálculos de distância de forma automática, com a emissão do sinal e captação do eco feita pelo próprio sensor. Através de pulsos PWM, os sensores geram saídas serial e analógica, com variação do nível de tensão proporcional à distância do objeto.

O sensor ultrassônico tem intervalo de operação de zero a até 6,45m de distância, porém, a faixa de percepção de objetos entre 0 a 15cm são medidos como 15cm, sendo este valor o limiar mínimo de detecção. As medidas são realizadas em uma frequência de 42KHz. Os sensores LV-MaxSonar EZ1 e XL-MaxSonar WRC possuem dois modos de operação no acionamento da leitura, sendo um de forma manual, onde toda medida efetuada exige

comando do usuário, e o outro de forma automática, onde o próprio sonar realiza continuamente medidas da distância do objeto.

A alimentação varia entre 2,5V a 5,5V, e possui ganho variável ajustável, para controle preciso do feixe de ultrassom, consumo de 2mA e medição a cada 50ms (em 20 Hz). Por ser de baixo consumo é ideal para operar com baterias de pequeno porte.

Os pinos de ambos os sonares são: GND, +5V, TX, RX, AN, PW e BW, sendo que no XL-MaxSonar WRC, o pino PW atua com fator de escala em 58 μ s, mais rápido que o primeiro. Ainda, o sonar XL abrange uma área maior de captação de eco, ideal para estimar objetos menores.

Os resultados obtidos pela aquisição dos sonares mostram-se passíveis de caracterização e correlação com os dados pretendidos para as matrizes de distância. O sensor ultrassom *XL-Maxsonar WRC* foi montado na parte lateral de um veículo guiado para testes em campo (quadriciclo *Honda TRX420TM*), simulando a operação do robô móvel agrícola *Agribot*. Tal dispositivo foi acoplado a um arranjo de dois servomotores *Hobbico CS-60*, que operam em posições discriminadas em passos de 1:25, nos eixos x e y , possibilitando a varredura num plano cartesiano para a construção de uma matriz de distâncias, de tamanho 25 x 25, como ilustrado na figura 4.26.

Figura 4.26: Montagem do sensor de ultrassom (*XL-Maxsonar*) no suporte em MDF atrás do quadriciclo, nas duas laterais, na imagem à esquerda; Detalhe do mecanismo (*pan-tilt*) dos servomotores, na imagem à direita, e atrás o ultrassom da lateral direita do veículo está montado com o segundo mecanismo dos servomotores.

Para cada varredura, o veículo guiado permanece em repouso, até dirigir a próxima árvore alvo, como apresentado na figura 4.27. O tempo de processamento das distâncias somado a construção das matrizes e posicionamento angular é considerável para aplicações em tempo real, e deve ser monitorado para a correção de erros. Os resultados também fazem parte da contribuição relacionada em Tronco (TRONCO, 2013).

Figura 4.27: Conjunto sensor de ultrassom/mecanismo servomotor atuando na varredura cartesiana para a leitura das distâncias - na parte debaixo do suporte MDF, observa-se a placa de acionamento dos servomotores e as conexões de dados até o computador.

A montagem implementada permite que o sensor seja posicionado em um número discreto de posições (625 posições, resultantes de 25 posições possíveis no sentido das linhas e 25 posições possíveis no sentido das colunas). Este posicionamento proporciona ao sensor um movimento de varredura nos eixos x e y (figura 4.69), permitindo o levantamento das distâncias de uma região que se situa imediatamente à direita do quadriciclo. Uma vez o quadriciclo posicionado, procede-se à movimentação controlada dos dois servomotores responsáveis pela movimentação do sensor. Os motores são acionados de tal forma que o sensor aponte para a posição superior esquerda, a qual é sua posição inicial. Uma leitura de distância é realizada e então o servomotor que controla o movimento referente às linhas é acionado, realizando uma rotação controlada de $3,6^\circ$ por passo (cada passo do servomotor corresponde a $3,6^\circ$, sendo 25 posições em linha e 25 posições em coluna, para 90° de intervalo em todo o mapeamento). Outra leitura de distância é então realizada.

Este procedimento é realizado 25 vezes, quando então o sensor alcança sua posição mais à direita. Nesta situação, o servomotor responsável pelo movimento referente às colunas é acionado, realizando uma rotação de $3,6^\circ$. Isto leva o sensor para a posição referente à segunda linha e o procedimento descrito anteriormente é realizado, de tal forma que o sensor vai sendo posicionado, sequencialmente, em posições que representam 25 colunas. Após completar toda a varredura, 625 medidas foram realizadas e armazenadas em uma matriz 25×25 , como mostrado na figura 4.28.

Figura 4.28: Procedimento de varredura matricial da árvore pelo sonar, com o mecanismo dos servomotores planares (x e y).

As cenas naturais mapeadas para as matrizes de distância, fazem parte da base de dados **A**, contendo dosséis completos, para que o mapa de profundidade de cada árvore corresponda com as mesmas características analisadas anteriormente, na proposta de visão computacional, dada a análise de localização e quantificação dos frutos, sendo a temática deste trabalho, na confusão de características pelo classificador geral ponderado.

Nesta proposta são consideradas aproximadamente 220 imagens de dosséis completos, adquiridos na fazenda Santa Elisa, na região de São Carlos/SP. Todas foram mapeadas e processadas, de acordo com os métodos a seguir descritos, para uma estimativa de mapeamento das linhas de plantio em percentuais de 10%, 50% e 100%.

A seguir são apresentadas cinco tomadas de leituras em pontos sequenciais de pomares de laranjeiras em um talhão. Cada imagem apresenta características distintas da disposição espacial da cultura em questão (frutos/laranjas), a disparidade entre os elementos constituintes da cena, como as folhas, ramos e galhos. Outro fator a ser considerado é a correspondência da distância euclidiana entre cada medida lida, com o ponto geométrico do sonar, diferente da medida correspondente até o veículo, paralelo às linhas de plantio.

A base matricial que agrega as 625 medidas de distância, pode ser reajustada em passos menores de deslocamento angular de cada servomotor, para um maior detalhamento da formação das copas e dosséis, todavia, como a recepção do sinal refletido tende a apresentar ruídos e falsos positivos, pela abertura angular de emissão da onda sonora, 25 medidas para linhas e 25 medidas para colunas são consideradas ideais pelas médias obtidas empiricamente, considerando a distância efetiva do sonar para com cada árvore.

Na aquisição das imagens, o robô agrícola ou o veículo guiado durante a locomoção nas fileiras de cultivo, deve fornecer informações sobre a posição, orientação e altura, por um dispositivo GPS (figura 4.29), no momento em que cada cena é registrada, para seu georeferenciamento com o sistema de coordenadas do ambiente na descrição de localização do objeto real. Tais dispositivos calculam a posição de objetos em coordenadas locais (x, y, z), com os dados de latitude, longitude e altura, que são convertidos para graus decimais, sendo possível a determinação da distância (D) entre dois pontos (equações 30 e 31).

$$G_d = \text{graus} + \frac{\text{min}}{60} + \frac{\text{seg}}{3600} \quad (30)$$

$$D = \sqrt{(F_{lat}(\varphi_1 - \varphi_2))^2 + (F_{lon}(\lambda_1 \lambda_2))^2} \quad (31)$$

Figura 4.29: Módulo GPS NBoard M3 - composto por uma IMU, sendo um magnetômetro para medir o fluxo magnético como compasso/bússola (3 eixos), um acelerômetro para medir a aceleração linear (3 eixos) e um giroscópio para medir a variação angular (3 eixos).

árvore 01- GPS: 21°50'02.8"S 47°50'23.6"O

Matriz de distâncias gerada

116.05	140.09	116.05	69.63	92.84	84.40	71.74	61.19	92.84	42.20	84.40	82.29	116.05	54.86	46.42	71.74	42.20	71.74	124.49	69.63	92.84	61.19	92.84	42.20	84.40
113.94	150.64	113.94	71.74	92.84	92.84	63.30	109.72	44.31	44.31	40.09	50.64	113.94	56.97	80.18	88.62	94.95	78.07	73.85	71.74	61.19	109.72	44.31	44.31	40.09
148.53	118.16	111.83	75.96	67.52	92.84	44.31	50.64	50.64	46.42	35.87	50.64	94.95	59.08	78.07	118.16	78.07	80.18	40.09	63.30	109.72	50.64	50.64	46.42	35.87
137.98	120.27	107.61	73.85	82.29	80.18	46.42	118.16	50.64	48.53	35.87	54.86	94.95	137.98	120.27	61.19	105.50	65.41	80.18	71.74	44.31	50.64	50.64	46.42	35.87
118.16	84.40	132.93	82.29	84.40	78.07	61.19	92.84	61.19	50.64	59.08	90.73	94.95	92.84	122.38	67.52	101.28	63.30	84.40	67.52	46.42	118.16	50.64	48.53	59.08
56.97	108.62	126.60	84.40	80.18	94.95	71.74	92.84	82.29	52.75	46.42	94.95	116.05	56.97	105.50	65.41	99.17	82.29	65.41	69.63	61.19	92.84	61.19	50.64	46.42
94.95	100.73	130.82	92.84	80.18	94.95	65.41	90.73	82.29	54.86	46.42	71.74	42.20	71.74	124.49	69.63	92.84	84.40	67.52	61.19	78.07	99.17	50.64	88.62	84.40
54.86	102.20	128.71	90.73	78.07	99.17	50.64	88.62	84.40	56.97	80.18	88.62	94.95	78.07	73.85	71.74	61.19	92.84	69.63	61.19	88.62	94.95	52.75	61.19	103.39
116.05	140.09	116.05	80.18	88.62	94.95	52.75	61.19	103.39	59.08	78.07	118.16	78.07	80.18	40.09	63.30	109.72	44.31	69.63	50.64	118.16	78.07	52.75	61.19	103.39
113.94	150.64	113.94	78.07	118.16	78.07	52.75	61.19	103.39	61.19	63.30	103.39	67.52	80.18	71.74	44.31	50.64	50.64	75.96	54.86	103.39	67.52	63.30	52.75	90.73
94.95	148.53	118.16	63.30	103.39	67.52	63.30	52.75	90.73	63.30	61.19	105.50	65.41	80.18	71.74	46.42	118.16	50.64	61.19	59.08	105.50	65.41	71.74	52.75	97.06
94.95	137.98	120.27	61.19	105.50	65.41	71.74	52.75	97.06	65.41	67.52	101.28	63.30	84.40	67.52	61.19	92.84	61.19	59.08	71.74	61.19	84.40	65.41	73.85	67.52
130.82	92.84	80.18	94.95	61.19	84.40	65.41	73.85	67.52	67.52	65.41	99.17	82.29	65.41	69.63	71.74	92.84	82.29	61.19	84.40	52.75	84.40	69.63	73.85	52.75
128.71	90.73	78.07	99.17	52.75	84.40	69.63	73.85	52.75	69.63	69.63	92.84	84.40	67.52	61.19	65.41	90.73	82.29	52.75	84.40	78.07	73.85	71.74	61.19	92.84
116.05	80.18	88.62	94.95	78.07	73.85	71.74	61.19	92.84	42.20	71.74	92.84	92.84	69.63	61.19	50.64	88.62	128.71	90.73	78.07	80.18	40.09	63.30	109.72	44.31
113.94	78.07	118.16	78.07	80.18	40.09	63.30	109.72	44.31	44.31	75.96	67.52	92.84	69.63	50.64	52.75	61.19	116.05	80.18	88.62	71.74	71.74	44.31	50.64	50.64
61.19	92.84	61.19	59.08	71.74	71.74	44.31	50.64	50.64	46.42	73.85	82.29	80.18	75.96	54.86	52.75	61.19	113.94	78.07	118.16	84.40	71.74	46.42	118.16	50.64
71.74	92.84	82.29	61.19	84.40	71.74	46.42	118.16	50.64	48.53	82.29	84.40	78.07	61.19	59.08	63.30	52.75	118.16	63.30	103.39	67.52	63.30	52.75	48.53	35.87
65.41	90.73	82.29	52.75	84.40	67.52	61.19	92.84	61.19	50.64	84.40	80.18	94.95	59.08	71.74	71.74	52.75	120.27	61.19	105.50	65.41	71.74	52.75	50.64	59.08
50.64	88.62	84.40	78.07	73.85	69.63	71.74	92.84	82.29	52.75	92.84	80.18	94.95	61.19	84.40	65.41	73.85	80.18	94.95	61.19	84.40	65.41	73.85	52.75	46.42
52.75	61.19	103.39	80.18	40.09	61.19	65.41	90.73	82.29	54.86	90.73	78.07	99.17	52.75	84.40	69.63	73.85	78.07	99.17	52.75	84.40	69.63	73.85	54.86	46.42
52.75	61.19	103.39	80.18	71.74	61.19	50.64	88.62	84.40	56.97	80.18	88.62	94.95	78.07	73.85	71.74	61.19	88.62	94.95	78.07	73.85	71.74	61.19	56.97	42.20
63.30	52.75	90.73	80.18	71.74	50.64	52.75	61.19	103.39	59.08	78.07	118.16	78.07	80.18	40.09	63.30	109.72	118.16	78.07	80.18	40.09	63.30	109.72	59.08	90.73
71.74	52.75	97.06	84.40	67.52	54.86	52.75	61.19	103.39	61.19	63.30	103.39	67.52	80.18	71.74	44.31	50.64	61.19	59.08	71.74	71.74	44.31	50.64	61.19	90.73
132.93	82.29	84.40	78.07	61.19	59.08	63.30	52.75	90.73	63.30	61.19	105.50	65.41	80.18	71.74	46.42	118.16	82.29	61.19	84.40	71.74	46.42	118.16	63.30	103.39

Figura 4.30: Correspondência da cena da árvore 01 com a matriz de distâncias gerada.

árvore 02- GPS: 21°50'02.5"S 47°50'23.4"O

Matriz de distâncias gerada

113.94	78.07	118.16	78.07	118.16	118.16	118.16	109.72	44.31	44.31	75.96	67.52	92.84	78.07	118.16	78.07	52.75	61.19	103.39	61.19	103.39	103.39	118.16	108.62	126.60
61.19	92.84	61.19	59.08	103.39	103.39	103.39	50.64	50.64	46.42	73.85	82.29	80.18	63.30	103.39	67.52	63.30	52.75	90.73	63.30	105.50	105.50	103.39	100.73	130.82
71.74	92.84	82.29	61.19	118.16	50.64	48.53	118.16	50.64	48.53	82.29	84.40	78.07	61.19	105.50	65.41	71.74	52.75	97.06	65.41	67.52	61.19	105.50	102.20	128.71
65.41	90.73	82.29	52.75	92.84	61.19	50.64	92.84	61.19	50.64	84.40	80.18	94.95	61.19	84.40	71.74	46.42	118.16	50.64	67.52	65.41	61.19	105.50	108.62	126.60
50.64	88.62	84.40	78.07	118.16	50.64	48.53	92.84	82.29	52.75	92.84	80.18	94.95	67.52	84.40	67.52	61.19	92.84	61.19	54.86	103.39	67.52	101.28	44.31	50.64
56.97	108.62	126.60	84.40	80.18	94.95	71.74	92.84	82.29	52.75	46.42	94.95	116.05	65.41	73.85	69.63	71.74	92.84	82.29	59.08	105.50	65.41	99.17	46.42	118.16
94.95	100.73	130.82	92.84	80.18	94.95	65.41	90.73	82.29	54.86	46.42	71.74	42.20	71.74	80.18	94.95	71.74	92.84	82.29	61.19	78.07	99.17	42.20	71.74	124.49
54.86	102.20	128.71	90.73	78.07	99.17	50.64	88.62	84.40	56.97	80.18	88.62	94.95	78.07	80.18	94.95	65.41	90.73	82.29	61.19	88.62	94.95	94.95	78.07	118.16
44.31	50.64	50.64	46.42	73.85	82.29	80.18	63.30	103.39	67.52	78.07	118.16	78.07	80.18	78.07	99.17	50.64	88.62	84.40	50.64	118.16	78.07	78.07	80.18	103.39
46.42	118.16	50.64	48.53	82.29	84.40	78.07	61.19	105.50	65.41	63.30	103.39	67.52	80.18	88.62	94.95	52.75	61.19	103.39	54.86	103.39	67.52	67.52	80.18	105.50
61.19	92.84	61.19	50.64	84.40	80.18	94.95	61.19	84.40	71.74	61.19	105.50	65.41	80.18	118.16	78.07	52.75	61.19	103.39	59.08	105.50	65.41	65.41	80.18	101.28
71.74	92.84	82.29	52.75	92.84	80.18	94.95	67.52	84.40	67.52	67.52	101.28	63.30	84.40	103.39	67.52	63.30	52.75	90.73	71.74	61.19	84.40	63.30	84.40	118.16
71.74	92.84	82.29	52.75	46.42	94.95	116.05	65.41	73.85	69.63	65.41	99.17	82.29	65.41	105.50	65.41	71.74	52.75	97.06	84.40	52.75	84.40	82.29	65.41	103.39
65.41	90.73	82.29	54.86	46.42	71.74	42.20	71.74	80.18	94.95	103.39	67.52	63.30	52.75	105.50	84.40	65.41	73.85	67.52	84.40	78.07	73.85	63.30	52.75	90.73
50.64	88.62	84.40	56.97	80.18	88.62	94.95	78.07	80.18	94.95	105.50	65.41	71.74	52.75	101.28	44.31	50.64	50.64	75.96	78.07	80.18	40.09	71.74	52.75	97.06
52.75	61.19	103.39	59.08	78.07	118.16	78.07	80.18	78.07	99.17	61.19	84.40	65.41	73.85	99.17	46.42	118.16	50.64	61.19	88.62	71.74	71.74	65.41	73.85	67.52
52.75	61.19	103.39	61.19	63.30	103.39	67.52	80.18	88.62	94.95	52.75	84.40	69.63	73.85	67.52	61.19	92.84	61.19	59.08	118.16	84.40	71.74	69.63	73.85	52.75
63.30	52.75	90.73	63.30	61.19	105.50	65.41	80.18	118.16	78.07	78.07	73.85	71.74	65.41	84.40	71.74	46.42	118.16	50.64	61.19	59.08	105.50	65.41	80.18	71.74
71.74	52.75	97.06	65.41	67.52	101.28	63.30	84.40	103.39	67.52	80.18	40.09	63.30	63.30	84.40	67.52	61.19	92.84	61.19	59.08	71.74	61.19	63.30	84.40	67.52
65.41	73.85	67.52	67.52	65.41	99.17	82.29	65.41	105.50	65.41	71.74	71.74	44.31	82.29	73.85	69.63	71.74	92.84	82.29	61.19	84.40	52.75	82.29	65.41	69.63
44.31	50.64	50.64	46.42	73.85	82.29	80.18	63.30	103.39	67.52	84.40	71.74	46.42	63.30	52.75	90.73	63.30	90.73	82.29	52.75	84.40	78.07	63.30	52.75	90.73
46.42	118.16	50.64	48.53	82.29	84.40	78.07	61.19	105.50	65.41	67.52	63.30	52.75	71.74	52.75	97.06	61.19	88.62	128.71	90.73	78.07	80.18	71.74	52.75	97.06
113.94	78.07	118.16	84.40	71.74	71.74	52.75	120.27	61.19	105.50	65.41	71.74	52.75	65.41	80.18	71.74	46.42	118.16	50.64	61.19	59.08	105.50	65.41	80.18	71.74
118.16	63.30	103.39	67.52	63.30	54.86	52.75	61.19	103.39	61.19	63.30	103.39	67.52	63.30	84.40	67.52	61.19	92.84	61.19	59.08	71.74	61.19	63.30	84.40	67.52
52.75	90.73	63.30	61.19	105.50	59.08	63.30	52.75	90.73	63.30	61.19	105.50	65.41	80.18	71.74	46.42	118.16	82.29	61.19	84.40	71.74	46.42	65.41	80.18	71.74

Figura 4.31: Correspondência da cena da árvore 02 com a matriz de distâncias gerada.

árvore 03- GPS: 21°50'02.1"S 47°50'23.2"O

Matriz de distâncias gerada

65.41	80.18	71.74	46.42	59.08	78.07	118.16	78.07	80.18	40.09	63.30	82.29	61.19	61.19	103.39	71.74	42.20	71.74	124.49	69.63	50.64	61.19	88.62	84.40	56.97
63.30	84.40	67.52	61.19	137.98	120.27	61.19	105.50	65.41	80.18	71.74	82.29	52.75	52.75	90.73	88.62	94.95	78.07	73.85	71.74	61.19	59.08	61.19	103.39	59.08
82.29	65.41	69.63	71.74	92.84	122.38	67.52	101.28	63.30	84.40	67.52	128.71	90.73	52.75	97.06	118.16	78.07	80.18	40.09	63.30	82.29	61.19	61.19	103.39	61.19
84.40	67.52	61.19	44.31	56.97	105.50	65.41	99.17	82.29	65.41	69.63	84.40	65.41	73.85	67.52	61.19	105.50	65.41	80.18	71.74	82.29	52.75	52.75	90.73	63.30
92.84	69.63	61.19	46.42	118.16	50.64	61.19	59.08	61.19	50.64	59.08	90.73	94.95	92.84	122.38	67.52	101.28	63.30	84.40	67.52	128.71	90.73	52.75	97.06	65.41
92.84	69.63	50.64	61.19	92.84	61.19	59.08	71.74	82.29	52.75	46.42	94.95	116.05	56.97	105.50	65.41	99.17	82.29	65.41	69.63	84.40	65.41	73.85	67.52	67.52
80.18	75.96	54.86	71.74	92.84	82.29	61.19	84.40	82.29	54.86	46.42	71.74	42.20	71.74	124.49	69.63	92.84	84.40	67.52	61.19	84.40	69.63	73.85	52.75	69.63
65.41	80.18	71.74	65.41	90.73	82.29	52.75	84.40	84.40	56.97	80.18	88.62	94.95	78.07	73.85	71.74	61.19	92.84	69.63	61.19	92.84	71.74	61.19	92.84	42.20
63.30	84.40	67.52	50.64	88.62	128.71	90.73	78.07	99.17	82.29	56.97	118.16	78.07	80.18	40.09	63.30	109.72	44.31	69.63	50.64	56.97	63.30	109.72	44.31	44.31
82.29	65.41	69.63	52.75	61.19	116.05	80.18	88.62	92.84	84.40	71.74	103.39	67.52	80.18	71.74	44.31	50.64	50.64	75.96	54.86	71.74	44.31	50.64	50.64	46.42
84.40	67.52	61.19	52.75	61.19	113.94	78.07	118.16	61.19	92.84	78.07	105.50	65.41	80.18	71.74	46.42	118.16	50.64	61.19	59.08	78.07	46.42	118.16	50.64	48.53
92.84	69.63	61.19	63.30	52.75	118.16	63.30	103.39	109.72	44.31	80.18	101.28	63.30	84.40	67.52	61.19	92.84	61.19	59.08	71.74	80.18	61.19	92.84	61.19	50.64
130.82	92.84	80.18	71.74	52.75	120.27	61.19	105.50	50.64	50.64	80.18	99.17	82.29	65.41	69.63	71.74	92.84	82.29	61.19	84.40	92.84	71.74	92.84	82.29	52.75
128.71	90.73	78.07	65.41	73.85	80.18	94.95	61.19	118.16	50.64	80.18	92.84	84.40	67.52	61.19	65.41	90.73	82.29	52.75	84.40	50.64	61.19	88.62	84.40	56.97
61.19	50.64	59.08	69.63	73.85	78.07	99.17	52.75	92.84	61.19	84.40	92.84	92.84	69.63	61.19	50.64	88.62	128.71	90.73	78.07	71.74	61.19	92.84	71.74	61.19
82.29	52.75	46.42	71.74	61.19	88.62	94.95	78.07	92.84	82.29	65.41	67.52	92.84	69.63	50.64	52.75	61.19	116.05	80.18	88.62	94.95	92.84	122.38	67.52	101.28
82.29	54.86	46.42	63.30	109.72	118.16	78.07	80.18	90.73	82.29	67.52	82.29	80.18	75.96	54.86	52.75	61.19	113.94	78.07	118.16	116.05	56.97	105.50	65.41	99.17
84.40	56.97	80.18	44.31	50.64	61.19	59.08	71.74	88.62	128.71	69.63	84.40	78.07	61.19	59.08	63.30	52.75	118.16	63.30	103.39	42.20	71.74	124.49	69.63	92.84
103.39	59.08	71.74	42.20	71.74	124.49	69.63	92.84	84.40	67.52	61.19	84.40	94.95	59.08	71.74	71.74	52.75	120.27	61.19	105.50	94.95	78.07	73.85	71.74	61.19
61.19	50.64	88.62	94.95	78.07	73.85	71.74	61.19	92.84	69.63	61.19	92.84	94.95	61.19	84.40	65.41	73.85	80.18	94.95	61.19	78.07	80.18	40.09	63.30	109.72
82.29	52.75	118.16	78.07	80.18	40.09	63.30	109.72	44.31	69.63	50.64	56.97	99.17	52.75	84.40	69.63	73.85	78.07	99.17	52.75	67.52	80.18	71.74	44.31	50.64
82.29	54.86	103.39	67.52	80.18	71.74	44.31	50.64	50.64	75.96	54.86	71.74	94.95	78.07	73.85	71.74	61.19	88.62	94.95	78.07	65.41	80.18	71.74	46.42	118.16
84.40	56.97	105.50	65.41	80.18	71.74	46.42	118.16	50.64	61.19	59.08	78.07	78.07	80.18	40.09	63.30	109.72	118.16	78.07	80.18	63.30	84.40	67.52	61.19	92.84
103.39	59.08	101.28	63.30	84.40	67.52	61.19	92.84	61.19	59.08	71.74	80.18	67.52	80.18	71.74	44.31	50.64	61.19	59.08	71.74	82.29	65.41	69.63	71.74	92.84
61.19	50.64	99.17	82.29	65.41	69.63	71.74	92.84	82.29	61.19	84.40	92.84	65.41	80.18	71.74	46.42	118.16	82.29	61.19	84.40	71.74	61.19	92.84	71.74	61.19

Figura 4.32: Correspondência da cena da árvore 03 com a matriz de distâncias gerada.

árvore 04- GPS: 21°50'01.7"S 47°50'22.9"O

Matriz de distâncias gerada

124.49	69.63	92.84	61.19	92.84	42.20	84.40	61.19	92.84	92.84	84.40	67.52	61.19	92.84	46.42	71.74	42.20	71.74	124.49	69.63	92.84	94.95	78.07	73.85	71.74
73.85	71.74	61.19	109.72	44.31	44.31	40.09	109.72	44.31	92.84	92.84	69.63	61.19	92.84	80.18	88.62	94.95	78.07	73.85	71.74	61.19	78.07	80.18	40.09	63.30
40.09	63.30	109.72	50.64	50.64	46.42	35.87	50.64	50.64	67.52	92.84	69.63	50.64	67.52	78.07	118.16	78.07	80.18	40.09	63.30	109.72	67.52	80.18	71.74	44.31
80.18	71.74	44.31	50.64	50.64	46.42	35.87	118.16	50.64	82.29	80.18	75.96	54.86	82.29	120.27	61.19	105.50	65.41	80.18	71.74	44.31	65.41	80.18	71.74	46.42
84.40	67.52	46.42	118.16	50.64	48.53	59.08	92.84	61.19	84.40	78.07	61.19	59.08	84.40	122.38	67.52	101.28	63.30	50.64	46.42	35.87	50.64	50.64	67.52	61.19
78.07	73.85	71.74	61.19	78.07	94.95	71.74	92.84	82.29	92.84	84.40	67.52	61.19	92.84	105.50	65.41	99.17	82.29	50.64	46.42	35.87	118.16	50.64	69.63	71.74
80.18	40.09	63.30	109.72	80.18	94.95	65.41	90.73	82.29	92.84	92.84	69.63	61.19	92.84	124.49	69.63	92.84	84.40	50.64	48.53	59.08	92.84	50.64	61.19	65.41
65.41	80.18	71.74	44.31	65.41	99.17	50.64	88.62	84.40	56.97	80.18	88.62	94.95	78.07	73.85	71.74	61.19	92.84	78.07	94.95	71.74	92.84	78.07	61.19	50.64
63.30	84.40	67.52	46.42	63.30	94.95	52.75	61.19	103.39	59.08	78.07	118.16	78.07	80.18	40.09	63.30	109.72	44.31	80.18	94.95	65.41	90.73	80.18	50.64	52.75
82.29	65.41	69.63	61.19	82.29	78.07	61.19	105.50	65.41	80.18	71.74	61.19	105.50	65.41	71.74	44.31	50.64	50.64	65.41	99.17	50.64	88.62	65.41	54.86	52.75
84.40	67.52	61.19	78.07	84.40	67.52	67.52	101.28	63.30	50.64	46.42	67.52	101.28	63.30	82.29	92.84	84.40	71.74	63.30	94.95	52.75	61.19	63.30	73.85	71.74
92.84	69.63	61.19	88.62	92.84	65.41	65.41	99.17	82.29	50.64	46.42	65.41	99.17	82.29	82.29	92.84	92.84	63.30	82.29	78.07	52.75	61.19	82.29	40.09	63.30
44.31	69.63	50.64	118.16	44.31	84.40	69.63	92.84	84.40	50.64	48.53	69.63	92.84	84.40	84.40	56.97	80.18	71.74	84.40	67.52	63.30	52.75	84.40	71.74	44.31
50.64	75.96	54.86	103.39	50.64	84.40	71.74	61.19	92.84	78.07	94.95	71.74	61.19	92.84	48.53	59.08	50.64	48.53	92.84	65.41	71.74	52.75	92.84	71.74	46.42
50.64	61.19	59.08	105.50	50.64	73.85	63.30	109.72	44.31	80.18	94.95	63.30	109.72	44.31	94.95	71.74	78.07	94.95	50.64	46.42	35.87	50.64	50.64	67.52	61.19
61.19	59.08	71.74	61.19	61.19	40.09	44.31	50.64	50.64	65.41	99.17	44.31	50.64	50.64	94.95	65.41	80.18	94.95	50.64	46.42	35.87	118.16	50.64	69.63	71.74
82.29	61.19	84.40	52.75	82.29	71.74	92.84	84.40	71.74	63.30	94.95	92.84	84.40	71.74	99.17	50.64	65.41	99.17	50.64	48.53	59.08	92.84	50.64	67.52	65.41
82.29	52.75	84.40	78.07	82.29	71.74	92.84	92.84	63.30	82.29	78.07	92.84	92.84	63.30	94.95	52.75	63.30	94.95	78.07	94.95	71.74	92.84	78.07	69.63	69.63
78.07	73.85	71.74	61.19	78.07	67.52	56.97	80.18	71.74	84.40	67.52	56.97	80.18	71.74	78.07	52.75	82.29	78.07	61.19	105.50	65.41	61.19	92.84	42.20	71.74
88.62	94.95	78.07	73.85	71.74	61.19	88.62	92.84	82.29	52.75	92.84	80.18	94.95	84.40	67.52	63.30	84.40	67.52	94.95	61.19	84.40	109.72	44.31	44.31	75.96
118.16	78.07	80.18	40.09	63.30	109.72	118.16	90.73	82.29	54.86	90.73	78.07	99.17	52.75	84.40	69.63	73.85	78.07	99.17	52.75	84.40	52.75	90.73	63.30	61.19
103.39	67.52	80.18	71.74	44.31	50.64	61.19	88.62	84.40	56.97	80.18	88.62	94.95	78.07	73.85	71.74	61.19	88.62	94.95	78.07	73.85	52.75	97.06	65.41	67.52
105.50	65.41	80.18	71.74	46.42	118.16	82.29	61.19	103.39	59.08	78.07	118.16	78.07	80.18	40.09	63.30	109.72	118.16	78.07	80.18	40.09	73.85	67.52	67.52	65.41
88.62	94.95	78.07	73.85	71.74	61.19	88.62	61.19	103.39	61.19	63.30	103.39	67.52	80.18	71.74	44.31	50.64	61.19	59.08	71.74	71.74	73.85	52.75	69.63	69.63
118.16	78.07	80.18	40.09	63.30	109.72	118.16	52.75	90.73	63.30	61.19	105.50	65.41	80.18	71.74	46.42	118.16	82.29	61.19	84.40	71.74	61.19	92.84	42.20	71.74

Figura 4.33: Correspondência da cena da árvore 04 com a matriz de distâncias gerada.

árvore 05- GPS: 21°50'01.5"S 47°50'22.7"O

Matriz de distâncias gerada

92.84	42.20	84.40	82.29	116.05	54.86	46.42	71.74	42.20	42.20	84.40	82.29	116.05	54.86	46.42	71.74	42.20	71.74	124.49	35.87	50.64	94.95	61.19	103.39	59.08
44.31	44.31	40.09	50.64	113.94	56.97	80.18	88.62	94.95	44.31	40.09	50.64	113.94	56.97	80.18	88.62	94.95	78.07	73.85	35.87	54.86	94.95	61.19	103.39	61.19
50.64	46.42	35.87	50.64	94.95	59.08	78.07	118.16	78.07	46.42	35.87	50.64	94.95	59.08	78.07	118.16	78.07	80.18	40.09	59.08	90.73	94.95	52.75	90.73	63.30
50.64	48.53	35.87	54.86	94.95	137.98	120.27	61.19	105.50	48.53	35.87	54.86	94.95	137.98	120.27	61.19	105.50	65.41	80.18	46.42	94.95	116.05	52.75	97.06	65.41
118.16	84.40	132.93	82.29	84.40	78.07	61.19	92.84	61.19	50.64	59.08	90.73	94.95	92.84	122.38	67.52	101.28	63.30	84.40	46.42	71.74	42.20	73.85	67.52	67.52
56.97	108.62	126.60	84.40	80.18	94.95	71.74	92.84	82.29	52.75	46.42	94.95	116.05	56.97	105.50	140.09	116.05	69.63	92.84	80.18	88.62	94.95	73.85	52.75	69.63
94.95	100.73	130.82	92.84	80.18	94.95	65.41	90.73	82.29	54.86	46.42	71.74	42.20	71.74	124.49	150.64	113.94	71.74	92.84	84.40	78.07	73.85	61.19	92.84	42.20
54.86	90.73	82.29	52.75	84.40	78.07	73.85	88.62	84.40	56.97	80.18	88.62	94.95	78.07	73.85	118.16	111.83	75.96	67.52	35.87	50.64	94.95	61.19	103.39	59.08
116.05	50.64	50.64	46.42	35.87	50.64	94.95	61.19	103.39	59.08	78.07	118.16	78.07	80.18	40.09	120.27	107.61	73.85	82.29	35.87	54.86	94.95	61.19	103.39	61.19
113.94	118.16	50.64	48.53	35.87	54.86	94.95	61.19	103.39	61.19	63.30	103.39	67.52	80.18	71.74	84.40	132.93	82.29	84.40	59.08	90.73	94.95	52.75	90.73	63.30
94.95	92.84	61.19	50.64	59.08	90.73	94.95	52.75	90.73	63.30	61.19	105.50	65.41	80.18	71.74	108.62	126.60	84.40	80.18	46.42	94.95	116.05	52.75	97.06	65.41
94.95	92.84	82.29	52.75	46.42	94.95	116.05	52.75	97.06	94.95	137.98	120.27	61.19	105.50	48.53	100.73	130.82	92.84	80.18	46.42	71.74	42.20	73.85	67.52	67.52
46.42	94.95	116.05	52.75	48.53	35.87	42.20	73.85	67.52	84.40	78.07	61.19	92.84	61.19	50.64	71.74	92.84	82.29	61.19	80.18	88.62	94.95	73.85	52.75	69.63
46.42	71.74	42.20	52.75	50.64	59.08	94.95	73.85	52.75	80.18	94.95	71.74	92.84	82.29	52.75	65.41	90.73	82.29	52.75	84.40	78.07	73.85	71.74	61.19	92.84
80.18	88.62	94.95	73.85	52.75	46.42	73.85	61.19	92.84	80.18	94.95	65.41	90.73	82.29	54.86	44.31	50.64	50.64	46.42	35.87	50.64	94.95	63.30	109.72	44.31
78.07	118.16	78.07	73.85	54.86	46.42	94.95	109.72	44.31	84.40	78.07	73.85	88.62	84.40	56.97	46.42	118.16	50.64	48.53	35.87	54.86	94.95	44.31	50.64	50.64
63.30	103.39	67.52	61.19	56.97	42.20	94.95	50.64	50.64	35.87	50.64	94.95	61.19	103.39	59.08	61.19	92.84	61.19	50.64	59.08	90.73	94.95	46.42	118.16	50.64
80.18	40.09	63.30	109.72	59.08	90.73	46.42	118.16	50.64	35.87	54.86	94.95	61.19	103.39	61.19	71.74	92.84	82.29	52.75	46.42	94.95	116.05	52.75	48.53	35.87
46.42	94.95	116.05	52.75	48.53	35.87	61.19	92.84	61.19	50.64	84.40	80.18	94.95	59.08	94.95	65.41	90.73	82.29	54.86	46.42	71.74	42.20	52.75	50.64	59.08
46.42	71.74	42.20	52.75	50.64	59.08	71.74	92.84	140.09	116.05	69.63	92.84	84.40	71.74	61.19	50.64	88.62	84.40	56.97	80.18	88.62	94.95	73.85	52.75	46.42
118.16	50.64	48.53	82.29	84.40	61.19	65.41	90.73	150.64	113.94	71.74	92.84	92.84	63.30	109.72	52.75	61.19	103.39	59.08	78.07	118.16	78.07	73.85	54.86	46.42
92.84	61.19	50.64	84.40	80.18	61.19	50.64	88.62	118.16	111.83	75.96	67.52	92.84	44.31	50.64	52.75	61.19	103.39	61.19	63.30	103.39	67.52	61.19	56.97	42.20
92.84	82.29	52.75	92.84	80.18	50.64	52.75	61.19	120.27	107.61	73.85	82.29	80.18	46.42	118.16	63.30	109.72	118.16	78.07	80.18	40.09	63.30	109.72	59.08	90.73
90.73	82.29	54.86	90.73	78.07	54.86	52.75	61.19	84.40	132.93	82.29	84.40	78.07	61.19	92.84	44.31	50.64	61.19	59.08	71.74	71.74	44.31	50.64	61.19	90.73
88.62	84.40	56.97	80.18	88.62	59.08	63.30	52.75	108.62	126.60	84.40	80.18	94.95	71.74	92.84	46.42	118.16	82.29	61.19	84.40	71.74	46.42	118.16	63.30	103.39

Figura 4.34: Correspondência da cena da árvore 05 com a matriz de distâncias gerada.

A direção da bússola durante a aquisição de cada imagem/matriz estava em 210° SO em relação ao norte magnético. Conforme são mostradas nas figuras 4.30, 4.31, 4.32, 4.33 e 4.34, as coordenadas em latitude e longitude de cada árvore, e a formação das matrizes de distâncias gerada, são relacionadas.

Na figura 4.35, é apresentada esquematicamente a correspondência da imagem da laranjeira com a respectiva matriz de distâncias.

Figura 4.35: Correspondência da cena da laranjeira com a matriz de distâncias.

As matrizes de distâncias contêm as medidas do sensor até pontos da árvore. Para gerar as distâncias correspondentes ao volume da copa da árvore, foram feitas normalizações nos dados, em que são retificados e armazenados na matriz $[DC(x,y)]$, representando o perfil da copa da árvore, e sendo usados para gerar parâmetros de volume da mesma, como demonstrado pelas etapas procedurais a seguir, e na figura 4.36.

1) *Busca-se na matriz de distâncias a menor distância relativa entre todas as distâncias armazenadas (D_{min});*

2) *O valor D_{min} é subtraído de todas as distâncias armazenadas na matriz, sendo o resultado (distância corrigida - DC) armazenado em cada posição de armazenamento;*

- 3) Busca-se na matriz o maior valor armazenado (maior DC , denominado DC_{max});
- 4) DC_{max} é usado para gerar os novos valores armazenados na matriz, denominados valores retificados (D_{ret}), de acordo com a seguinte formulação:

$$D_{ret}(x, y) = -DC(x, y) - D_{max} \quad (32)$$

Figura 4.36: Geração da Matriz de Distâncias Retificadas.

Após a geração da matriz de distâncias retificadas, são aplicadas técnicas e extração de valores/gráficos para cada linha matricial e de superfície, que permitem o cálculo da estimativa do volume de dosséis, e o mapeamento estimado da profundidade de cada árvore.

4.5. Métodos propostos para a caracterização da refletância, NDVI e instrumentação

Índices de vegetação são calculados pelas "medidas radiométricas adimensionais, as quais indicam a abundância relativa e a atividade da vegetação verde" (TANGERINO, 2009 *apud* JENSEN, 2009). A função entre estas medidas radiométricas é obter índices vegetativos culturais, como área foliar, cobertura vegetal, biomassa, tipo da cultura analisada e estado nutricional/qualitativo do vegetal (SHIRATSUCHI *et al.*, 2014).

Um índice vegetativo muito utilizado é o NDVI (*Normalized Difference Vegetation Index*), que é calculado a partir de combinações de faixas específicas de luz, entre elas a visível e a infravermelha (IR). A fonte inicial da energia eletromagnética, como a luz solar, é registrada pelos sistemas de sensoriamento remoto, e tal conhecimento sobre a interação entre a radiação solar e a vegetação é necessário para interpretar e analisar dados agrônômicos em sensores exteroceptivos (TANGERINO, 2009; 2014).

O grau de refletância de um dossel de plantas é caracterizado pela desuniformidade de incidência de radiação solar, estrutura da planta, área da folha, caules, ramos, galhos, sombras e reflexões de *background*, com baixa densidade na região espectral visível, devido a absorção da clorofila, alta densidade na infravermelha próxima (NIR), devido à dispersão interna e nenhuma absorção foliar (KNIPLING, 1970).

A perspectiva da planta influencia diretamente no índice de refletância, e depende de sua interação com a radiação, sendo que a qualidade e intensidade refletida/emitida são baseadas nas variações de geometria, morfologia e composição química da folha, tipo de solo, influência climática, temperatura incidente, fatores físico-químicos gerais.

Um índice de vegetação ideal deve (TANGERINO, 2009):

- Maximizar a sensibilidade a parâmetros biofísicos das plantas, preferencialmente de uma forma linear, para uma grande amplitude de condições de vegetação e para facilitar a validação e a calibração do índice;
- Ser acoplável a algum parâmetro biofísico mensurável, tais como biomassa, índice de área foliar (IAF), radiação fotossinteticamente ativa absorvida (RFAA - APAR), para fins de validação e de controle de qualidade.

O Índice Vegetativo Diferencial Normalizado (NDVI - *Normalized Difference Vegetation Index*) trata-se da relação entre a diferença sobre a soma do fluxo radiante refletivo no infravermelho próximo (R_{NIR} - *Infrared Band Reflectance*) e o fluxo radiante refletivo no vermelho (R_{VIS} - *Visible Band Reflectance*), fornecendo informações sobre a biomassa da vegetação ou sobre o índice de área foliar (IAF).

$$NDVI = \frac{R_{NIR} - R_{VIS}}{R_{NIR} + R_{VIS}} \quad (33)$$

Com tal índice vegetativo, as mudanças sazonais e interanuais no desenvolvimento e na atividade da vegetação são monitoradas, e a razão matemática da equação 35 reduz muitas formas de ruídos multiplicativos (diferenças de iluminação solar, sombras de nuvens, algumas atenuações atmosféricas, variações topográficas) contidas na variação das bandas de imagens (ROUSE *et al.*, 1973).

Alguns fatores também devem ser considerados ao uso do NDVI, que necessitam de tratamento computacional:

- Apresenta informação não-linear, influenciado por efeitos ruidosos aditivos, como radiação de trajetória atmosférica, por ser um índice baseado em razão;
- NDVI é relacionado diretamente com o índice de área foliar, mas não de forma intensa durante períodos de máximo IAF, quando existe saturação do NDVI e o IAF é muito alto;
- NDVI é muito sensível a variações do substrato sob o dossel, com razão alta para substratos mais escuros.

Uma revisão bibliográfica abrangente sobre os estudos realizados em diferentes culturas, e considerando o uso de sensores ativos de refletância, é encontrada em Tangerino (TANGERINO, 2009; 2014) e em Inamasu (INAMASU *et al.*, 2006), onde destacam que o NDVI medido pelo sensor Crop Circle (HOLLAND, 2015) pode identificar a deficiência de N em culturas de cana-de-açúcar com consequente uso em controle de tempo-real em aplicação de fertilizante, mas que são aplicados também em milho, trigo, algodão, e citros, relacionando o NDVI e o índice de clorofila com índices vegetativos, para a estimação da quantidade de nitrogênio nas culturas por análise espectral.

Crop Circle e instrumentação embarcada

O sensor Crop Circle (HOLLAND, 2015) é um sensor de refletância que usa a propriedade de que as plantas absorvem a luz visível e refletem uma faixa do infravermelho (IR), devido as características estruturais da planta. A luz refletida é detectada pelo sensor e usada para o processamento dos cálculos de biomassa vegetativa, diretamente proporcional à biomassa da planta.

Neste trabalho, foi usado o sensor Crop Circle modelo ACS-430 da Holland Scientific, sendo um sensor ativo de refletância que fornece informações sobre índices vegetativos da planta. Apresenta a vantagem de conduzir sua própria fonte de luz no comprimento de onda do visível ao infravermelho próximo (NIR), com um vetor de diodos emissores de luz policromáticos modulados, que emitem ondas de luz na banda de 320nm a 1100nm, e três bandas de medidas ópticas de detecção em 670nm, 730nm e 775nm.

Segundo o manual de instruções, tal sensor faz medidas com distâncias entre 0,25m e 2,00m, mas como posicionamento ideal entre 0,50m e 0,90m, para um campo de visão ativo entre 30° e 15°, e a temperatura de operação indicada é de 0°C a 50°C.

A interface de comunicação pode ser configurada para o padrão serial RS-485 em comunicação bidirecional, e RS-232, apenas como saída de dados, em *baud rate* de 38400bps, sem paridade, 1 *stop bit* e 8 *data bits* de transmissão.

As informações adquiridas pelo sensor são R_{NIR} (*Infrared Band Reflectance*), R_{VIS} (*Visible Band Reflectance*), o índice vegetativo diferencial normalizado (NDVI - *Normalized Difference Vegetation Index*), a refletância de banda na borda do vermelho (RE - *red edge*), e a borda de vermelho diferencial normalizado (NDRE - *Normalized Difference Red Edge*), calculada pela equação 34:

$$NDRE = \frac{R_{NIR} - RE}{R_{NIR} + RE} \quad (34)$$

A forma como os dados são montados pelo barramento serial RS-232 é dada pela sequência: RE, R_{NIR} , R, NDRE, NDVI. Um código implementado em C#, que trata as interrupções de maneira mais transparente orientado a objetos, faz a leitura dos dados do sensor, montando-os na sequência acima e gravando num arquivo de texto, para análise *a posteriori*.

O experimento de aquisição de dados com o sensor de refletância foi conduzido nos semestres de 2013, 2014 e 2015, em períodos entressafras, de maturação e colheita da laranja (qualidade *valência*), também na fazenda Santa Elisa, região de São Carlos/SP, usando a base de dados **B**, também trabalhada na proposta de tratamento de imagens termográficas. Com 60 talhões divididos em setores de aplicação, a fazenda cultiva as variedades: *westin*, *rubi*, *hamlin* (precoces), *pera-rio* (meia-estação), *valência*, *natal* e *folha murcha* (tardias), com 40% da área dedicada à *valência*, e sendo a variedade oportuna aos experimentos, quando da condução efetiva do sensor Crop Circle por parte do laboratório de pesquisa.

A montagem do sensor na parte traseira do quadriciclo ficou estabelecida, conforme imagens abaixo, na posição vertical, direcionada lateralmente à direita, com fixação de 1,40m de altura. Como a distância entre as linhas de plantio é de 3,0m, e considerando a largura do veículo terrestre durante a locomoção, a distância efetiva entre o sensor e cada árvore é de 0,90m, sendo adequada para medidas com abertura angular de FOV (*field-of-view*) integral, segundo as próprias especificações do manual técnico (figura 4.37). Ainda, a largura do feixe de refletância, quando montado, é determinado pela equação 35:

$$L_{feixe} = 2 \cdot d \cdot \tan\left(\frac{\theta}{2}\right) = 0,82 \cdot d \quad (35)$$

Sendo:

d : distância efetiva entre sensor e árvore

θ : abertura angular FOV (*field-of-view*) de 45°

Figura 4.37: Abertura angular entre o sensor e o alvo.

A montagem do sensor Crop Circle no quadriciclo é verificada na figura 4.38.

Figura 4.38: Montagem do sensor Crop Circle no veículo de testes.

Os objetivos de processamento de dados nos índices vegetativos se estendem à caracterização dos frutos e da biomassa, de acordo com as fases de conservação e, principalmente, a detecção de sintomas de deficiências, mapas de distribuição das plantações, qualidades dos frutos, tipos de doenças, irregularidades, imperfeições e outros danos na crosta dos frutos, bem como nas folhas, baseado no guia de deficiências *Stoller* (STOLLER, 2015).

A *priori*, os elementos químicos listados na tabela 4.1 são alvos de inspeção nas folhas, colmos e frutos, como verificados na figura 4.39.

Tabela 4.1: Elementos químicos e características na inspeção de folhas, colmos e frutos.

Elemento químico	Características
<i>Zinco</i>	Folhas novas pequenas, acentuadas, clorose internerval, internódios curtos. Floração reduzida, frutos pequenos e com pouco suco.
<i>Manganês</i>	Folhas novas de tamanho normal, com clorose internerval, porém mais pálidas e menos acentuadas que as de zinco. Frutos pequenos e menor produção.
<i>Boro</i>	Folhas novas pequenas e mal formadas, com ondulação no limbo e

	nervuras salientes. Frutos de tamanho reduzido deformados e com casca grossa e irregular, podendo apresentar goma. Sementes pequenas, escuras e mal formadas.
<i>Ferro</i>	Folhas novas apresentando clorose típica de reticulado fino. Nervuras permanecem verdes, porém com limbo foliar amarelo.
<i>Cobre</i>	Folhas novas grandes em ramos com crescimento excessivo.
<i>Molibdênio</i>	Folhas velhas com manchas amareladas, queda de flores e de frutos novos.
<i>Enxofre</i>	Folhas novas pequenas com amarelecimento homogêneo.
<i>Cálcio</i>	Folhas novas com amarelecimento da borda para o centro, morte de ramos novos. Sistema radicular pouco desenvolvido implicando em baixa resistência à seca com queda de folhas, flores e frutos.
<i>Magnésio</i>	Folhas velhas com amarelecimento da ponta para o pecíolo.
<i>Potássio</i>	Irregularidades nos frutos, tornando-os pequenos, de casca lisa e fina.
<i>Fósforo</i>	Folhas velhas amareladas, queda de folhas e botões florais, frutos ásperos, esponjosos com casca espessa e com centro oco.
<i>Nitrogênio</i>	Folhas velhas com amarelecimento homogêneo, vegetação rala, folhas pequenas, frutos pequenos com casca fina

Figura 4.39: Sintomas de deficiências em pomares: (a) zinco, (b) manganês, (c) boro, (d) ferro, (e) cobre, (f) molibdênio, (g) enxofre, (h) cálcio, (i) magnésio, (j) potássio, (k) fósforo, (l) nitrogênio.

Em relação aos índices vegetativos da planta, o principal associado ao sensor de refletância (NDVI) verifica se a área foliar (*índice de área foliar IAF*) apresenta saturação correspondente aos valores obtidos. Para valores entre -0,5000 e -0,9999 a correspondência com as características de biomassa da planta denominam que a área analisada é saudável e em período de colheita.; para valores entre -0,0001 e -0,4999 a correspondência com as características da biomassa da planta denominam que a área analisada é saudável e em período de maturação; para valores entre 0,5001 e 0,0000, a área analisada é saudável e em

período de plantação; e para valores entre 0,9999 e 0,5000, a área analisada não é saudável, independente do período de amostragem.

NDRE (*Normalized Difference Red Edge*), sendo a razão da diferença pela adição entre R_{NIR} e RE, caracteriza relativamente o período entre plantação (0,9999 a 0,5000), maturação (0,4999 a 0,0000) e colheita (-0,0001 a -0,5000) do fruto. Os índices vegetativos RE, R_{NIR} e R correspondem as características isoladas na região onde o sensor é aplicado, que denotam determinados graus de deficiência, como *diagnoses* inicial, sendo a verificação *a posteriori* em laboratório, como fator determinante em sua análise. RE (*red edge*), R_{NIR} (*refletância da banda infravermelha*) e R (*vermelho*), discriminam as seguintes falhas/não falhas nos elementos químicos, em função dos seus valores. A relação destes índices de refletância é apresentada na tabela 4.2.

Tabela 4.2: Relação entre valores dos índices vegetativos RE, R_{NIR} e R, e diagnoses.

Índice vegetativo	Valores de refletância	Características
RE	~20,00	Deficiência em: Zinco, Enxofre e Boro;
	~21,00	Deficiência em: Manganês, Cálcio e Fósforo;
	~22,00	Deficiência em Nitrogênio, Magnésio e Potássio;
	~23,00	Deficiência em Ferro, Molibdênio e Cobre;
	~24,00	Pré-deficiências (regularmente saudável);
	~25,00	Sem deficiências;
R_{NIR}	~20,00	Deficiência em: Zinco, Enxofre e Boro;
	~21,00	Deficiência em: Manganês, Cálcio e Fósforo;
	~22,00	Deficiência em Nitrogênio, Magnésio e Potássio;
	~23,00	Deficiência em Ferro, Molibdênio e Cobre;
	~24,00	Pré-deficiências (regularmente saudável);
	~25,00	Sem deficiências;
R	85,01 a 90,00	Estimativa do equilíbrio entre os períodos de maturação e colheita com nenhuma deficiência.
	90,01 a 95,00	Estimativa do equilíbrio entre os períodos de maturação e colheita com alguma deficiência.

4.6. Proposta para classificação geral cognitiva na fusão sensorial óptica

As propostas de classificadores cognitivos (RNA e *Fuzzy*) dedicados às classes trabalhadas nos índices de refletância são correlacionados com as tarefas de mineração de dados. Na mineração de dados, é necessário definir as técnicas de recorrência de dados, que consiste na especificação de métodos que garantem a extração de um padrão ou classes de padrões classificados. É dividida em duas áreas: predição (classificação e regressão) e descrição (associação e agrupamento) (LAROSE, 2015).

As atividades de predição envolvem a aplicação de atributos de um conjunto de dados (geralmente de treinamento) para prever se dado evento ocorre em uma situação pré-determinada. São examinados atributos de um conjunto de entidades, em que são assinalados valores e atributos para as características destas entidades.

As atividades de descrição se relacionam a padrões interpretáveis em que os dados são descritos, antes de realizar a previsão e, conseqüentemente, a decisão. Tem por objetivo descrever o que acontece em uma base de dados, para aumentar a garantia de associação ou agrupamento destas características com os padrões estimados.

Desta forma, são propostos dois métodos de classificação cognitiva para integrar os dados de forma ponderada. Tais dados, pré-classificados de cada sensor, devem atender a um peso de relevância computacional ao classificador geral, caracterizando assim, uma fusão de dados ponderados sequenciais. A relação de pesos que o classificador geral assume, identifica se os dados são classificados de forma quantitativa, qualitativa ou ambos:

1) Sensor óptico RGB (visão computacional): para localização, posição e distribuição de frutos, em função da área do dossel de cada árvore (*quantificação dos frutos*) - **peso 3**;

2) Sensor óptico IR termográfico (imagens térmicas): pré-classificação *expectation maximization* para identificação de irregularidades na superfície do fruto (*diagnoses/qualificação do fruto*) - **peso 2**;

3) Sensor ultrassônico (sonar): construção de matrizes de distância, mapas de profundidade e estimação do volume espacial (*quantificação da produção*) - **peso 2**;

4) Sensor de refletância: obtenção e tratamento dos índices vegetativos da planta, caracterização de dados bioquímicos para cultivo de citros (RE, R_{NIR} , R, NDRE, NDVI) - (*diagnoses/qualificação da produção*) - **peso 1**;

Com os pesos pré-definidos, estabeleceu-se que pela integração entre os classificadores cognitivos por lógica difusa e redes neurais artificiais, existe uma relação de dados que necessitam ser classificados de acordo com suas características, lineares e não-lineares.

Na primeira etapa do classificador geral cognitivo ponderado (CgCP), a relação dos pesos de cada entrada (quatro vetores de entrada) relacionada às pré-classificações dos dados nas propostas de cada sensor, são discriminadas pela lógica difusa, assim como se as imagens da base de dados **B** (regiões específicas das árvores), são denominadas regiões constituintes das imagens da base de dados **A** (cenos de dosséis completos). Na segunda etapa do classificador geral, as redes neurais artificiais são responsáveis pela associação de cada resultado parcial dos pré-classificadores com um conjunto homogêneo resultante,

identificando as características qualitativas e quantitativas trabalhadas com os quatro sensores em sua respectiva imagem (cena natural) de entrada.

Na figura 4.40, é apresentado o diagrama de blocos do processo de classificação geral cognitivo com pesos para a fusão sensorial pretendida.

Figura 4.40: Diagrama de blocos funcional do processo de classificação geral cognitiva com atribuição de pesos na fusão sensorial.

No diagrama de blocos da figura 4.40, inicialmente são normalizados os resultados das pré-classificações de cada sensor envolvido. Os histogramas RGB/HSV pós segmentação (quantização de cores), as máximas-verossimilhanças das cenas termográficas, as matrizes de distâncias retificadas e as médias dos índices vegetativos (NDVI). Por conseguinte, estes dados são inseridos como as entradas da primeira etapa do CgCP, no classificador por lógica difusa, cujo processo é associar magnitudes de peso para cada dado (peso maior para dados com maior relevância), e associar cenas de regiões com cenas de dosséis, isto é, verificar se os dados de menor peso, que correspondem as cenas de regiões, são dependentes/contidas nas cenas de dosséis (de maior peso). Finalmente, na segunda etapa do CgCP, é implementado um classificador por RNA, que verifica se os dados de maior peso correspondem as classes

pretendidas para uma fusão completa, seguindo pelos dados de menor peso, construindo assim, um modelo resultante de sobreposição com as características qualitativas e quantitativas para cada cena natural (figura 4.41).

Figura 4.41: Diagrama de blocos expandido do processo de classificação geral cognitiva ponderada, com a discriminação dos dados de entrada e saída para as duas etapas do classificador.

O resultado, nos dados de saída, da etapa 02 do CgCP (RNA), apresenta informações que podem ser de ordem quantitativa e qualitativa (fusão relacional), apenas quantitativa (fusão parcial quantitativa), e apenas qualitativa (fusão qualitativa). Estas relações são descritas com mais detalhes na seção do classificador por RNA.

O CgCP associa tanto como entradas como saídas, matrizes normalizadas dos dados das pré-classificações, e informações vetoriais sobre:

- *Quantificação de frutos*: identificação e localização de frutos na cena natural (imagem RGB/HSV);
- *Qualificação de frutos/diagnoses*: deformidades nos frutos avaliados (imagem termográfica);
- *Quantificação de produção*: correspondência da matriz de distâncias com a cena natural;
- *Qualificação de produção/diagnoses*: índices vegetativos da planta (NDVI informando o período de plantação, maturação e colheita).

i. *Lógica Fuzzy (difuso-nebulosa)* (ZADEH, 1965):

Na lógica *fuzzy*, os conjuntos dimensionados são uma generalização dos conjuntos clássicos. A diferença entre ambos consiste na variação de pertinência (0 ou 1) a determinado elemento para o modelo clássico, e $\mu = [0,1]$ como intervalo aos graus de pertinência no modelo difuso. Sua pertinência neste intervalo é relacionada à própria normalização dos dados (LULIO *et al.*, 2010b).

Com várias formas geométricas (sino, triangulares, trapezoidais), as funções de pertinência são relacionadas conforme seu desenho gráfico. Para a expressão da função

trapezoidal utilizam-se quatro parâmetros (α , β , γ , δ) que correspondem aos vértices do trapézio. Os parâmetros α e δ representam os valores mínimo e máximo da variável analisada, que têm pertinência dentro do conjunto. São definidas as operações de união e interseção para estes conjuntos. Assim, são atribuídos números difusos. Um número difuso é um valor numérico que representa um conjunto difuso. As variáveis linguísticas representam vários conjuntos formados pelos números difusos, que assumem valores dentro de um conjunto de termos lingüísticos, ou seja, palavras ou frases, assim elas assumem instâncias linguísticas.

Desta forma, as regras aplicadas para as instâncias linguísticas neste caso são do tipo condição-ação, em que um conjunto de condições de entrada é ligada a ações que fazem com o processo estudado chegue às respostas esperadas. Logo, a representação do conhecimento dá-se através de um conjunto de regras, nas quais as condições dadas a partir de um conjunto de termos linguísticos são associadas às variáveis de saída/entrada do processo. A relação entre as entradas e as regras de saída é conhecida como inferência ou estado de inferência.

Observa-se o diagrama de blocos para um classificador *Fuzzy* com as etapas acima citadas, na figura 4.42.

Figura 4.42: Diagrama de blocos de um classificador *Fuzzy*: (EP: entradas precisas; SP: saídas precisas).

Assim, um classificador de inferências *Fuzzy* trabalha as variáveis de entrada com a *fuzzyficação*, processo de escalonamento para normalização dos dados e transformação dos números difusos em conjuntos ou variáveis linguísticas. Criando a base de regras, e considerando a existência de uma base de conhecimento (a qual gera a estratégia de controle e os resultados), o processo de inferência, trabalha com as ações de controle para a saída, conhecidas como *defuzzyficação*, que transformam as variáveis linguísticas para números difusos. Um dos métodos mais utilizados em *defuzzyficação* é o método do centro de área

(CDA), que retorna o centro da área do conjunto difuso de saída, ou conjunto inferido (ZADEH, 1965).

Nesta primeira etapa do classificador CgCP, o modelo *fuzzy* manipula as variáveis de entrada (*fuzzyficação*), para o escalonamento da normalização dos vetores de características (histogramas RGB/HSV pós segmentação, máxima-verossimilhança das misturas *gaussianas*, matrizes de distâncias retificadas, médias dos índices vegetativos), resultando em variáveis linguísticas dentro de um intervalo que correspondem a padrões de pesos estimados nas imagens analisadas. Com isso, tais variáveis obedecem a uma base de regras para a adequação dos padrões em um processo de inferência preditivo, que após analisados, são classificados de acordo com as abordagens trabalhadas.

Inicialmente, a classificação dar-se-á pela atribuição correta dos pesos para cada vetor de características e, conseqüentemente, cada qual associará a correspondência das cenas naturais analisadas, com a dependência entre as bases de dados, *i.e.* se determinada cena de região é parte de cena de dossel, com os pesos calculados.

Estes padrões são então, *defuzzyficados*, tornando as variáveis linguísticas em números representativos dos *pixels/dados* analisados na imagem/matriz de pontos (cena de região e cena de dossel com os vetores ponderados). Em ambos os casos, é aplicado o centróide (CDA) que retorna o centro de área dos conjuntos difusos de saída.

A implementação do classificador *fuzzy* foi feita através da *toolbox* de lógica difusa no MATLAB. As relações de entrada, conjunto de regras, funções-membro e processos de inferências são descritas a seguir. Os gráficos que relacionam as funções membro e seus respectivos estados de inferência ao grau de pertinência são demonstrados a seguir.

Como os vetores de características de cada abordagem/proposta denotam valores díspares entre cada situação (histogramas RGB/HSV pós segmentação, máxima-verossimilhança das misturas *gaussianas*, matrizes de distâncias retificadas, médias dos índices vegetativos), as entradas definidas são, então, normalizadas para que o classificador *fuzzy* apresente saídas parametrizadas e convergentes, de acordo com a base de regras.

As entradas definidas são:

- Vetor de Histograma Imagem RGB/HSV (*VHim*) - histogramas da quantização de cores do processo de segmentação, nas imagens RGB/HSV trabalhadas;
- Vetor de Máxima-Verossimilhança IR (*VMVir*) - vetores das máximas-verossimilhanças das misturas gaussianas processadas nas imagens termográficas;
- Vetor Normalizado das Matrizes de Distância (*VnMD*) - vetores contendo as médias normalizadas das matrizes de distâncias retificadas, pelo sonar;

- Vetor das Médias dos Índices Vegetativos ($VmIV$) - vetores contendo as médias dos índices vegetativos pelo sensor de refletância;

As saídas definidas são:

- Peso de Convergência 3 (PC3);
- Peso de Convergência 2a (PC2a);
- Peso de Convergência 2b (PC2b);
- Peso de Convergência 1 (PC1);

Na figura 4.43, é apresentada a estrutura das entradas e saídas, ao modelo fuzzy preditivo, sendo o sistema de inferência configurado como *mamdani*, uma vez que a expectativa da classificação nas saídas estimadas seja atribuída em conjuntos difusos de *pixels/dados* durante a varredura da imagem/matriz, e não apenas a característica de determinado elemento.

Figura 4.43: Sistema de inferência *fuzzy* para a primeira abordagem do classificador CgCP.

A atribuição dos pesos segue a referência de maior relevância para a informação qualitativa e quantitativa em citricultura. Primeiramente, a *quantificação de frutos* tem seu maior peso (PC3), porque nela, são verificados todos os parâmetros de identificação e localização de frutos, na cena natural de dossel. Em seguida, para a *qualificação de frutos*, é avaliado o fruto que apresenta alguma irregularidade/deformidade em sua superfície, com peso intermediário (PC2a), também correspondendo a *quantificação de produção*, que identifica aspectos sobre a estimação de volume de dosséis (PC2b). Por fim, é verificada a *qualificação de produção*, em que as características de plantação, maturação e colheita são analisadas (PC1).

As funções-membro para cada valor de entrada são definidas pelo modo de aquisição e tratamento das imagens/matrizes, assim, para as entradas:

- *VHim*: *arco100*, *arco75*, *arco25* (figura 4.44);

As funções-membro para cada valor de entrada são definidas em seus respectivos limiares de ação. Para o caso da abordagem em visão computacional (entrada *VHim*), na localização de frutos e biomassa, a função-membro **arco25** varia o estado de inferência entre o padrão linear constante para a detecção percentual do fruto em semi-arco de 0 à 0,1 ao grau de pertinência máximo (trapezoidal), e 0,1 à 0,5 em padrão linear decrescente. A função-membro **arco100** que referencia toda a circunferência do fruto apresenta estado de inferência 0,5 em grau de pertinência máximo (triangular). A função-membro **arco75** apresenta estado de inferência 0,5 à 0,6 em padrão linear crescente, e 0,6 à 1 em padrão linear constante (trapezoidal), que simboliza a maior parte do fruto, o que majoritariamente ocorre nas cenas de pomares localizados. Com isso, arcos de circunferência detectáveis nas imagens segmentadas com áreas correspondentes até 100 e 200 pixels são relacionadas como candidatos a frutos, provendo maior peso (3,0) ao classificador – dada a distância focal das cenas adquiridas, bem como conjuntos de frutos próximos na mesma região segmentada.

Figura 4.44: Funções-membro para a entrada *VHim*, quanto ao grau de pertinência (eixo das ordenadas) e estado de inferência (eixo das abscissas).

- *VMVir*: *mancha100*, *mancha50*, *mancha10* (figura 4.45);

As funções-membro para a entrada *VMVir* se relacionam com o grau de deformidades que as regiões apresentam, uma vez detectados os frutos, com maior peso, as regiões passíveis de apresentarem irregularidades nas superfícies dos frutos são caracterizadas com menor peso (2,0). Logo, a primeira função-membro, **mancha100**, identifica regiões com maior abrangência visual irregular no fruto, e confundida com alterações no reflexo de luminosidade, apresenta estado de inferência 0,5 em grau de pertinência máximo (triangular). A função-membro **mancha50**, denota que para regiões menores passíveis de irregularidades, a observação ponderada nesta é maior, para relacionar sua classificação anterior com o

algoritmo EM, assim, apresenta padrão linear constante de 0,0 à 0,1 em grau de pertinência máximo (trapezoidal), com padrão linear decrescente de 0,1 até 0,5. E a função-membro **mancha10** apresenta padrão linear crescente de 0,5 à 0,8, e padrão linear constante de 0,8 à 1,0 com grau de pertinência máximo (trapezoidal), uma vez que neste caso é mais complexo associar manchas menores como irregularidades nos frutos, e determinar seu peso.

Figura 4.45: Funções-membro para a entrada *VMVir*, quanto ao grau de pertinência (eixo das ordenadas) e estado de inferência (eixo das abscissas).

- *VnMD*: *aim* (área irregular média), *aib* (área irregular baixa), *aia* (área irregular alta) (figura 4.46);

As funções-membro para a entrada *VnMD* discriminam o quão análogas são as áreas mapeadas pelas matrizes de distâncias com as imagens em RGB, descrevendo apenas partes da sua construção. Como a formação do dossel está relacionada com a detecção e localização dos frutos, pela primeira abordagem, esta entrada tem peso menor (2,0). A função-membro **aib** denota que baixa incidência de formação da planta é relativamente precisa, com isso, tem padrão linear crescente com grau de pertinência (triangular) em 0,5, até estado de inferência 0,2. Da mesma forma, para a função-membro **aia**, apresenta padrão linear decrescente em 0,8 com grau de pertinência (triangular) em 1,0, até estado de inferência 1,0. Por outro lado, a função-membro **aim** representa a maior porção da formação virtual da planta, assim, seu peso maior é atribuído em função de sua maior incidência de pontos, indicando folhas, ramos e galhos, assim, apresenta padrão linear crescente em 0,1 à 0,2, com grau de pertinência máximo (trapezoidal) até estado de inferência em 0,8, e padrão linear decrescente de 0,8 à 0,9.

Figura 4.46: Funções-membro para a entrada $VnMD$, quanto ao grau de pertinência (eixo das ordenadas) e estado de inferência (eixo das abscissas).

- $VmIV$: $NDVI_{alto}$, $NDVI_{medio}$, $NDVI_{baixo}$ (figura 4.47);

As funções-membro da entrada $VmIV$ denotam as variações em que os índices vegetativos indicam como fator qualitativo ao classificador, mas apenas como estimação, uma vez que a verificação é dada *a posteriori* em laboratório, sendo seu peso menor (1,0).

Figura 4.47: Funções-membro para a entrada $VmIV$, quanto ao grau de pertinência (eixo das ordenadas) e estado de inferência (eixo das abscissas).

As funções-membro **NDVIalto** e **NDVIbaixo** representam o índice vegetativo de menor interesse ao classificador, portanto, apresentam padrões lineares decrescentes e crescentes de 0,0 a 0,4 e 0,6 a 1,0 (triangulares). A função-membro **NDVImedio** denota o quão próxima determinada cena analisada se encontra em período de maturação e seu estado (*diagnoses*), sendo assim, apresenta grau de pertinência máximo em estado de inferência de 0,3 a 0,7 (trapézoidal).

As funções-membro para as quatro saídas (PC3, PC2a, PC2b, PC1) são caracterizadas de forma a identificar que todas as intersecções apresentem cenas de regiões pertencentes a cenas de dosséis (**CENAtotal**), cenas de regiões parcialmente pertencentes a cenas de dosséis (**CENAparcial**), e cenas de regiões não encontradas ou associadas a cenas de dosséis (**CENAinexistente**). Assim, a função-membro **CENAinexistente** apresenta padrão linear crescente em estado de inferência de 0,6 à 1,0 (triangular); a função-membro **CENAparcial** apresenta padrão linear crescente em estado de inferência de 0,0 à 0,1 para grau de pertinência máximo (trapezoidal) e padrão linear decrescente em estado de inferência 0,1 à 0,5; a função-membro **CENAtotal** apresenta padrão linear crescente em estado de inferência de 0,1 à 0,3, grau de pertinência máximo em estado de inferência de 0,3 à 0,7 (trapezoidal), e padrão linear decrescente em estado de inferência de 0,7 à 0,9 (figura 4.48).

Figura 4.48: Funções-membro para as saídas PC3, PC2a, PC2b e PC1, quanto ao grau de pertinência (eixo das ordenadas) e estado de inferência (eixo das abscissas).

ii. *Redes Neurais Artificiais (RNA)* (HAYKIN, 2008):

Os modelos computacionais baseados em Redes Neurais Artificiais (RNA) processam de forma paralela, dados não-lineares e complexos, inspiradas no cérebro humano, precisamente pelas estruturas celulares independentes, os neurônios. Sua estrutura baseia-se na complexidade de processamento paralelo, taxa de aplicação e redução do tempo de execução. Um modelo de RNA deve apresentar os conceitos naturais do cérebro humano, como a aprendizagem, a qual fomenta a obtenção do conhecimento a partir de uma aplicação, e as operações sinápticas ponderadas, que são as conexões intra-neurônios para o treinamento das informações.

Assim, como informações de entrada, são aplicados dendritos em um neurônio artificial, (corpo celular para a função de ativação, onde são realizados os cálculos

ponderados), e os axônios, que denotam as informações de saída. O estímulo de entrada de informações é representado de forma algébrica por $x_1, x_2, \dots, x_m$, cujos pesos sinápticos são representados por $w_{k1}, w_{k2}, \dots, w_{km}$, e que resultam numa soma limiarizada por b_k , responsável pela ativação do neurônio em resposta ao estímulo inicial. Em seguida, a função de ativação $\varphi(\cdot)$ delimita o sinal de saída (axônio) y_k a um intervalo finito e definido. Tal modelo é definido na equação 36.

$$y_k = \varphi \left(\sum_{i=1}^m w_{ki} x_i + b_k \right) = \sum_{i=1}^m w_{ki} x_i \geq \varphi \quad (36)$$

Como base, o modelo do neurônio artificial *McCulloch e Pitts* (McCULLOCH & PITTS, 1943), as entradas são disparadas simultaneamente a um estímulo e não dependem dos estados anteriores. Os neurônios são organizados em camadas, cujas entradas são conectadas na primeira camada, e os cálculos ponderados na camada de processamento. Esta estrutura é denominada de *feedforward*, cujo processamento é sequencial nas camadas necessárias à RNA. Os pesos sinápticos e o limiar são ajustados com um algoritmo de treinamento supervisionado, baseado no erro da rede (diferença entre os valores de saída e os de referência), e são dedicadas apenas a funções lineares, como Adaline e Perceptron de camada única (HAYKIN, 2008). É mostrada na figura 4.49, o modelo de neurônio artificial de *McCulloch e Pitts*.

Figura 4.49: Modelo de neurônio artificial *McCulloch e Pitts*.

Os cálculos ponderados nas camadas intermediárias (escondidas), são direcionados à maior complexidade e tendem a resultar em maior precisão após a limiarização do intervalo pretendido. Assim, tal arquitetura é denominada de Perceptron Multicamadas (MLP – *multilayer perceptron*), e dedicada a problemas matemáticos não-lineares. A sua função de

ativação deve ser contínua, não linear e diferenciável em qualquer ponto de convergência no cálculo do gradiente e no ajuste dos pesos sinápticos, para possibilitar a minimização do erro. Tal erro depende intrinsecamente ao modo de aprendizagem (treinamento) da RNA. Esta, então, é definida como o processo de adaptação dos parâmetros livres (pesos sinápticos dos neurônios e os limiares de ativação) na estimulação pelo ambiente, a qual a RNA é inserida, e seu modo é determinado pela modificação de tais parâmetros. A aprendizagem pode ser não-supervisionada ou supervisionada. A aprendizagem não supervisionada não provê a existência de um professor para a discriminação do estímulo na resposta da função de ativação, o que relaciona apenas os padrões de entrada como a proporção e identificação dos dados, mediante uma regularidade estatística durante a classificação. (LULIO, 2011a, 2011b).

Com isso, a aprendizagem supervisionada provê a existência de um professor, que conhece o ambiente de representação da RNA, submetido à avaliação dos resultados pela diferença entre os dados esperados e os dados obtidos (erro). Tal erro é usado para o ajuste dos parâmetros livres da RNA, a fim de torná-lo mínimo ou tão próximo de zero. Esse ajuste é conhecido como regra *Delta* generalizada (*Widrow-Hoff*). Na equação 37, e representa o erro, k o neurônio após ajuste de peso e n a medida de tempo discreta.

$$E(n) = \frac{1}{2} e_k^2(n) \quad (37)$$

No algoritmo *Backpropagation*, a regra *Delta* é generalizada, apresentando erro da RNA atribuído no ajuste dos pesos sinápticos da camada de saída (*forward*), e nas demais camadas ajustados pela propagação inversa (*backward*). Tal ajuste é proporcional ao gradiente da função erro (gradiente de descida) e pode não ser ótimo se considerar o mínimo local e não global da mesma função. Para correção deste cálculo, o algoritmo *backpropagation* foi adaptado em propagação resiliente aprimorada, *iRPROP* (IGEL e HÜSEKN, 2000). Tal derivação provê ao algoritmo, adaptação ao gradiente de descida, maximizando-o e no ajuste da taxa de treinamento, minimizando as oscilações, tornando robusto e preciso. Além disso, o algoritmo *iRPROP* apresenta número reduzido de iterações, o que diminui o tempo de convergência.

Desta forma, os vetores de características das quatro abordagens, com a normalização dos pesos e referências de cenas, pela lógica *fuzzy* são classificados em topologia adequadas de redes neurais MLP customizadas com o *iRPROP*.

As entradas são discriminadas pelos quatro conjuntos de vetores de características para todas as percentagens de treinamento, e validação, com as seguintes características:

- *histogramas RGB/HSV pós segmentação não-homogênea - abordagem 1;*

- *máxima-verossimilhança das misturas gaussianas - abordagem 2;*
- *matrizes de distâncias retificadas - abordagem 3;*
- *médias dos índices vegetativos - abordagem 4;*

Cada topologia apresenta uma camada de entrada contendo n dimensões relativa aos vetores de características, camada escondida de 20 neurônios, e camada de saída com três neurônios (*fusão relacional*, *fusão quantitativa* e *fusão qualitativa*), direcionadas aos pré-resultados das quatro abordagens, totalizando 720 tipos de RNA.

Ainda, como as saídas pretendidas da RNA são direcionadas a uma integração dos dados de entrada, cuja relação entre as quatro abordagens (pré-classificações) é definida pela proximidade de informações que uma saída ponderada tem com a outra, são atribuídos percentuais das taxas de acerto, para cada saída.

- 95% ou mais - classe para a *fusão relacional*;
- 85% a 94,9% - classe para a *fusão quantitativa*;
- 75% a 84,9% - classe para a *fusão qualitativa*.

Isso significa que para a *fusão relacional*, ao menos, três das quatro classes/abordagens devem corresponder sua sobreposição em 95% ou mais; caso apenas a abordagem de quantificação de frutos e a abordagem de quantificação de produção sejam correspondidas entre 85% e 94,9%, a saída *fusão quantitativa* é classificada; caso apenas a abordagem de qualificação de frutos e a abordagem de qualificação de produção sejam correspondidas entre 75% e 84,9%, a saída *fusão qualitativa* é classificada; por fim, caso outras correspondências coexistam de forma arbitrária e em menor percentual, a fusão não existe (RNA não classifica). Com isso, a representação dos neurônios de entrada e de saída atende a topologia abaixo, da figura 4.50.

Figura 4.50: Topologia RNA aplicada as quatro abordagens.

As entradas x_n correspondem ao número de dimensões dos vetores de características após a normalização, que cada pré-resultado das abordagens apresenta em forma matricial.

As topologias foram treinadas 25 vezes, para o número máximo de iterações (épocas) em 100.00 ou o erro quadrático médio for inferior a 0,0001. A ponderação sináptica foi iniciada com os valores calculados na classificação por lógica *fuzzy*, e os padrões de treinamento foram aplicados arbitrariamente. A função de ativação é tangente hiperbólica variando entre 0,7 e 0,9. A programação das topologias foi implementada através da *toolbox* de redes neurais artificiais (ANN) do MATLAB.

A *toolbox* de RNA do MATLAB possui uma biblioteca dedicada ao reconhecimento de padrões, em que os dados de entrada e testes são relacionados como matrizes de características (acrescentam-se os pesos da primeira etapa difusa). Cada linha desta matriz corresponde aos elementos ou características e cada coluna corresponde às amostras ou dimensões, definida pelos cálculos da ACP, também projetada em MATLAB, dos pré-resultados das quatro abordagens. A percentagem entre os conjuntos de amostras para o treinamento, testes e validação é dada respectivamente por: 70%, 15% e 15%.

iii. *Classificador geral Cognitivo Ponderado (CgCP):*

As classes do CgCP (*fusão relacional*, *fusão quantitativa* e *fusão qualitativa*) são associadas de acordo com os pesos calculados e percentuais de referência de uma cena para outra, demonstrando se os dados qualitativos (do pomar e do fruto) se confundem com os dados quantitativos (do pomar e do fruto). Assim, são pretendidas as seguintes classes, para que a integração dos dados qualitativos e quantitativos apresente convergência durante a fusão sensorial:

- *fusão relacional*: sobreposição dos quatro pré-resultados (ou ao menos três) de acordo com a prioridade dos pesos na classificação (mapas de classe RGB/HSV, máxima-verossimilhança em regiões termográficas, matrizes de distância retificadas, índices vegetativos);
- *fusão quantitativa*: sobreposição inicial dos dois pré-resultados quantitativos (mapas de classe RGB/HSV, matrizes de distâncias retificadas) - de fruto e de produção;
- *fusão qualitativa*: sobreposição inicial dos dois pré-resultados qualitativos (máxima-verossimilhança em regiões termográficas, índices vegetativos) - de fruto e de produção.

Na fusão sensorial, é implementado o algoritmo de preenchimento de regiões, que estabelece a sobreposição dos pré-resultados (classes), para as saídas pretendidas.

Cada saída neuronal, também recebe mais de uma classe associada a fusão, mas diverge no percentual da taxa de acerto que corresponde a determinada classe (cenas

regionais, da base de dados **B**) para outra (cenais totais, da base de dados **A**), e a RNA classifica tais regiões, de acordo com os percentuais de cada classe, que devem apresentar magnitude alta para caracterizar a classificação dos neurônios de saída.

4.7. Considerações finais

Neste capítulo foram descritos os procedimentos para os materiais, métodos e resultados sequenciais dedicados as etapas de processamento de imagens, segmentação, extração e normalização de características, classificador estatístico e determinação das propriedades geométricas de imagens em cenas de laranjeiras, bem como o tratamento e proposta de integração a soluções de processamento de imagens por termografia óptica, soluções de caracterização de regiões por modelos de mistura de *Gaussianas* (*MoG*) na definição de mapas de profundidade por fluxo óptico IR e sensor monocromático CMOS. Os resultados da aplicação de testes com sonares, para a obtenção e normalização de parâmetros das matrizes de distância, gráficos de dispersão e superfície das matrizes de distâncias, e a análise dos índices vegetativos das plantas pelo sensor de refletância.

Os modelos de classificação e reconhecimento de padrões por modelos cognitivos foram propostos como alternativa a integração de denominações de padrões e classes para a fusão sensorial de dados, de forma ponderada, integrando um classificador baseado em lógica *fuzzy* para parametrizar os dados de entrada, e um classificador baseado em redes neurais artificiais, para a associação dos dados de saída, fomentando a temática de um classificador geral cognitivo ponderado (CgCP).

5. RESULTADOS EXPERIMENTAIS

Neste capítulo são apresentados os resultados experimentais para as quatro abordagens propostas e desenvolvidas, bem como para o classificador geral cognitivo ponderado, proposto como modelo de reconhecimento e interpretação de padrões para a integração dos dados qualitativos e quantitativos processados.

Inicialmente, são apresentados os resultados da abordagem 01, que representa a proposta em visão computacional aplicada a imagens RGB, seguida da abordagem 02, sobre a proposta em visão computacional aplicada a imagens térmicas, da abordagem 03, sobre a estimação do volume de dosséis por sonares, e da abordagem 04, sobre a caracterização dos índices de refletância (NDVI) e instrumentação. Por fim, são apresentados e discutidos os resultados da proposta do classificador geral cognitivo ponderado (CgCP).

5.1. Resultados em visão computacional aplicada a imagens RGB

Os resultados apresentados nesta abordagem são, de acordo com a sequência das etapas do sistema de visão computacional aplicado a imagens RGB, desde o pré-processamento, algoritmos de segmentação por regiões não-homogêneas, a extração e normalização dos vetores de características e as técnicas de classificação por modelos estatísticos em *Bayes* e *Bayes ingênuo*. O pós-processamento também é apresentado, com resultados da identificação, localização e quantificação de frutos/biomassa, na criação dos mapas de classe.

5.1.1. Resultados da etapa de segmentação por regiões não-homogêneas

O conjunto de algoritmos, escrito originalmente em C++ (DENG e MANJUNATH, 2001), foi recompilado e customizado na aplicação de funções e bibliotecas em *OpenCV*, para evitar super-segmentação atribuir a correlação de regiões J em objetos alvos para a distribuição de regiões e o seu reagrupamento. Os parâmetros necessários à execução do algoritmo após a compilação são: *limiar de quantização de cores* (270 entre 0 e 600), que corresponde ao número de cores usado na quantização; *número de escalas* (3 como inicial e 1 como final), que refina os detalhes de segmentação na imagem; *limiar de agrupamento de regiões* (0,1 até 0,7), que une regiões segmentadas com cores semelhantes.

Na figura 5.1, são mostradas três categorias de cenas em pomares. A primeira identifica a maior parte da árvore, em que o limiar de quantização foi reajustado a maiores

valores de pico para que a fusão de regiões com mesma tonalidade de cores entre colmos, ramos, galhos e solo fosse evitada (segmentação não-homogênea). A segunda denota detalhes em determinados conjuntos nas cenas de pomares, excluindo regiões mais escuras do restante da cena, segmentando as irregularidades de cada folha e as anormalidades de tons no próprio fruto, possibilitando posterior análise de doenças características de laranjas - estas regiões são úteis para descrever os objetos secundários dos modelos reais. A terceira categoria identifica a maior parte das árvores, porém com maior incidência da copa e regiões do céu - esta diferença denota que o dossel de cada árvore mantém especificidades próprias que os distinguem entre si, também relevantes como objetos secundários para os modelos reais.

Figura 5.1: Grupo de cenas de pomares originais (coluna 1), cores quantizadas (coluna 2) e segmentadas (coluna 3) - em RGB.

Os mesmos atributos foram associados às imagens em HSV, porém com valores diferentes, uma vez que as informações cromáticas das cenas são separadas pelos canais S e V, discriminando os padrões de segmentos sem ruídos.

Pode-se observar na figura 5.2, que as cenas com foco em determinadas partes do dossel mantêm proporção de níveis das regiões J para com os segmentos pretendidos, considerando até detalhes dos frutos. Ainda, as cenas apresentam distribuição espacial passíveis de super-segmentação. Logo, a aquisição de imagens é readequada quanto à

distância focal da câmera, para se obter distribuições dos padrões pretendidos em toda a cena, integradas em maior escala. Isso resulta em cenas menos esparsas, com menos padrões para as classes pretendidas, viabilizando menor tempo de processamento durante a segmentação, mas também com menos detalhes para compor os objetos de modelos reais.

Figura 5.2: Grupo de cenas de pomares originais (coluna 1), cores quantizadas (coluna 2) e segmentadas (coluna 3) - em HSV.

Nas imagens em HSV, torna-se mais flexível o agrupamento de segmentos com maior tonalidade (sombra) com os segmentos de maior incidência de luz - para o canal H, constituindo uma classe de padrões pretendida ao objeto fruto; os demais segmentos, alocados geometricamente na imagem, por desvios laterais e superiores são relacionados à segunda classe de padrões (ramos, galhos e folhas).

Na figura 5.3, para o caso de aquisição de cenas com orientação paralela às fileiras de cultivo, as regiões quantizadas são pré-processadas de forma não homogênea, com realce em regiões de mesma tonalidade de cores, e que devem ser atribuídos à mesma classe, com compensação empírica do reajuste do limiar de agrupamento de regiões (0,5 até 0,7) e o número de escalas (2 até 1). Esta modificação auxilia no equilíbrio de regiões de interesse em imagens com formato geométrico de polígonos à esquerda, à direita e centro - para delimitar a

homogeneidade das fileiras, e as fronteiras destas regiões são redimensionadas com relativa redução de ruídos.

Figura 5.3: Grupo de cenas de fileiras de cultivo (coluna 1), cores quantizadas (coluna 2) e segmentadas (coluna 3) - em RGB.

Nas cenas naturais das fileiras de cultivo em HSV, mostradas na figura 5.4, observa-se que a disparidade entre as regiões que denotam solo, sombras e oclusões de partes das copas das laranjeiras dificultam a separação das regiões J para tornar as classes pretendidas homogêneas, mas o solo entre as linhas de plantio é delimitado pela regularidade de regiões durante a quantização de cores, tornando a aplicação neste ponto, viável de ser aplicada.

A partir da quantização de cores dada pela filtragem de grupo de pares de *pixels*, a primeira etapa do algoritmo não supervisionado (JSEG) conseguiu dividir as regiões não homogêneas das imagens. Experimentalmente, a partir destes valores, os reajustes dos parâmetros de limiar de agrupamento de regiões e o número de escalas na fusão de regiões devem ser aplicados para cada caso de aquisição, atingindo a baixa equivalência de *pixels*, resultando numa distribuição espacial menos densa, simples e com os padrões apropriados, para que os objetos pretendidos dos modelos reais sejam agrupados.

Observa-se também que, para os conjuntos de cenas dos dosséis completos, o algoritmo de segmentação não homogênea identifica com maior precisão, regiões que apresentam maior proximidade de tons de cor e textura, tanto em RGB quanto em HSV.

Figura 5.4: Grupo de cenas de fileiras de cultivo (coluna 1), cores quantizadas (coluna 2) e segmentadas (coluna 3) - em HSV.

5.1.2. Resultados da etapa de extração e normalização de características

Nas figuras 5.5, 5.6, 5.7, 5.8, inicialmente têm-se os resultados da interpolação linear (redução da dimensionalidade com agrupamento de regiões homogêneas), seguidos dos histogramas nos espaços de cores RGB e HSV pela etapa de quantização de cores na segmentação das imagens, que denotam a aplicação para as demais cenas (com orientação da câmera ortogonal, paralela e diagonal) dos conjuntos de treinamento – proporção de aproximadamente 20:1 do conjunto treinado em 50% da base de dados total.

A aplicação da PCA é feita inicialmente na extração dos autovetores da matriz de covariância - a média dos vetores de entrada em um vetor linha. Pela diferença de cada vetor média, encontra-se um padrão de dimensões da matriz de covariância. Em seguida, os autovetores são recalculados e os autovalores são definidos na diagonal principal da matriz resultante, normalizando enfim as dimensões dos vetores de características das imagens de entrada no conjunto de treinamento. A variação vertical na interpolação linear de segmentação é dada entre $0,50m$ - $4,50m$ e a variação horizontal em $1,0m$ - $6,0m$.

Os histogramas foram obtidos no modelo de cor RGB, quantizado pelas regiões não homogêneas durante a primeira etapa de segmentação do algoritmo JSEG. Estes histogramas ilustram a representação gráfica em barras verticais da intensidade dos segmentos com mesma equivalência de *pixels* nas regiões quantizadas, ou seja, a quantidade de dimensões não

normalizadas é dada pelo eixo das ordenadas, enquanto a intensidade do nível de cinza em cada região é dada pelo eixo das abscissas.

Figura 5.5: Histograma e interpolação linear de contorno para cena com linhas de plantio, em RGB.

Figura 5.6: Histograma e interpolação linear de contorno para cena com detalhes do pomar, em RGB.

Figura 5.7: Histograma e interpolação linear de contorno para cena com linhas de plantio, em HSV.

Figura 5.8: Histograma e interpolação linear de contorno para cena com detalhes do pomar, em HSV.

Na figura 5.6, observa-se que a equivalência de *pixels* é maior para a tonalidade entre alaranjado e amarelo (maior intensidade de nível de cinza), que caracterizam as laranjas, e em menor grau, os demais itens da cena, como folhas e galhos, devido à não homogeneidade entre estas regiões. Quanto menor o número de dimensões na representação das regiões, menores são as chances de redundância de dados para que estes sejam normalizados pela PCA, otimizando o tempo de processamento. Na figura 5.8, reamostrada no espaço de cores HSV, da mesma forma que para o caso RGB, há maior incidência de equivalência de *pixels* entre os segmentos correspondentes aos maiores níveis de cinza da quantização (maior barra – menor quantidade de dimensões para maior nível de cinza), logo, as laranjas são agrupadas em regiões adjacentes, tornando-as homogêneas, e distintas das demais regiões adjacentes, que contemplam as folhas, ramos e galhos. Em ambos os casos, a interpolação linear de segmentação mostra a relação estimada de agrupamento de regiões homogêneas, sem considerar as delimitações das classes pretendidas.

Nos casos das imagens de cenas das linhas de plantio, nas figuras 5.5 e 5.7, os segmentos atendem a maior parte do solo até o horizonte, e as copas das árvores delimitam a relação de proporção na etapa de quantização de cores, com regiões não homogêneas. Para as regiões de baixa densidade de *pixels*, na vegetação rasteira e nos picos das folhas, há maior intensidade de nível de cinza, identificando homogeneidade acentuada nestas regiões. Porém, nas regiões onde há maior disparidade heterogênea entre cores e texturas, consequentemente, o número de regiões quantizadas e segmentadas é maior, dada a sua não homogeneidade.

Trabalhar com valores altos e redundantes é inviável pelo tempo de processamento e resposta, e compromete também a recorrência no armazenamento de dados, sendo necessário aplicar a PCA, com a finalidade de comprimir os dados mais significativos e eliminar a repetitividade destes, normalizando os vetores de características que são usados como dados de entrada na classificação estatística. Assim, são usados percentuais (10%, 20%, 30%, 40%, 50%, 75% e 100%) para comparar a quantidade de dimensões distribuídas após a PCA.

A distribuição dos vetores de características às classes de pomares no espaço de cores RGB atende a aproximações entre as componentes das classes: **Solo e vegetação rasteira e Copas e linearidade**, para os conjuntos entre 10% a 50%. Os vetores de características são maioria na segunda classe para todas as percentagens, uma vez que nas cenas analisadas nesta abordagem apresentam mais regiões das copas das árvores, como as linhas de plantio nas laterais e o céu na parte superior, como é mostrado na tabela 5.1. Os vetores de características em HSV denotam maioria na primeira classe devido ao mesmo comportamento no caso RGB, mas para as percentagens 75% e 100%, a diferença entre a quantidade total de vetores em

relação às percentagens menores, aumenta, dada a concentração dos vetores quando a região de interesse da primeira classe é limiarizada nos canais H, S e V deste espaço de cores.

Tabela 5.1: Distribuição dos vetores de características às classes de Pomares em RGB e HSV.

Pomares (RGB)			
%	Solo e vegetação rasteira	Copas e linearidade	Total
10	3768	4128	7896
20	3876	4024	7900
30	3900	4054	7954
40	3923	4067	7990
50	3941	4154	8095
75	4001	4244	8245
100	4056	4401	8457

Pomares (HSV)			
%	Solo e vegetação rasteira	Copas e linearidade	Total
10	3770	4132	7902
20	3789	4126	7915
30	3800	4154	7954
40	3832	4197	8029
50	3845	4210	8055
75	3890	4249	8139
100	3916	4414	8330

No caso das cenas de detalhes dos pomares, para localização dos frutos, a distribuição dos vetores de características nos dois casos RGB e HSV mostra quantidades superiores para a classe **Folha, ramos e galhos**. Os objetos associados a esta classe são dispostos em toda a imagem, dificultando a associação dos frutos, à medida que a quantidade de elementos dos conjuntos aumenta. No modelo de cores RGB, para os conjuntos 50%, 75% e 100% a quantidade de vetores relacionada com a classe **Frutos** é superior aos correspondentes em HSV, dada a não homogeneidade de elementos de cores compostas em ambos. A distribuição dos vetores de características nos dois casos RGB/HSV é mostrada na tabela 5.2.

Tabela 5.2: Distribuição dos vetores de características às classes na localização de frutos em RGB e HSV.

Localização de frutos (RGB)				
%	Frutos	Folhas, ramos e galhos	Céu e solo	Total
10	1873	4057	309	6239
20	1903	4383	357	6643
30	1933	4383	377	6693
40	1988	4393	402	6783
50	2023	4414	408	6845
75	2094	4554	465	7113
100	2100	4737	489	7326

Localização de frutos (HSV)				
%	Frutos	Folhas, ramos e galhos	Céu e solo	Total
10	1359	5551	290	7200
20	1400	5528	306	7234
30	1422	5564	355	7341
40	1459	5545	384	7388
50	1468	5579	403	7450
75	1493	5586	452	7531
100	1577	5976	491	8044

Feita a normalização nos conjuntos de treinamento, os conjuntos de teste também foram normalizados pela mediana das dimensões para que a validação apresentasse dados paramétricos de mesma unidade, através da média e do desvio padrão das distâncias.

Nos resultados da distribuição dos vetores, nota-se que as características aumentam com baixa razão entre 10%, 20%, 30%, 40% e 50%, e entre 75% e 100% as taxas de crescimento são maiores. As taxas de acerto mantêm então, semelhança entre os conjuntos.

Os gráficos das figuras 5.9, 5.10, 5.11, 5.12 mostram a quantidade de dimensões para cada conjunto em 10%, 20%, 30%, 40%, 50%, 75% e 100% às duas abordagens nos espaços de cores RGB e HSV.

Figura 5.9: Quantidade de dimensões a cada conjunto - linhas de plantio RGB.

Figura 5.10: Quantidade de dimensões a cada conjunto - linhas de plantio HSV.

Figura 5.11: Quantidade de dimensões a cada conjunto – laranja RGB.

Figura 5.12: Quantidade de dimensões a cada conjunto – laranja HSV.

5.1.3. Resultados da etapa de reconhecimento de padrões por modelos *Bayesianos*

A classificação das probabilidades *a priori* estimadas às cenas de fileiras de cultivo denotam maior incidência na classe **Solo e vegetação rasteira** e nas aquisições lateral direita e esquerda, sendo que os índices de cor e textura são pouco variáveis, dividindo as regiões de interesse para esta classe. Na segunda classe **Copas e linearidade**, a textura e variação de cor não são intensas, ocasionando regularidades de regiões homogêneas e diminuindo a incerteza da classificação, para as cenas em RGB. O grau de incerteza nas imagens em HSV para a primeira classe é menor, sendo que estas regiões apresentam baixa taxa de falsos negativos, ao contrário do que ocorre com o espaço de cores RGB, em que a segunda classe denota maiores taxas de acerto.

A probabilidade *a priori* estimadas às cenas ortogonais (frontais) às laranjeiras dos conjuntos de treinamento denota maior estimativa da classe **Frutos**, uma vez que irregularidades de textura e cor nestes objetos não são super-segmentadas, apresentando regiões homogêneas e distintas. A classe **Folhas, ramos e galhos** tendem a apresentar maior quantidade de regiões nos segmentos, aumentando o grau de incerteza. A taxa de acerto é maior, para a classificação da primeira classe, em HSV (conjuntos em 30%, 40% e 50% que usam a quantidade crescente de vetores e dimensões para a determinação da PDFc), e em

RGB a segunda classe é classificada como a primeira, em muitos casos, apresentando maiores taxas de falsos negativos, mas diretamente proporcional ao aumento do conjunto de treinamento. As tabelas 5.3 e 5.4 mostram as probabilidades *a priori* estimadas dos conjuntos de treinamento para os dois casos.

Tabela 5.3: Probabilidade *a priori* estimadas dos conjuntos de treinamento de pomares.

Linhas de plantio de pomares								
Espaço de cores	Classes	10%	20%	30%	40%	50%	75%	100%
RGB	Classe1	0,4129	0,4273	0,3128	0,4112	0,4223	0,4122	0,4187
	Classe 2	0,5871	0,5727	0,6872	0,5888	0,5777	0,5878	0,5813
HSV	Classe 1	0,3593	0,4544	0,4384	0,5209	0,5232	0,7733	0,8274
	Classe 2	0,6407	0,5456	0,5616	0,4791	0,4768	0,2267	0,1726

Tabela 5.4: Probabilidade *a priori* estimadas dos conjuntos de treinamento de laranjas.

Localização (laranjas)								
Espaço de cores	Classes	10%	20%	30%	40%	50%	75%	100%
RGB	Classe 1	0,1324	0,1745	0,1234	0,2213	0,3943	0,3743	0,2485
	Classe 2	0,8637	0,8211	0,8716	0,7733	0,5983	0,6233	0,7476
	Classe 3	0,0039	0,0044	0,0050	0,0054	0,0074	0,0024	0,0039
HSV	Classe 1	0,1327	0,1745	0,3535	0,3613	0,3643	0,1452	0,1346
	Classe 2	0,8640	0,8191	0,6397	0,6331	0,6259	0,8460	0,8620
	Classe 3	0,0033	0,0064	0,0068	0,0056	0,0098	0,0088	0,0034

Os gráficos a seguir (figuras 5.13, 5.14, 5.15, 5.16) apresentam os parâmetros distribuídos em função da menor razão na mistura dos dados e na estimativa dos vetores de características dos conjuntos de treinamento para cada percentual, espaço de cor e abordagens de orientação da câmera na aquisição.

As linhas vermelha (*Bayes*) e azul (*Bayes ingênuo*) representam a razão da estimativa (eixo das abscissas), isto é, o quão variam os parâmetros distribuídos alvos para a classificação, a medida que aumentam o número de vetores parametrizados - classes de entrada (eixo das ordenadas). Quanto menor a razão da estimativa (entre positivo e negativo), maior a probabilidade da taxa de acerto daquela classe ser devidamente classificada. Se a razão da estimativa aumentar, maior também é a incerteza na classificação das classes pretendidas.

A razão da estimativa funciona da seguinte forma: se a variação tender para a esquerda (faixa negativa), a razão classifica os padrões de classe como falsos negativos (folhas, ramos e galhos não classificados como a biomassa do dossel), se a variação tender para a direita, a

razão classifica os padrões de classe como falsos positivos (folhas, ramos e galhos classificados como frutos). A faixa absoluta entre negativo e positivo é de 100 pontos. Nas classificações a seguir, figuras 5.13, 5.14, 5.15, 5.16, observa-se que a variação é entre -5 e +5 (10 pontos), provendo uma estimativa de 90% de taxa de acerto (cada qual com implicações e variações mais aproximadas).

Na figura 5.13, o classificador *Bayes* apresenta baixa variação da razão probabilística dos parâmetros classificados, comparados ao modelo ingênuo. O percentual da taxa de acerto (*Bayes*) é de 96,0%, com variação de -2/+2 pontos (4%) de erro entre falsos positivos e negativos; o percentual da taxa de acerto (*Bayes* ingênuo) é de 94,0%, com variação de -3/+3 pontos (6%) de erro entre falsos positivos e negativos.

Figura 5.13: Parâmetros à mistura do treinamento – Linhas de plantio RGB.

Da mesma forma, na figura 5.14, a razão da estimativa em relação ao número de vetores é menor para o classificador *Bayes*, no espaço de cores HSV. O percentual da taxa de acerto (*Bayes*) é de 92,0%, com variação de -4/+4 pontos (8%) de erro entre falsos positivos e negativos; o percentual da taxa de acerto (*Bayes* ingênuo) é de 90,0%, com variação de -5/+5 pontos (10%) de erro entre falsos positivos e negativos. Em comparação com o caso RGB, os índices de probabilidade apresentam melhores taxas de acerto neste espaço de cores, uma vez que a PDF e a distribuição normal associam os objetos em suas respectivas classes com

menor grau de incerteza, não sendo necessário atribuir correções de probabilidade em parâmetros independentes, como é o caso do *Bayes ingênuo*.

Figura 5.14: Parâmetros à mistura do treinamento – Linhas de plantio HSV.

Nas figuras 5.15 e 5.16, os melhores resultados foram obtidos com o classificador *Bayes ingênuo*, apresentando menor razão de estimativa em relação ao número de componentes analisadas. No espaço de cores RGB, a estimativa no reconhecimento dos objetos relacionados a primeira classe é dada pela PDF de cada vetor, corrigindo os valores atuais pela esperança de cada área não correspondida à respectiva classe. No espaço de cores HSV, a classificação da primeira classe apresenta compensação da taxa de acerto, para margens menores da razão de estimativa, sendo que este permite a correção dos próximos resultados pela aproximação das estimativas *a priori*, na PDF de cada vetor.

Na figura 5.15, o percentual da taxa de acerto (*Bayes*) é de 90,0%, com variação de -5/+5 pontos (10%) de erro entre falsos positivos e negativos; o percentual da taxa de acerto (*Bayes ingênuo*) é de 96,0%, com variação de -2/+2 pontos (4%) de erro entre falsos positivos e negativos. E na figura 5.16, o percentual da taxa de acerto (*Bayes*) é de 93%, com variação de -3,5/+3,5 pontos (7%) de erro entre falsos positivos e negativos; o percentual da taxa de acerto (*Bayes ingênuo*) é de 94%, com variação de -3/+3 pontos (6%) de erro entre falsos positivos e negativos.

Figura 5.15: Parâmetros à mistura do treinamento – Pomares RGB.

Figura 5.16: Parâmetros à mistura do treinamento – Pomares HSV.

5.1.4. Resultados da etapa de pós-processamento na criação de mapas de classe

Os mapas de classe representam a formação de regiões classificadas em sua maioria pelas classes pretendidas das regiões de interesse, com os dois espaços de cores amostrados, e apenas as imagens adquiridas pela orientação da câmera ortogonal são consideradas. As técnicas usadas foram customizadas do *Image Processing Toolbox* (MATLAB).

Os mapas de classe são processados, uma vez que a representação pelo preenchimento de área (*floodfill*) agrega apenas as regiões sólidas que são quantificadas. Inicialmente, é realizada uma conversão em níveis de cinza da imagem, para limiarizar as regiões que serão contornadas. Em seguida, para a determinação dos rótulos dos elementos conectados, devem-se excluir objetos com área maior a 200 ou 300 *pixels*, dependendo da distância focal. Logo, é necessário identificar cada elemento menor que este limiar, e calcular as propriedades destes objetos, tais como área, centróide, e a região de contorno. Com isso, os objetos que apresentarem áreas próximas à geometria circular serão rotulados e quantificados como frutos.

Para a determinação das métricas e delimitação dos objetos passíveis a cultura de laranja, a segmentação baseada em representação de grafos (GONZALEZ & WOODS, 2007) foi aplicada. Esta provê a relação de adjacência A entre os valores binários dos *pixels*, e suas respectivas posições, destacando as propriedades locais geométricas da imagem. O conjunto de *pixels* $A(p)$ representa ao grupamento de *pixels* adjacentes ao *pixel* p em relação a A , ou seja:

$$q \in A(p) = (p, q) \in A \quad (38)$$

Assim, a relação de adjacência provê a definição de um grafo $G = (D, A)$ para a imagem, onde D é o agrupamento de *pixels*, e π uma sequência de *pixels* adjacentes $(p_1, p_2, \dots, p_n)$, para $(p_i, p_{i+1}) \in A, i = 1, 2, \dots, n-1$. Logo, a formação do grafo atende ao seguinte sistema.

$$\begin{cases} (p, q) \in A, d(p, q) \leq p \\ (p, q) \in A, (q - p) \in [(-1, 1), (1, -1)] \\ (p, q) \in A, |x_p - x_q| + |y_p - y_q| \leq 1 \rightarrow |f(p) - f(q)| \leq l \end{cases} \quad (39)$$

Com isso, para a relação simétrica da delimitação das regiões, sem variações de translação durante o agrupamento dos *pixels*, são usadas vizinhanças de *pixel* para três situações: *Vizinhança-4*: $p = 1$; *Vizinhança-8*: $p = \sqrt{2}$; *Dispersão de pixels vizinhos*: $p = \sqrt{5}$.

No primeiro caso, áreas correspondentes às regiões pequenas, como frutos parcialmente ocultos (laranjas) de textura e cor equivalentes às folhas são excluídas. No segundo caso, os elementos de interesse já são agrupados em sua totalidade, quando ocupam segmentos representando as formas passíveis de laranja. No terceiro caso, o agrupamento é feito para regiões que detectam dois ou mais segmentos de áreas passíveis a laranja.

Com esta formulação, é possível realizar a busca por regiões de diversos tamanhos, bem como, no caso de laranjas, se os segmentos correspondem à geometria circular. A quantificação é realizada também para o total de regiões de interesse agrupadas na imagem. A segmentação baseada em grafos é tratada como etapa de pós-processamento posterior à criação dos mapas de classe pelos classificadores estatísticos, uma vez que com as regiões devidamente classificadas, torna-se viável a aplicação do algoritmo de conexão das componentes principais de saída. Para os casos RGB e HSV são apresentadas as imagens nos seus respectivos mapas de classe, o pré-processamento para a limiarização com áreas menores que 100 e maiores que 300, as métricas de aproximação geométrica para a detecção de objetos circulares e as regiões de contorno com os centróides de cada objeto.

Na figura 5.17, as imagens na linha (a) representam os mapas de classe baseados em *Bayes* ingênuo, considerando as tonalidades entre alaranjado e amarelo como da classe *frutos* e as demais tonalidades da biomassa, da classe *folhas, ramos e galhos*, em RGB à esquerda e em HSV à direita (verifica-se que a classificação nas duas classes pretendidas em RGB é feita com maior exatidão, discriminando maior número dos elementos da biomassa - para a análise qualitativa, já na classificação pelo mapa de classe em HSV, há pouca relação da classe *folhas, ramos e galhos*, e maior eficiência na discriminação da classe *frutos*, - para a análise quantitativa); nas imagens da linha (b) estão os resultados da limiarização de áreas menores que 100 e maiores 300, e o gradiente de contorno para a determinação da métrica de aproximação geométrica em 1,0, que denota o perímetro gradiente máximo para um círculo. Quanto mais próxima da métrica em 1,0, mais discriminante é a equivalência de determinado fruto (laranja) ser identificado por um círculo (verifica-se que alguns elementos da biomassa são calculados com métricas inferiores a 0,50 em RGB, o que não acontece em HSV, com praticamente todos os elementos da classe *frutos* identificados); as imagens na linha (c) denotam a determinação da região de contorno e dos centróides de áreas para a localização de frutos (como na imagem em RGB a heterogeneidade de regiões é maior, os centróides nesse caso, identificam a localização dos elementos da biomassa, e da classe *frutos*, e na imagem em HSV, a concentração dos elementos da classe *frutos* é feita de forma mais homogênea, para a sua quantificação).

Figura 5.17: Quantificação 01 – (a) mapas de classe por *Bayes ingênuo*, (b) métricas circulares próximas do limiar geométrico 1,0, (c) áreas e centróides para a localização de frutos (RGB – esquerda; HSV – direita).

Na figura 5.18, os mapas de classe representados nas imagens na linha (a), consideram uma maior dispersão de regiões classificadas tanto para a classe *frutos* quanto para a classe *folhas, ramos e galhos*, em RGB, porém em HSV, há pouca relação da classe *folhas, ramos e galhos*, e maior identificação da classe *frutos* na quantificação de citros; na linha (b) o gradiente de contorno para a determinação da métrica de aproximação circular, denota que em alguns elementos da biomassa são calculados com métrica inferior a 0,50 em RGB, o que não acontece em HSV, com os elementos da classe *frutos* identificados; na linha (c), a região de

contorno e os centróides de áreas para a localização de frutos são representadas, em RGB a heterogeneidade de regiões é maior, e os centróides nesse caso, identificam a localização dos elementos da biomassa, e da classe *frutos*, e na imagem em HSV, a concentração dos elementos da classe *frutos* é feita de forma mais homogênea, para a sua quantificação.

Figura 5.18: Quantificação 02 – (a) mapas de classe por *Bayes ingênuo*, (b) métricas circulares próximas do limiar geométrico 1,0, (c) áreas e centróides para a localização de frutos (RGB – esquerda; HSV – direita).

No caso da figura 5.19, a disparidade entre os elementos da biomassa com os frutos é notavelmente maior pela oclusão entre os objetos da cena, em RGB e HSV, como verificado pelos mapas de classe nas imagens na linha (a); em (b) o gradiente de contorno discrimina

vários elementos da biomassa com métrica inferior a 0,50 em RGB, e em HSV, os elementos da classe *frutos* são identificados com maior exatidão; em (c) a região de contorno e dos centróides de áreas para a localização de frutos, em RGB, apresenta maior heterogeneidade de regiões, e os centróides nesse caso, identificam a localização dos elementos da biomassa, e da classe *frutos*, e na imagem em HSV, a concentração dos elementos da classe *frutos* é feita de forma mais homogênea, para a sua quantificação.

Figura 5.19: Quantificação 03 – (a) mapas de classe por *Bayes ingênuo*, (b) métricas circulares próximas do limiar geométrico 1,0, (c) áreas e centróides para a localização de frutos (RGB – esquerda; HSV – direita).

No **APÊNDICE A**, são apresentados outros resultados para o processamento de imagens (quantização de cores e distribuição espacial), e a construção dos mapas de classe em *Bayes ingênuo*, assim como as métricas e determinação dos centróides de área.

5.2. Resultados em visão computacional aplicada a imagens térmicas

Na abordagem de visão computacional aplicada a imagens térmicas, são apresentados os resultados obtidos na etapa de segmentação baseada em regiões (*Watershed*), e da etapa de classificação estatística por modelos de Misturas de *Gaussianas* (*MoG*), na localização de regiões passíveis de doença no exterior do fruto.

5.2.1. Resultados da etapa de segmentação de imagens térmicas por *Watershed*

Como no método proposto para o tratamento de imagens térmicas é objetivada a caracterização de possíveis lesões na superfície do fruto, é relevante apresentar alguns detalhes sobre tais doenças:

a) Cancro cítrico: Causado pela bactéria *Xanthomonas citri subsp. citri*, afeta todas as espécies e variedades de citros, principalmente a valência. As lesões de cancro cítrico apresentam a formação de anéis concêntricos e rachaduras na casca, resultado do crescimento da lesão e da necrose do tecido afetado.

b) Leprose: Atinge, principalmente, laranjeiras doces. Provocada pelo vírus *Citrus leprosis virus* (CiLV) e transmitido pelo ácaro *Brevipalpus phoenicis*, pode causar perdas de produção e redução da vida útil da árvore debilitada. Nos frutos, as lesões geralmente são rasas e necróticas, distribuídas por toda a superfície. Em período de maturação, observa-se uma área de contorno amarelo em torno da lesão e, à medida que o fruto amadurece, as lesões na superfície se escurecem gradativamente.

Com isso, o processo de segmentação baseada em regiões, discrimina os segmentos pretendidos através do cálculo do gradiente de contorno para todos os *pixels* da imagem, principalmente nos locais da cena com incidência estimada de manchas nas superfícies dos frutos, onde cada região apresenta mínimos e máximos gradientes, que são processados com a etapa do algoritmo responsável pela divisão de águas (*Watershed*).

Para o caso da primeira cena, figura 5.20, o detalhe entre as laranjas centrais, de cada cena, denota uma saliência na superfície destas. A aplicação do algoritmo provê sua segmentação para posterior análise das possíveis causas de lesão, distinguindo as duas referidas doenças das demais, com outras características.

Figura 5.20: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5, em imagem RGB, com detalhes da deformação nos frutos centrais.

Para a o pré-processamento em gradiente de contorno e segmentação por *Sobel*, é necessário linearizar as texturas de cada imagem termográfica, apresentadas na figura 5.21, como padrão de informação de entrada. As diferenças nas tonalidades de cada paleta denotam que o índice de radiação refletida se mostra homogêneo, mesmo com variações climáticas, alterando níveis de iluminação *outdoor*, durante a aquisição.

Figura 5.21: Resultados das imagens termográficas das cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5.

O primeiro passo na aplicação do algoritmo *watershed* é pré-processar a imagem em níveis de cinza (figura 5.22), por gradiente de contorno e segmentação por *Sobel*, como mostrado na figura 5.23. Os elementos mais escuros são os alvos para a segmentação, dentro da cena e especificamente sobre os frutos.

Figura 5.22: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 em níveis de cinza.

Figura 5.23: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 segmentadas por gradiente de contorno e segmentação por *Sobel*.

Em seguida, para o processamento de marcadores em primeiro plano (*foreground*), por reconstrução morfológica, é aplicado a magnitude de gradiente da transformada de *watershed* (*l*-RGB), para evitar supersegmentação, mostrado na figura 5.24.

Figura 5.24: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com a magnitude de gradiente da transformada de *watershed*.

Nas imagens das figuras 5.25, 5.26, 5.27 e 5.28 são aplicadas técnicas de morfologia matemática para o processamento de marcadores em primeiro e em segundo plano (*foreground* e *background*), com separação dos pixels que não fazem parte de nenhum objeto.

Figura 5.25: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com aplicação de erosão seguida de dilatação (abertura morfológica).

Figura 5.26: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com aplicação de erosão seguida de reconstrução morfológica.

Figura 5.27: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com aplicação de remoção de manchas escuras (fechamento morfológico).

Por fim, as técnicas de reconstrução de regiões são aplicadas nas imagens a seguir, para reconstruir os modelos pós aplicação das técnicas morfológicas, sem afetar diretamente

as formas gerais dos objetos, mas direcionando o complemento de marcadores onde foram detectados segmentos com temperaturas acima da proporção geral da cena.

Figura 5.28: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com aplicação das técnicas de reconstrução de regiões.

O passo seguinte é a calibração do gradiente de contorno para a superposição da imagem com as localizações dos marcadores dos elementos de primeiro e segundo planos, que apresenta os marcadores dos segmentos alvos avaliados no primeiro plano (figura 5.29).

Figura 5.29: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com aplicação dos marcadores de máximo regional nos elementos do primeiro plano.

Para ressaltar o cálculo dos marcadores de máximo regional nos elementos do primeiro plano, impostos na imagem original, são aplicadas técnicas de sobreposição e

refinamento dos objetos de interesse, que são ocultados e sombreados, não apresentando bom resultado na segmentação final. Ainda, os marcadores de primeiro plano em alguns objetos se sobrepõem às bordas destes, necessitando da retirada destas bordas nas máscaras dos marcadores e, em seguida, reduzi-los apenas por uma fração (figuras 5.30 e 5.31).

Figura 5.30: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com regiões de máxima sobrepostos na imagem original.

Figura 5.31: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com regiões de máxima modificados para refinamento dos elementos de primeiro plano, sobrepostos na imagem original.

O passo final é a aplicação da transformada de *watershed*, modificando a função de segmentação para as regiões de borda entre os segmentos contornados (figura 5.32).

Figura 5.32: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com limiarização de exclusão dos marcadores do segundo plano.

Os *pixels* do segundo plano estão em preto, mas idealmente não é adequado deixar marcadores em *background* próximos das bordas dos objetos de interesse à segmentação. As linhas de cume/crista em cada região de interesse são, então, segmentadas pela transformada da distância, com auxílio da técnica *skeleton* como morfologia matemática (figura 5.33).

Figura 5.33: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com morfologia matemática *skeleton*.

Os marcadores do primeiro plano são sobrepostos na imagem original, bem como os limites/bordas dos objetos (figura 5.34).

Figura 5.34: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com sobreposição dos marcadores do primeiro plano na imagem original.

Em seguida, a visualização abaixo demonstra como os locais dos marcadores de primeiro e segundo plano afetam o resultado. Em pares localizados, objetos escuros parcialmente oclusos são fundidos com seu vizinho de maior intensidade (canal), porque esses não têm marcadores de primeiro plano (figura 5.35).

Figura 5.35: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com a matriz rótulo colorida da transformada de *watershed* na identificação das regiões de interesse à classificação.

Finalmente, é aplicada a sobreposição na imagem original em transparência de cores, para comparação com os elementos de primeiro plano, segmentados anteriormente. Tais sobreposições identificam quais regiões são passíveis de apresentarem irregularidades nas superfícies dos frutos, as quais são classificadas pelas técnicas de misturas *Gaussianas* (figura 5.36).

Figura 5.36: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 com sobreposição de transparência de cores na imagem original.

5.2.2. Resultados da etapa de classificação estatística por *MoG*

Para cada região pretendida, foram extraídos os *pixels* correspondentes pós morfologia como parâmetros de entrada ao conjunto de dados de treinamento, o algoritmo realiza a combinação de forma arbitrária na média e desvio padrão, para que a convergência aumente.

O resultado final denota que a convergência é tão próxima do valor de máximo global, dadas as características de resiliência do algoritmo.

Na figura 5.37, são demonstradas as equivalências entre as regiões sobrepostas processadas com as cenas naturais, registrando como parâmetros de entrada ao classificador por modelos de *MoG*.

a4

a5

b1

b2

Figura 5.37: Cenas naturais $a1$, $a2$, $a3$, $a4$, $a5$, $b1$, $b2$, $b3$, $b4$, $b5$ comparadas com as regiões de sobreposição, parametrizadas como entradas no classificador por modelos de mistura de *Gaussianas*.

Na cena natural $a1$, observa-se que a região sombreada interna de um dos frutos identifica uma 'irregularidade'. Através da classificação por modelos de mistura de *Gaussianas*, é passível sua correlação com uma deformação existente no fruto. Na cena natural $a2$, é notável a irregularidade na região superior, porém na mesma imagem, na região inferior, a demarcação que é inserida como entrada à classificação é confundida com um ramo/folha, provendo um falso positivo. Na cena natural $a3$ a deformação na superfície do fruto, na região lateral esquerda é identificada, na $a4$, as duas protuberâncias são relacionadas a variações de tons da intensidade na cor amarelo, também provendo um falso positivo. Na

cena *a5*, os dois frutos na mesma região são devidamente separados, e para o caso do fruto em período de colheita, existe uma saliência moderada na sua superfície.

Na cena natural *b1*, a região demarcada como irregularidade no fruto é confundida com a intensidade maior da cor amarela, na *b2*, o algoritmo valida sua segmentação, não identificando regiões passíveis de irregularidades, como um falso negativo. Nas cenas naturais *b3* e *b4* as regiões com irregularidades são devidamente segmentadas, e na cena *b5*, nas duas regiões analisadas, o algoritmo se mostrou robusto, removendo ruídos visuais de sombras nos dois casos, isolando-os como homogêneos.

Com os segmentos separados, estes são parametrizados para o cálculo das covariâncias globais, etapa inicial da mistura de *Gaussianas*.

A figura 5.38 denota a inicialização randômica e por agrupamento *k-means* na média (eixo das ordenadas) e desvio padrão (eixo das abscissas) dos segmentos alvo selecionados, em que as covariâncias encontradas são as covariâncias globais multiplicadas por $(1/k)$.

Figura 5.38: Inicialização randômica/arbitrária da média e desvio padrão para as covariâncias globais.

Para a cena natural *a1*, k é igual a 5 neste caso. Isso significa que o espalhamento da máxima-verossimilhança (*log-likelihood*) aponta não apenas para o segmento pretendido,

como outros possíveis elementos de primeiro plano com as mesmas características, auxiliando a investigação de outras áreas com manchas nas superfícies dos frutos. Na cena $a2$, $k = 2$, delimitando as regiões pretendidas dos frutos como segmentos-alvo classificados, em $a3$, $k = 3$, apenas uma região deveria ser classificada, e o gráfico mostra que para as populações das covariâncias globais, existe uma convergência na sua intersecção; nas cenas $a4$ ($k = 3$) e $a5$ ($k = 1$), dois casos em que o *k-means* necessita avaliar as populações com maior critério durante as iterações: no primeiro caso, duas regiões segmentadas são pretendidas na identificação de irregularidades, as interseções entre o espalhamento da máxima-verossimilhança apenas convergem para uma das regiões, enquanto que no segundo caso, como se trata da identificação da heterogeneidade entre dois frutos com períodos de maturação diferentes, o número de iterações para a convergência foi muito menor, mas inicialmente com a mesma dificuldade em analisar sua irregularidade no segmento.

Nas cenas naturais $b1$, $b2$, $b3$, $b4$, $b5$ o classificador foi prototipado/implementado a discriminar falsas regiões dentro dos segmentos-alvo, não representando irregularidades nos frutos, mas diferenças de tons de cor e textura, bem como a luminosidade refletida pelos frutos presentes. Assim, em $b1$ ($k = 3$), três incidências de convergência foram necessárias para que o classificador separasse a região na superfície do fruto como uma anomalia não relacional (não discretizada como deformação do fruto), na cena $b2$ ($k = 2$), o mesmo procedimento foi adotado, com menor número de agrupamentos, o que caracteriza a máxima-verossimilhança como sendo ativa nestes casos. Na cena $b3$ ($k = 3$), um problema durante a classificação foi relacionar a quantidade de agrupamentos e suas intersecções, com as características distintas de duas regiões presentes no mesmo segmento-alvo, sendo a primeira o reflexo da luminosidade no fruto e a segunda a mancha/deformação na superfície do mesmo. Todas as populações foram cruzadas e verificou-se que duas convergências apontaram para a mancha/deformação e uma com maior quantidade de iterações apontou para o reflexo da luminosidade. Na cena $b4$ ($k = 2$), o mesmo caso foi apresentado, como em $b3$, porém como a mancha/deformação é predominante no segmento-alvo, o espalhamento da máxima-verossimilhança convergiu para os dois agrupamentos, relacionando a deformação como uma irregularidade no segmento-alvo. Por fim, na cena $b5$ ($k = 3$), dois segmentos-alvo eram pretendidos na classificação, com regiões de reflexo de luminosidade, e os agrupamentos se mostraram confusos durante a convergência entre o espalhamento da máxima-verossimilhança, uma vez que o classificador era dimensionado para encontrar ou reflexo de luminosidade ou manchas/deformações, não apenas reflexos e mais de um segmento-alvo.

Após a convergência do algoritmo EM, em função das covariâncias encontradas, são mostradas na figura 5.39 as 10 cenas com seus respectivos centróides de convergência, sendo o eixo das ordenadas a população atual e o eixo das abscissas a população inicial:

- 101 iterações para *a1* (máxima-verossimilhança em 5 *clusters*/agrupamentos de regiões);
- 11 iterações para *a2* (máxima-verossimilhança em 2 *clusters*/agrupamentos de regiões);
- 25 iterações para *a3* (máxima-verossimilhança em 3 *clusters*/agrupamentos de regiões);
- 63 iterações para *a4* (máxima-verossimilhança em 3 *clusters*/agrupamentos de regiões);
- 4 iterações para *a5* (máxima-verossimilhança em 1 *cluster*/agrupamento de regiões);
- 120 iterações para *b1* (máxima-verossimilhança em 3 *clusters*/agrupamentos de regiões);
- 36 iterações para *b2* (máxima-verossimilhança em 2 *clusters*/agrupamentos de regiões);
- 55 iterações para *b3* (máxima-verossimilhança em 3 *clusters*/agrupamentos de regiões);
- 10 iterações para *b4* (máxima-verossimilhança em 2 *clusters*/agrupamentos de regiões);
- 20 iterações para *b5* (máxima-verossimilhança em 3 *clusters*/agrupamentos de regiões).

Figura 5.39: Agrupamentos/clusters das regiões classificadas, nas cenas a1, a2, a3, a4, a5, b1, b2, b3, b4, b5.

Os gráficos da figura 5.40 denotam a relação entre cada parte dos agrupamentos com a máxima probabilidade de ocorrerem. No eixo das ordenadas têm-se os valores das máximas verossimilhanças, que correspondem o quão estáveis e prováveis os agrupamentos podem acontecer; no eixo das abscissas têm-se a quantidade de agrupamentos iniciais, antes da

convergência. Quando a linha do gráfico torna-se linear e constante para um determinado valor de *log-likelihood*, naquele ponto o algoritmo converge para a quantidade de agrupamentos que os segmentos-alvos se intersectam, isto é, denota o conjunto de agrupamentos que minimizam a soma dos erros quadráticos (SSE - *sum of squared errors*), máxima verossimilhança pretendida. Valores mais negativos da SSE máxima-verossimilhança representam que cada observação pertence ao agrupamento mais próximo da média.

Figura 5.40: Linearidade da convergência da máxima-verossimilhança do segmento-alvo.

Para cada cena natural, a correspondência da SSE máxima verossimilhança com a convergência no(s) segmento(s)-alvo(s) é:

- Cena natural *a1*: SSE *log-likelihood* de ~ -4450 ;
- Cena natural *a2*: SSE *log-likelihood* de ~ -5345 ;
- Cena natural *a3*: SSE *log-likelihood* de ~ -3930 ;
- Cena natural *a4*: SSE *log-likelihood* de ~ -3920 ;
- Cena natural *a5*: SSE *log-likelihood* de ~ -5460 ;
- Cena natural *b1*: SSE *log-likelihood* de ~ -5345 ;
- Cena natural *b2*: SSE *log-likelihood* de ~ -4455 ;
- Cena natural *b3*: SSE *log-likelihood* de ~ -5345 ;
- Cena natural *b4*: SSE *log-likelihood* de ~ -5345 ;
- Cena natural *b5*: SSE *log-likelihood* de ~ -3910 .

Na figura 5.41, cada cena natural é correspondida com sua respectiva sobreposição da segmentação *Watershed*, e conseqüentemente, seus mapas de classe, demonstrando a

identificação/classificação dos segmentos-alvo pelo modelo de mistura de *Gaussianas* 'Expectation Maximization', usando o algoritmo de preenchimento de polígonos/inundação *floodfill* no MATLAB.

Figura 5.41: Cenas naturais a1, a2, a3, a4, a5, b1, b2, b3, b4, b5 pós classificação por modelos de mistura de *Gaussianas*. Na coluna esquerda têm-se as imagens termográficas de cada cena, com respectivamente, a sobreposição *Watershed* do processo de segmentação dos objetos-alvo (coluna central), e os resultados dos mapas de classe, relacionando os objetos-alvo com as regiões classificadas (coluna direita).

5.3. Resultados da estimação do volume de dosséis por sonares

Nas figuras 5.42, 5.43, 5.44, 5.45 e 5.46 são apresentadas cinco informações de características quantitativas, iniciando com o histograma, cuja distribuição das barras verticais denota a intensidade de *pixels* naquela região, seguida da área de contorno (imagens ao meio) e distribuição dos *pixels* em cada quadrante (quanto mais fria a cor, mais próximo é o objeto), e as distribuições linear e agrupada da superfície frontal, representada em três dimensões.

Figura 5.42: Cena 1: gráfico de intensidades pelo histograma (distribuição das barras indica a incidência de *pixels* naquela região); gráfico da área de contorno (quanto mais fria a cor, mais próximo é o objeto); gráfico da distribuição de *pixels* em cada ponto de leitura; gráficos de superfície e contorno (linear e total).

Figura 5.43: Cena 2: gráfico de intensidades pelo histograma (distribuição das barras indica a incidência de *pixels* naquela região); gráfico da área de contorno (quanto mais fria a cor, mais próximo é o objeto); gráfico da distribuição de *pixels* em cada ponto de leitura; gráficos de superfície e contorno (linear e total).

Figura 5.44: Cena 3: gráfico de intensidades pelo histograma (distribuição das barras indica a incidência de *pixels* naquela região); gráfico da área de contorno (quanto mais fria a cor, mais próximo é o objeto); gráfico da distribuição de *pixels* em cada ponto de leitura; gráficos de superfície e contorno (linear e total).

Figura 5.45: Cena 4: gráfico de intensidades pelo histograma (distribuição das barras indica a incidência de *pixels* naquela região); gráfico da área de contorno (quanto mais fria a cor, mais próximo é o objeto); gráfico da distribuição de *pixels* em cada ponto de leitura; gráficos de superfície e contorno (linear e total).

Figura 5.46: Cena 5: gráfico de intensidades pelo histograma (distribuição das barras indica a incidência de *pixels* naquela região); gráfico da área de contorno (quanto mais fria a cor, mais próximo é o objeto); gráfico da distribuição de *pixels* em cada ponto de leitura; gráficos de superfície e contorno (linear e total).

A análise das linhas e colunas individuais de cada imagem da matriz de distâncias retificadas apresenta informações sobre o perfil de cada linha e coluna que foi mapeada pelo sensor. Os perfis gerados podem ser usados para gerar traços que representam porções

aproximadas da árvore monitorada. A seguir são mostrados resultados de processamento das linhas da matriz de distâncias retificadas, geradas como descrito anteriormente. As linhas são denominadas de *séries* (perfis parciais), o eixo das abscissas representa o número de colunas (1 a 25) e o eixo das ordenadas representa as distâncias medidas em *cm* pelo sonar.

Cena natural 01:

Série 01

Série 02

Série 03

Série 04

Série 05

Série 06

Série 07

Série 08

Série 09

Série 10

Série 11

Série 12

Série 13

Série 14

Série 15

Série 16

Série 17

Série 18

Série 19

Série 20

Série 21

Série 22

Figura 5.47: Séries 01 à 25 da cena natural 1.

Na figura 5.48 é apresentado o gráfico de superfície de contorno, onde as tonalidades mais claras de verde representam distâncias maiores, e as mais escuras, as distâncias menores.

Figura 5.48: Gráfico da superfície de contorno para a cena natural 1 - cada célula ($n \times m$), representa 12088 pixels, correspondentes da cena natural em RGB/HSV (3664 x 2062).

Sabendo como é a distribuição de cada série/linha em toda a matriz, na figura 5.49 são identificadas todas as intersecções das 25 séries, em que visualmente, é perceptível o quão irregular é cada linha matricial da laranjeira, considerando pontos distintos entre frutos, ramos, galhos e folhas.

Figura 5.49: Gráfico de dispersão total, contendo as 25 séries, para a cena natural 1.

Quanto maior o número de séries, mais detalhes são apresentados na formação de cada árvore. Observa-se também que a variação com que cada matriz apresenta, em função de todas as suas 25 posições para linhas e 25 para colunas, é ocasionada pela proximidade do sensor ultrassônico e cada elemento refletido pela propagação de onda.

Ainda, na figura 5.50, é apresentada a sequência de séries tridimensionais de forma empilhada, considerando as maiores distâncias para tons de verde claro, e menores distâncias para tons de verde escuro.

Figura 5.50: Gráfico das 25 séries tridimensionais empilhadas para a cena natural 1.

Para as demais cenas naturais (02, 03, 04, 05), são mostradas as imagens dos gráficos de cada série para cada árvore, gráficos da superfície de contorno de cada árvore, gráficos de dispersão total de cada árvore, e os gráficos das 25 séries tridimensionais empilhadas para cada árvore.

Cena natural 02:

Série 03

Série 04

Série 05

Série 06

Série 07

Série 08

Série 09

Série 10

Série 11

Série 12

Série 13

Série 14

Série 15

Série 16

Série 17

Série 18

Figura 5.51: Séries 01 à 25 da cena natural 2.

Figura 5.52: Gráfico de dispersão total, contendo as 25 séries, para a cena natural 2.

Figura 5.53: Gráfico da superfície de contorno para a cena natural 2 - cada célula ($n \times m$), representa 12088 pixels, correspondentes da cena natural em RGB/HSV (3664 x 2062).

Figura 5.54: Gráfico das 25 séries tridimensionais empilhadas para a cena natural 2.

Cena natural 03:

Série 01

Série 02

Série 03

Série 04

Série 05

Série 06

Série 07

Série 08

Série 09

Série 10

Série 11

Série 12

Série 13

Série 14

Série 15

Série 16

Série 17

Série 18

Série 19

Série 20

Figura 5.55: Séries 01 à 25 da cena natural 3.

Figura 5.56: Gráfico de dispersão total, contendo as 25 séries, para a cena natural 3.

Figura 5.57: Gráfico da superfície de contorno para a cena natural 3 - - cada célula ($n \times m$), representa 12088 pixels, correspondentes da cena natural em RGB/HSV (3664 x 2062).

Figura 5.58: Gráfico das 25 séries tridimensionais empilhadas para a cena natural 3.

Cena natural 04:

Série 01

Série 02

Série 03

Série 04

Série 05

Série 06

Série 07

Série 08

Série 09

Série 10

Série 11

Série 12

Série 13

Série 14

Série 15

Série 16

Série 17

Série 18

Série 19

Série 20

Figura 5.59: Séries 01 à 25 da cena natural 4.

Figura 5.60: Gráfico de dispersão total, contendo as 25 séries, para a cena natural 4.

Figura 5.61: Gráfico da superfície de contorno para a cena natural 4 - cada célula ($n \times m$), representa 12088 pixels, correspondentes da cena natural em RGB/HSV (3664 x 2062).

Figura 5.62: Gráfico das 25 séries tridimensionais empilhadas para a cena natural 4.

Cena natural 05:

Série 01

Série 02

Série 03

Série 04

Série 05

Série 06

Série 07

Série 08

Série 09

Série 10

Série 11

Série 12

Série 13

Série 14

Série 15

Série 16

Série 17

Série 18

Série 19

Série 20

Figura 5.63: Séries 01 à 25 da cena natural 5.

Figura 5.64: Gráfico de dispersão total, contendo as 25 séries, para a cena natural 5.

Figura 5.65: Gráfico da superfície de contorno para a cena natural 5 - cada célula ($n \times m$), representa 12088 pixels, correspondentes da cena natural em RGB/HSV (3664 x 2062).

Figura 5.66: Gráfico das 25 séries tridimensionais empilhadas para a cena natural 5.

Utilizando-se uma aproximação polinomial de curva para os pontos gerados, pode-se construir fatias do modelo virtual da árvore. Essa estimativa é necessária para compor a cena natural de forma a organizar a linha de plantio, caracterizada pela equidistância entre cada árvore, e a percepção de elementos que influenciam de uma árvore em outra (figura 5.67).

Figura 5.67: Aproximação polinomial (linhas de tendência) das séries 01 até 25 da cena natural 1 (a), cena natural 2 (b), cena natural 3 (c), cena natural 4 (d), cena natural 5 (e).

A seguir são apresentadas todas as equações polinomiais para as linhas de tendência que formam os pontos gerados na construção das fatias/séries do modelo virtual da árvore, nas tabelas 5.5, 5.6, 5.7, 5.8, 5.9. Através da aproximação polinomial, é possível gerar a elipse pela curva da série da superfície, e a fatia do modelo virtual da copa da árvore representando as linha de 1 até 25, de n medidas. Tais resultados da formação gráfica do modelo virtual são usados como parâmetros de entrada para o classificador geral ponderado, que corresponde a associação/identificação do dossel comparado à imagem em RGB.

Cena natural 01:

Tabela 5.5: Equações polinomiais de cada série para a cena natural 01.

Séries	Equações polinomiais
s. 01	$y = 0,200x^2 - 6,541x + 121,6$
s. 02	$y = 0,170x^2 - 4,469x + 98,39$
s. 03	$y = 0,164x^2 - 6,054x + 114,2$
s. 04	$y = 0,003x^2 - 2,186x + 104,5$
s. 05	$y = 0,11x^2 - 3,96x + 57,72$
s. 06	$y = 1,32x^2 - 5,43x + 112,8$
s. 07	$y = 0,113x^2 - 3,696x + 55,58$
s. 08	$y = -0,136x^2 + 5,613x + 65,51$
s. 09	$y = -0,018x^2 + 0,745x + 45,90$
s. 10	$y = -0,031x^2 + 0,555x + 33,62$
s. 11	$y = -0,021x^2 + 0,545x + 11,62$
s. 12	$y = 0,039x^2 - 1,444x + 22,25$
s. 13	$y = 0,029x^2 - 0,995x + 22,30$
s. 14	$y = -0,029x^2 + 1,173x + 43,86$
s. 15	$y = -0,028x^2 + 0,183x + 54,46$
s. 16	$y = -0,076x^2 + 2,087x + 54,74$
s. 17	$y = -0,056x^2 + 2,654x + 54,93$
s. 18	$y = -0,054x^2 + 1,453x + 58,13$
s. 19	$y = -0,003x^2 - 0,243x + 88,99$
s. 20	$y = -0,031x^2 + 0,911x + 77,65$
s. 21	$y = -0,088x^2 + 3,217x + 88,08$
s. 22	$y = 0,014x^2 + 1,433x + 76,02$
s. 23	$y = 0,113x^2 - 2,327x + 109,9$
s. 24	$y = 0,019x^2 - 1,327x + 88,75$
s. 25	$y = 0,056x^2 - 3,327x + 87,72$

Figura 5.68: Gráfico da superfície tridimensional da cena natural 01.

Finalmente, com as equações polinomiais de cada série, as áreas são mapeadas de forma bidimensional, e agrupadas seguindo a leitura matricial, formando a projeção do modelo virtual, relacionando todas as séries num gráfico de superfície tridimensional da cena natural, estimando a densidade do seu volume (figuras 5.69, 5.71, 5.73, 5.75 e 5.77).

Figura 5.69: Gráfico de superfície tridimensional com a estimativa do volume da cena natural 01.

Cena natural 02:

Tabela 5.6: Equações polinomiais de cada série para a cena natural 02.

Séries	Equações polinomiais
s. 01	$y = 0,283x^2 - 7,292x + 123,7$
s. 02	$y = 0,178x^2 - 3,989x + 91,33$
s. 03	$y = 0,158x^2 - 3,224x + 83,92$
s. 04	$y = -0,076x^2 + 1,607x + 70,87$
s. 05	$y = 0,101x^2 - 2,916x + 97,72$
s. 06	$y = 0,232x^2 - 6,644x + 115,8$
s. 07	$y = 0,110x^2 - 2,696x + 95,58$
s. 08	$y = -0,126x^2 + 4,615x + 45,01$
s. 09	$y = -0,008x^2 + 0,720x + 69,90$
s. 10	$y = -0,021x^2 + 0,992x + 69,62$
s. 11	$y = -0,01x^2 + 0,692x + 54,62$
s. 12	$y = 0,069x^2 - 1,721x + 85,55$
s. 13	$y = 0,019x^2 - 0,356x + 78,10$
s. 14	$y = -0,038x^2 + 1,212x + 65,86$
s. 15	$y = -0,028x^2 + 0,167x + 77,46$
s. 16	$y = -0,089x^2 + 2,019x + 69,74$
s. 17	$y = -0,079x^2 + 2,026x + 65,93$
s. 18	$y = -0,061x^2 + 1,586x + 68,13$
s. 19	$y = -0,002x^2 - 0,276x + 75,99$
s. 20	$y = -0,041x^2 + 0,983x + 69,65$
s. 21	$y = -0,098x^2 + 3,227x + 49,08$
s. 22	$y = 0,004x^2 + 0,439x + 69,02$
s. 23	$y = 0,133x^2 - 4,357x + 104,9$
s. 24	$y = 0,069x^2 - 2,327x + 87,72$
s. 25	$y = -0,053x^2 + 1,469x + 65,33$

Figura 5.70: Gráfico da superfície tridimensional da cena natural 02.

Figura 5.71: Gráfico de superfície tridimensional com a estimativa do volume da cena natural 02.

Cena natural 03:

Tabela 5.7: Equações polinomiais de cada série para a cena natural 03.

Séries	Equações polinomiais
s. 01	$y = -0,024x^2 + 0,744x + 68,22$
s. 02	$y = -0,077x^2 + 2,067x + 65,47$
s. 03	$y = -0,018x^2 + 0,668x + 76,59$
s. 04	$y = 0,074x^2 - 1,984x + 80,25$
s. 05	$y = 0,000x^2 - 0,701x + 86,16$
s. 06	$y = 0,112x^2 - 3,132x + 94,13$
s. 07	$y = 0,200x^2 - 6,541x + 121,6$
s. 08	$y = 0,170x^2 - 4,469x + 98,39$
s. 09	$y = 0,019x^2 - 0,356x + 78,10$
s. 10	$y = -0,038x^2 + 1,212x + 65,86$
s. 11	$y = 0,045x^2 - 0,998x + 86,16$

s. 12	$y = 0,155x^2 - 3,224x + 94,53$
s. 13	$y = 0,069x^2 - 1,721x + 85,55$
s. 14	$y = 0,019x^2 - 0,356x + 78,10$
s. 15	$y = -0,038x^2 + 1,212x + 65,86$
s. 16	$y = -0,028x^2 + 0,167x + 77,46$
s. 17	$y = -0,089x^2 + 2,019x + 69,74$
s. 18	$y = -0,088x^2 + 3,217x + 88,08$
s. 19	$y = 0,014x^2 + 1,433x + 76,02$
s. 20	$y = 0,113x^2 - 2,327x + 109,9$
s. 21	$y = 0,014x^2 + 1,433x + 76,02$
s. 22	$y = 0,113x^2 - 2,327x + 109,9$
s. 23	$y = 0,019x^2 - 1,327x + 88,75$
s. 24	$y = -0,002x^2 - 0,276x + 75,99$
s. 25	$y = -0,041x^2 + 0,983x + 69,65$

Figura 5.72: Gráfico da superfície tridimensional da cena natural 03.

Figura 5.73: Gráfico de superfície tridimensional com a estimativa do volume da cena natural 03.

Cena natural 04:

Tabela 5.8: Equações polinomiais de cada série para a cena natural 04.

Séries	Equações polinomiais
s. 01	$y = -0,002x^2 - 0,276x + 75,99$
s. 02	$y = -0,041x^2 + 0,983x + 69,65$
s. 03	$y = -0,098x^2 + 3,227x + 49,08$
s. 04	$y = 0,004x^2 + 0,439x + 69,02$
s. 05	$y = 0,019x^2 - 0,356x + 78,10$
s. 06	$y = -0,038x^2 + 1,212x + 65,86$
s. 07	$y = -0,028x^2 + 0,167x + 77,46$
s. 08	$y = -0,089x^2 + 2,019x + 69,74$
s. 09	$y = -0,079x^2 + 2,026x + 65,93$
s. 10	$y = -0,034x^2 + 5,744x + 58,22$
s. 11	$y = -0,067x^2 + 5,067x + 75,47$
s. 12	$y = -0,118x^2 + 4,668x + 66,59$
s. 13	$y = 0,054x^2 - 1,484x + 90,25$
s. 14	$y = 0,004x^2 - 0,401x + 76,16$
s. 15	$y = 0,102x^2 - 4,132x + 94,13$
s. 16	$y = 0,014x^2 + 1,433x + 76,02$
s. 17	$y = 0,113x^2 - 2,327x + 109,9$
s. 18	$y = 1,32x^2 - 5,43x + 112,8$
s. 19	$y = -0,234x^2 + 0,784x + 65,52$
s. 20	$y = -0,447x^2 + 3,088x + 65,67$
s. 21	$y = -0,048x^2 + 0,558x + 74,49$
s. 22	$y = 0,054x^2 - 1,954x + 70,25$
s. 23	$y = 0,045x^2 - 0,998x + 86,16$
s. 24	$y = 0,155x^2 - 3,224x + 94,53$
s. 25	$y = 0,178x^2 - 3,989x + 91,33$

Figura 5.74: Gráfico da superfície tridimensional da cena natural 04.

Figura 5.75: Gráfico de superfície tridimensional com a estimativa do volume da cena natural 04.

Cena natural 05:

Tabela 5.9: Equações polinomiais de cada série para a cena natural 05.

Séries	Equações polinomiais
s. 01	$y = 0,11x^2 - 3,96x + 57,72$
s. 02	$y = 1,32x^2 - 5,43x + 112,8$
s. 03	$y = 0,004x^2 + 0,439x + 69,02$
s. 04	$y = 0,133x^2 - 4,357x + 104,9$
s. 05	$y = 0,069x^2 - 2,327x + 87,72$
s. 06	$y = -0,018x^2 + 0,745x + 45,90$
s. 07	$y = -0,031x^2 + 0,555x + 33,62$
s. 08	$y = -0,076x^2 + 2,087x + 54,74$
s. 09	$y = 0,178x^2 - 3,989x + 91,33$
s. 10	$y = 0,019x^2 - 0,356x + 78,10$
s. 11	$y = -0,088x^2 + 3,467x + 68,67$
s. 12	$y = -0,033x^2 + 0,468x + 86,49$
s. 13	$y = 0,034x^2 - 1,384x + 88,45$
s. 14	$y = -0,056x^2 + 2,654x + 54,93$
s. 15	$y = -0,076x^2 + 1,607x + 70,87$
s. 16	$y = 0,200x^2 - 6,541x + 121,6$
s. 17	$y = 0,170x^2 - 4,469x + 98,39$
s. 18	$y = 0,158x^2 - 3,224x + 83,92$
s. 19	$y = -0,088x^2 + 3,217x + 88,08$
s. 20	$y = 0,014x^2 + 1,433x + 76,02$
s. 21	$y = 0,113x^2 - 2,327x + 109,9$
s. 22	$y = 0,019x^2 - 1,327x + 88,75$
s. 23	$y = 0,056x^2 - 3,327x + 87,72$
s. 24	$y = 0,014x^2 + 1,433x + 76,02$
s. 25	$y = 0,113x^2 - 2,327x + 109,9$

Figura 5.76: Gráfico da superfície tridimensional da cena natural 05.

Figura 5.77: Gráfico de superfície tridimensional com a estimativa do volume da cena natural 05.

Com a composição de todas as séries geradas (25), é possível compor o modelo virtual da árvore com maior precisão de volume estimado. Trabalhando com os gráficos gerados por dispersão dos pontos obtidos da matriz de distâncias retificadas, maior realismo é imposto à fatia do modelo gerado. Para completa integração com o método desenvolvido por Oliveira (OLIVEIRA, 2012), a matriz de distâncias retificadas pode ser enviada, via arquivo XML, juntamente com a identificação da posição (GPS) onde foi realizada a série de medidas.

Assim, cada árvore tem seu volume estimado, apresentando dados quantitativos de produção, da linha de plantio trabalhada. Estes resultados são parâmetros de entrada para o classificador geral cognitivo que relaciona o peso da construção dos modelos virtuais na fusão sensorial de dados pretendida.

5.4. Resultados da caracterização da refletância, NDVI e instrumentação

As imagens a seguir demonstram as linhas de plantio do talhão de plantação de citros (*valência*), em período de maturação e colheita, e cada árvore, com seus respectivos conjuntos de dados dos índices de refletância. São demonstrados os dados das 5 primeiras árvores e a relação entre as diferenças entre estas, em função da posição de aquisição e desuniformidade do dossel, com cada qual apresentando peculiaridades sobre a aglomeração e o afastamento de folhas, ramos, galhos e frutos, com regiões em *foreground* e *background*.

Figura 5.78: Árvore 1 - imagem em RGB para aquisição dos índices de refletância.

Tabela 5.10: Índices vegetativos obtidos e calculados da árvore 1.

RE	R _{NIR}	R	NDRE	NDVI
25.06	24.11	86.77	-0.0194	-0.5651
24.88	24.34	91.57	-0.0109	-0.5800
24.80	24.44	90.79	-0.0073	-0.5758
24.71	24.56	90.77	-0.0030	-0.5741
25.11	24.05	90.63	-0.0215	-0.5806
25.08	24.09	91.32	-0.0200	-0.5825
24.76	24.48	90.51	-0.0057	-0.5742
24.83	24.39	91.21	-0.0090	-0.5780
24.63	24.66	90.43	0.0007	-0.5714
24.94	24.27	90.40	-0.0136	-0.5767
25.06	24.12	91.18	-0.0192	-0.5817
24.96	24.24	90.80	-0.0145	-0.5785
24.81	24.43	89.99	-0.0077	-0.5730
24.64	24.65	90.19	0.0003	-0.5707
24.68	24.60	90.29	-0.0017	-0.5718
25.07	24.10	90.38	-0.0197	-0.5790
25.15	24.00	91.33	-0.0235	-0.5838

24.84	24.38	90.64	-0.0093	-0.5760
25.17	23.98	91.15	-0.0242	-0.5834
24.79	24.45	90.49	-0.0070	-0.5746
24.99	24.20	91.20	-0.0161	-0.5806
25.04	24.14	89.81	-0.0182	-0.5763
24.72	24.54	90.58	-0.0037	-0.5737
24.58	24.73	90.55	0.0031	-0.5710
24.58	24.73	90.37	0.0030	-0.5703

Figura 5.79: Árvore 2 - imagem em RGB para aquisição dos índices de refletância.

Tabela 5.11: Índices vegetativos obtidos e calculados da árvore 2.

RE	R _{NIR}	R	NDRE	NDVI
25.15	24.01	90.74	-0.0231	-0.5815
24.65	24.63	90.22	-0.0004	-0.5711
24.99	24.20	91.20	-0.0160	-0.5806
24.76	24.49	91.14	-0.0055	-0.5764
24.88	24.33	91.53	-0.0112	-0.5800
24.91	24.30	86.29	-0.0124	-0.5605
24.69	24.58	90.25	-0.0022	-0.5718
24.94	24.26	91.58	-0.0138	-0.5811
25.08	24.09	90.96	-0.0202	-0.5813
24.97	24.22	90.18	-0.0152	-0.5765
24.71	24.56	91.13	-0.0031	-0.5755
24.76	24.49	90.87	-0.0054	-0.5754
24.72	24.54	90.77	-0.0038	-0.5744
24.78	24.46	90.98	-0.0065	-0.5762
24.75	24.51	91.17	-0.0049	-0.5763
24.89	24.33	90.69	-0.0115	-0.5770
25.02	24.17	91.54	-0.0172	-0.5823

24.77	24.48	90.69	-0.0057	-0.5749
25.09	24.08	91.13	-0.0206	-0.5820
24.89	24.32	90.07	-0.0117	-0.5748
24.98	24.21	90.91	-0.0156	-0.5794
24.71	24.56	89.22	-0.0030	-0.5683
24.53	24.80	90.04	0.0054	-0.5682
24.64	24.64	89.99	0.0001	-0.5700
24.84	24.38	89.42	-0.0094	-0.5715

Figura 5.80: Árvore 3 - imagem em RGB para aquisição dos índices de refletância.

Tabela 5.12: Índices vegetativos obtidos e calculados da árvore 3.

RE	R _{NIR}	R	NDRE	NDVI
24.60	24.69	90.91	0.0018	-0.5728
25.18	23.97	91.06	-0.0248	-0.5833
24.90	24.31	90.21	-0.0118	-0.5754
25.15	24.01	91.26	-0.0233	-0.5835
24.91	24.30	91.28	-0.0123	-0.5795
24.72	24.54	90.51	-0.0038	-0.5735
24.76	24.49	91.03	-0.0055	-0.5760
24.63	24.65	90.31	0.0004	-0.5711
24.83	24.40	89.86	-0.0087	-0.5729
24.73	24.54	91.12	-0.0039	-0.5757
25.03	24.15	87.29	-0.0180	-0.5666
25.04	24.14	90.85	-0.0182	-0.5801
24.80	24.44	91.16	-0.0072	-0.5771
25.04	24.14	91.40	-0.0183	-0.5822
24.82	24.41	90.57	-0.0083	-0.5753
24.92	24.28	90.67	-0.0131	-0.5775
24.64	24.65	89.62	0.0001	-0.5686

24.74	24.52	90.09	-0.0043	-0.5721
24.76	24.49	90.60	-0.0054	-0.5744
24.70	24.56	89.64	-0.0029	-0.5698
24.79	24.46	90.38	-0.0067	-0.5741
24.90	24.31	91.26	-0.0121	-0.5793
25.00	24.18	90.47	-0.0167	-0.5782
24.74	24.52	90.74	-0.0046	-0.5746
25.16	24.00	91.59	-0.0236	-0.5848

Figura 5.81: Árvore 4 - imagem em RGB para aquisição dos índices de refletância.

Tabela 5.13: Índices vegetativos obtidos e calculados da árvore 4.

RE	R _{NIR}	R	NDRE	NDVI
24.79	24.45	90.46	-0.0070	-0.5745
24.82	24.41	89.80	-0.0083	-0.5725
24.80	24.43	90.32	-0.0075	-0.5742
24.65	24.63	91.17	-0.0004	-0.5746
25.19	23.95	91.49	-0.0252	-0.5850
24.70	24.57	90.99	-0.0027	-0.5748
24.80	24.43	91.11	-0.0075	-0.5770
25.01	24.18	91.17	-0.0169	-0.5808
24.89	24.32	89.47	-0.0117	-0.5726
24.62	24.67	90.00	0.0011	-0.5697
24.75	24.51	90.08	-0.0049	-0.5723
24.69	24.59	90.37	-0.0020	-0.5722
24.73	24.52	89.89	-0.0043	-0.5713
24.72	24.54	90.58	-0.0037	-0.5737
24.81	24.42	91.32	-0.0079	-0.5780
24.92	24.28	91.06	-0.0131	-0.5790
24.76	24.49	90.94	-0.0055	-0.5757

25.02	24.17	90.48	-0.0173	-0.5784
24.90	24.31	89.94	-0.0120	-0.5744
24.78	24.46	91.23	-0.0065	-0.5771
24.73	24.53	89.37	-0.0041	-0.5693
25.03	24.15	90.79	-0.0178	-0.5798
24.67	24.60	90.76	-0.0014	-0.5734
24.72	24.54	90.34	-0.0035	-0.5727
24.86	24.36	90.13	-0.0103	-0.5745

Figura 5.82: Árvore 5 - imagem em RGB para aquisição dos índices de refletância.

Tabela 5.14: Índices vegetativos obtidos e calculados da árvore 5.

RE	R _{NIR}	R	NDRE	NDVI
24.83	24.40	89.93	-0.0088	-0.5732
24.74	24.52	89.37	-0.0044	-0.5694
24.61	24.69	90.11	0.0015	-0.5699
24.78	24.47	88.99	-0.0064	-0.5687
24.94	24.26	90.90	-0.0137	-0.5786
24.93	24.28	89.71	-0.0133	-0.5741
24.99	24.20	90.38	-0.0159	-0.5775
24.96	24.23	90.16	-0.0149	-0.5763
25.37	23.74	86.86	-0.0332	-0.5707
24.70	24.57	91.71	-0.0025	-0.5774
24.73	24.53	91.27	-0.0040	-0.5763
24.94	24.26	90.27	-0.0138	-0.5764
24.87	24.35	90.83	-0.0107	-0.5772
25.01	24.18	90.22	-0.0170	-0.5773
24.89	24.33	90.18	-0.0114	-0.5751
24.69	24.58	90.19	-0.0022	-0.5716
24.52	24.80	90.87	0.0057	-0.5712

24.88	24.34	91.29	-0.0111	-0.5791
24.76	24.49	90.65	-0.0055	-0.5746
24.51	24.82	90.28	0.0064	-0.5687
24.62	24.67	90.27	0.0010	-0.5707
24.68	24.59	90.38	-0.0018	-0.5722
24.82	24.41	90.35	-0.0084	-0.5746
24.64	24.64	89.64	-0.0001	-0.5688
24.57	24.74	91.37	0.0034	-0.5739

Comparando as cinco tabelas (5.10, 5.11, 5.12, 5.13, 5.14), com média de 25 medidas, os índices NDVI variam entre -0,5700 a -0,5800, para as medidas entre o sensor e a parte frontal da superfície do dossel, tais valores indicam que a refletância se comporta entre os padrões indicados no manual do sensor para período de colheita e área regularmente saudável, como porções entre 35% e 60% do infravermelho próximo (NIR), apontando para níveis adequados de clorofila em período de colheita (observa-se cada cena natural com laranjas em período de colheita), mantendo em até 90% da cena analisada, a uniformidade entre as variações da cor verde e textura associadas.

Os valores de NDRE se situam entre -0,0001 a 0,5000, com média em -0,0104 (cena 01), -0,0105 (cena 02), -0,0108 (cena 03), -0,0103 (cena 4) e -0,0077 (cena 05), o que significa que as cenas analisadas se encontram em período de colheita.

Sobre os valores dos demais índices vegetativos (RE, RNIR e R), as cinco cenas naturais analisadas apresentam as seguintes médias, presentes na tabela 5.15.

Tabela 5.15: Índices vegetativos RE, R_{NIR} e R e resultados das medidas.

Índice vegetativo	Cenas naturais	Médias valores de refletância	Características
<i>RE</i>	Cena 01	24,8673	Pré-deficiência em algum elemento, porém em fase inicial (o valor de refletância indica a ausência ou diminuição dos elementos);
	Cena 02	24,8701	
	Cena 03	24,8768	
	Cena 04	24,8671	
	Cena 05	24,8087	
R_{NIR}	Cena 01	24,3574	Pré-deficiência em algum elemento, porém em fase inicial (o valor de refletância indica a ausência ou diminuição dos elementos)
	Cena 02	24,3539	
	Cena 03	24,3454	
	Cena 04	24,3577	
	Cena 05	24,4315	
<i>R</i>	Cena 01	90,6477	Estimativa do equilíbrio entre os períodos de maturação e colheita com alguma deficiência. (em fase inicial - regularmente saudável pela transição em 90,0000 a 90,7000);
	Cena 02	90,6417	
	Cena 03	90,6364	
	Cena 04	90,6367	
	Cena 05	90,3051	

O tratamento destes dados como informação qualitativa (*diagnoses*) do fruto é relacionada apenas aos seus valores apresentados anteriormente em cada tabela. Assim, modelos gráficos de análise são trabalhados para identificar a relação de desuniformidade de cada planta analisada, e o equilíbrio entre os índices obtidos.

Os gráficos das figuras 5.83, 5.84, 5.85, 5.86 e 5.87 mostram a distribuição ao longo das 25 medidas para cada índice vegetativo (RE, R_{NIR} , R, NDRE e NDVI).

Figura 5.83: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena natural 01.

Figura 5.84: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena natural 02.

Figura 5.85: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena natural 03.

Figura 5.86: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena natural 04.

Figura 5.87: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena natural 05.

Considerando que a largura do feixe (L_{feixe}) é aplicada em toda a cena, a distância de aquisição (d), entre o veículo guiado e as plantas, de forma paralela, e a abertura angular FOV (*field-of-view*) de 45° (ϑ), variam conforme a aproximação de uma região para outra, têm-se os seguintes valores de largura para cada aquisição:

$$L_{feixe\ 1} = 2.0,90. \tan\left(\frac{\vartheta}{2}\right) = 0,82.0,90 = 0,738\ m \quad (40)$$

$$L_{feixe\ 2} = 2.1,10. \tan\left(\frac{\vartheta}{2}\right) = 0,82.1,10 = 0,902\ m \quad (41)$$

$$L_{feixe\ 3} = 2.1,15. \tan\left(\frac{\vartheta}{2}\right) = 0,82.1,15 = 0,943\ m \quad (42)$$

$$L_{feixe\ 4} = 2.0,95. \tan\left(\frac{\vartheta}{2}\right) = 0,82.0,95 = 0,779\ m \quad (43)$$

$$L_{feixe\ 5} = 2.0,85. \tan\left(\frac{\vartheta}{2}\right) = 0,82.0,85 = 0,697\ m \quad (44)$$

Com isso, uma média entre cada conjunto de 25 medidas (tabela 5.16), extraídas pelo sensor é calculada que, em relação ao peso denominado pelo classificador geral, discrimina se determinada cena natural provê condições qualitativas *ante*-diagnóstico em laboratório.

Tabela 5.16: Média dos índices vegetativos para cada árvore.

Cena natural	RE	R _{NIR}	R	NDRE	NDVI
Cena 01	24,8673	24,3574	90,6477	-0,0104	-0,5764
Cena 02	24,8701	24,3539	90,6417	-0,0105	-0,5764
Cena 03	24,8768	24,3454	90,6364	-0,0108	-0,5765
Cena 04	24,8671	24,3577	90,6367	-0,0103	-0,5764
Cena 05	24,8087	24,4315	90,3051	-0,0077	-0,5741

Mesmo com valores médios próximos de uma cena a outra, cada variação em RE, R_{NIR} e R, principalmente denotam detalhes de formação da planta e área folicular. Os valores de NDRE e NDVI denotam o quão próximos de período de plantação/maturação/colheita estão, como mostrado na figura 5.88.

Na base de dados **B**, aproximadamente 220 imagens de cenas naturais representam 100% de toda a linha de plantio analisada. Uma média destas imagens, contendo suas respectivas tabelas de índices vegetativos, e gráficos da distribuição e dispersão de dados, é apresentada no **APÊNDICE D**.

Figura 5.88: Médias dos índices de refletância para cada árvore.

5.5. Resultados da classificação geral cognitiva na fusão sensorial óptica

Os resultados para as duas etapas do classificador geral cognitivo ponderado são apresentados nesta seção, inicialmente na etapa 01 (*lógica fuzzy*), identificando as informações normalizadas das pré-classificações (resultados das quatro abordagens), e as classificando de forma ponderada com associação de cenas, e finalizando pela etapa 02 (RNA), com a normalização dos dados vetoriais na entrada, e classificação das informações, com a fusão integrada por sobreposição.

5.5.1. Resultados da etapa 01 do CgCP (*lógica fuzzy*)

Através da programação no MATLAB, é realizada a adição das variáveis de entrada e saída, funções-membro, definidas como triangulares e trapezoidais, e a *defuzzificação* pelo método do Centróide (centro de gravidade dos conjuntos *fuzzy*).

Finalmente, a base de regras para as quatro entradas, quatro saídas e suas respectivas funções-membro é montada e apresentada abaixo. pela condição lógica ‘E’ das variáveis de entrada (*VHim*, *VMVir*, *VnMD*, *VmIV*), e suas respectivas funções-membro para cada associação, na extração das saídas estimadas (*PC3*, *PC2a*, *PC2b*, *PC1*) para a classificação inicial das classes ponderadas e as relações entre as cenas de regiões e cenas de dosséis.

Na tabela 5.17, são associados os estados de entrada e de saída, e suas respectivas funções-membro. Observa-se que para cada função-membro dos estados de entrada existem 4 saídas com suas respectivas funções-membro.

Tabela 5.17: Base de regras para as entradas e saídas.

		VHim				
		arco25	arco100	arco75		
VnMD	aib	PC3 CENAparcial	PC3 CENAtotal	PC3 CENAparcial	mancha10	VMVir
		PC2a CENAINexistente	PC2a CENAparcial	PC2a CENAparcial		
		PC2b CENAINexistente	PC2b CENAparcial	PC2b CENAparcial		
		PC1 CENAINexistente	PC1 CENAtotal	PC1 CENAINexistente		
	aim	PC3 CENAparcial	PC3 CENAtotal	PC3 CENAtotal	mancha100	
		PC2a CENAtotal	PC2a CENAtotal	PC2a CENAtotal		
		PC2b CENAtotal	PC2b CENAtotal	PC2b CENAparcial		
		PC1 CENAparcial	PC1 CENAtotal	PC1 CENAparcial		
	aia	PC3 CENAparcial	PC3 CENAtotal	PC3 CENAparcial	mancha50	
		PC2a CENAparcial	PC2a CENAparcial	PC2a CENAparcial		
		PC2b CENAparcial	PC2b CENAtotal	PC2b CENAparcial		
		PC1 CENAINexistente	PC1 CENAtotal	PC1 CENAINexistente		
		NDVIalto	NDVImedio	NDVIbaixo		
		VmIV				

A estrutura do MCP (*Model Predictive Control*) (NIKOLAU, 2001) nos conjuntos *fuzzy* atende os intervalos em que a função-membro de maior relevância para as saídas apresentem condições otimizadas de classificação, sendo a maior intersecção quando *VHim* (**arco100**), *VMVir* (**mancha100**), *VmIV* (**NDVImedio**) e *VnMD* (**aim**). Não é elaborada uma lei de controle que estabeleça tal relação, apenas a correção do modelo linear permite corresponder os estados de inferência como as saídas previstas, sendo estas corrigidas pela referência com o grau de pertinência máximo e as variáveis de saída.

Seguindo a discriminação da base de regras, na figura 5.89 é apresentado o conjunto de intersecções condicionais em que cada entrada, com cada função-membro, resulta em cada saída, com cada função-membro. Observa-se o comportamento dos estados de entrada e respectivos valores estimados nas saídas para a determinação dos pesos e sua respectiva função da cena de região contida na cena de dossel. Como a variação de inferência está relacionada com a média de probabilidades na detecção geométrica dos triângulos e trapézios, várias situações podem ser simuladas para valores diferentes de fator inicial, e correspondência com os processos de saída esperados.

Observa-se ainda que as cenas de região são integradas as cenas de dosséis, para todos os pesos, quando a função-membro de cada entrada é mais crítica, ainda, a maior relevância de pesos durante as intersecções acontece quando as abordagens iniciais não são mais prioritárias, *i.e.* $VmIV > VnMD > VMVir > VHim$. As funções de superfície para cada regra, denotando de forma gráfica a relação de condições das regras formuladas quanto aos valores de saída estimados (aplicação dos pesos e relação de cenas), são também verificadas de acordo com os estados de inferência.

Figura 5.89: Variação dos estados de inferência das entradas e saídas, pela base de regras *fuzzy*.

Com base na classificação inicial pela lógica *fuzzy*-preditiva, em que cada pré-classificação das abordagens trabalhadas foram devidamente ponderadas e as cenas de regiões e dosséis associadas, como segunda etapa do classificador CgCP, modelos de redes neurais artificiais são implementados para integrar todos os quatro resultados das pré-classificações

em discriminação a um determinada cena natural, que corresponde todas as características qualitativas e quantitativas necessárias a fusão sensorial.

5.5.2. Resultados da etapa 02 do CgCP (RNA)

Os resultados das topologias RNA com desempenho ideal são obtidos nos casos em que a abordagem 1 trabalha com as imagens no espaço de cores HSV, pois este delimita satisfatoriamente as regiões de contorno onde é caracterizada a região do fruto e dos demais elementos da biomassa, a abordagem 2 apresenta apenas uma região com irregularidades na superfície do fruto - maior estimativa pelo algoritmo EM, a abordagem 3 apresenta menos valores corrigidos nas matrizes de distâncias retificadas, e a abordagem 4 apresenta médias com menor variação entre os índices vegetativos. Alguns casos, o algoritmo de aprendizado não foi eficiente em aprender e discriminar as classes *fusão quantitativa* e *fusão qualitativa*, uma vez que as associações entre estas abordagens requerem normalizações durante as iterações, onde a resiliência foi ineficaz em parametrizar as classes, todavia, em 90% das épocas/iteraões, as três classes foram corretamente classificadas.

Essa verificação dá-se pelos gráficos de regressão das saídas alvo, baseadas nas matrizes de confusão dos testes nas quatro abordagens. Tais gráficos (figuras 5.90, 5.91, 5.92, 5.93) denotam a quantização dos vetores/saídas estimadas em relação às dimensões treinadas, testadas e validadas. A proximidade das classes quanto sua dispersão é notável nos gráficos, uma vez que os conjuntos de treinamento e teste podem ser inter-relacionados com similaridades de dimensões, tornando o classificador mais robusto, porém com maior tempo de resposta (aumento da latência, maior número de neurônios intermediários).

Nas matrizes de confusão para 25% dos conjuntos, observa-se que a distribuição percentual para o conjunto de validação é quase simétrica, com valores próximos para a classificação das classes-alvo e suas saídas. Nas matrizes de confusão dos conjuntos de treinamento e teste, observa-se, porém, uma maior variação percentual na classe 4 (índices vegetativos), com mais dimensões, indicando que para conjuntos menores, as classes menos prioritárias tendem a convergir com menor latência de processamento. As demais classes são classificadas pela média esperada. Conforme os percentuais dos conjuntos aumenta, as classes mais prioritárias apresentam dimensões entre os limites máximo e mínimo, para uma classificação com menor latência e mais eficiente. Assim, para as matrizes de confusão com 50% dos conjuntos, a classe 1 (histogramas das imagens RGB/HSV) são classificadas em primeiro lugar, provando seu peso inicial atribuído nos neurônios de entrada, calculado anteriormente pelo classificador *fuzzy*.

Figura 5.90: Matrizes de confusão (treinamento, validação e teste) para 25% dos conjuntos.

Figura 5.91: Matrizes de confusão (treinamento, validação e teste) para 50% dos conjuntos.

Figura 5.92: Matrizes de confusão (treinamento, validação e teste) para 75% dos conjuntos.

Figura 5.93: Matrizes de confusão (treinamento, validação e teste) para 100% dos conjuntos.

Para os percentuais de 75% e 100%, a classe 1 apresenta menor número de dimensões na matriz de confusão de teste, porém entre os mínimos e máximo nas matrizes de confusão de treinamento e validação, indicando que são classificadas de acordo com sua ponderação, necessitando apenas de poucas dimensões para sua classificação.

As médias de resultados com taxas de acerto pretendidas apresentaram falsos positivos e falsos negativos no total de iterações aplicadas, desconsideráveis, uma vez que as médias destas taxas para os vetores de menores dimensões de entrada apresentam os melhores resultados, sendo que a dispersão dos vetores de características foi facilmente evitada nas percentagens de aproximação entre 25% e 50%, , sendo os conjuntos com 75% e 100%, com 20 dimensões, apresentando as melhores classificações ponderadas.

Para as avaliações da classificação foram usadas as taxas de acerto, com 20 dimensões normalizadas para as quatro abordagens (figura 5.94), e o número de iterações do algoritmo de treinamento, sendo responsável pela melhoria do aprendizado, ajustando os pesos sinápticos de acordo com a necessidade das abordagens, minimizando o erro de classificação.

Figura 5.94: Taxa de verdadeiros positivos (VP) pela taxa de falsos positivos (FP) (treinamento, validação e teste) para 25%, 50%, 75% e 100% dos conjuntos.

Assim, são observados nas figuras 5.95, 5.96, 5.97, 5.98, os gráficos de desempenho para os conjuntos de treinamento, validação e teste, para todos os percentuais de conjunto (25%, 50%, 75% e 100%), e como seu limiar de discriminação é variado.

Analisando os gráficos dos erros quadráticos médios (EQM) dos conjuntos de treinamento, é verificada a relação das médias de treinamento, teste e validação para as quatro abordagens, em que todas apresentam média baixa quando os pesos não se confundem. Com o aumento de neurônios na camada intermediária, o classificador RNA torna-se mais eficiente, ao invés de expandir a relação de dimensões e amostras no conjunto de treinamento, uma vez que o tempo de resposta na denominação dos vetores que distam dos centróides das classes estimadas pode aumentar.

O erro quadrático médio nos quatro percentuais de classificação apresentou-se abaixo do estimado, antes da configuração dos parâmetros para o algoritmo de aprendizado. Para 25%, o valor de erro admissível está em $1,3800 \cdot 10^{-6}$, para 50% em $1,1144 \cdot 10^{-6}$, para 75% em $8,1971 \cdot 10^{-7}$, e para 100% em $3,6015 \cdot 10^{-7}$.

O método de entropia cruzada minimizada resulta também em classificações pretendidas para as saídas, com menores valores representando melhores resultados, e zero denotando nenhum erro. Para tal, a quantidade de amostras para o conjunto de treinamento é de 700, de validação 150, e teste 150.

Figura 5.95: EQM (treinamento, validação e teste) para 25% dos conjuntos.

Figura 5.96: EQM (treinamento, validação e teste) para 50% dos conjuntos.

Figura 5.97: EQM (treinamento, validação e teste) para 75% dos conjuntos.

Figura 5.98: EQM (treinamento, validação e teste) para 100% dos conjuntos.

Para os 720 tipos de RNA, uma média de 32 iterações foi aplicada para 25% dos conjuntos, com gradiente de magnitude em $5,99 \cdot 10^{-7}$ e sendo o algoritmo de treinamento como o *scaled conjugate gradient (SCG)* (figuras 5.99, 5.100, 5.101, 5.102). Para 50% dos conjuntos, média de 32 iterações e gradiente de contorno em $6,89 \cdot 10^{-7}$. Para 75% dos conjuntos, média de 30 iterações e gradiente de contorno em $9,77 \cdot 10^{-7}$. Para 100% dos conjuntos, média de 31 iterações e gradiente de contorno em $6,29 \cdot 10^{-7}$.

Figura 5.99: Estado de treinamento por *scaled conjugate gradient* para 25% dos conjuntos.

Figura 5.100: Estado de treinamento por *scaled conjugate gradient* para 50% dos conjuntos.

Figura 5.101: Estado de treinamento por *scaled conjugate gradient* para 75% dos conjuntos.

Figura 5.102: Estado de treinamento por *scaled conjugate gradient* para 100% dos conjuntos.

5.5.3. Resultados finais do classificador geral cognitivo ponderado

Os resultados apresentados nas duas etapas do CgCP denotam que para as classes *fusão relacional*, *fusão quantitativa* e *fusão qualitativa*, os dados de entrada ponderados convergiram nos padrões estimados, sendo que a prioridade de integração entre os dados deu-se em maior abrangência da classe 1 para a classe 2, para a classe 3, nos conjuntos de maior percentagem. Para conjuntos de menor percentagem, a classe 4 apresentou maior taxa de acerto, por não ter relevância ponderada a grupos maiores de imagens/dados.

Como a entrada da RNA é dinâmica, dada a normalização das características de todas as informações vetoriais de entrada, das quatro abordagens, estabeleceu-se uma média de 70×70 dados matriciais, o que significa que aproximadamente 5000 características dentro da matriz simbolizam os histogramas das imagens em RGB/HSV, as máximas-verossimilhanças das imagens térmicas, as matrizes de distância retificadas, e a média dos índices vegetativos das árvores, todos ponderados. Os resultados práticos da RNA, com a sobreposição, também resultam em matrizes dinâmicas nas três saídas pretendidas, denotando os aspectos geométricos, posição, orientação, estimação do volume e proporção da área foliar, tanto de frutos quanto da biomassa.

Assim, a tabela 5.18 relaciona as taxas de acerto para os quatro percentuais e quatro classes, na classificação das saídas pretendidas, de acordo com os resultados apresentados pelo método ROC, EQM, SCG, os erros de histogramas e, principalmente, as matrizes de confusão.

Tabela 5.18: Resultados das quatro classes/percentuais na classificação das saídas pretendidas.

Saídas	Classes de entrada	Taxas de acerto
<i>Fusão relacional</i>	01	~40%
	02	~25%
	03	~25%
	04	~10%
<i>Fusão quantitativa</i>	01	~35%
	02	~20%
	03	~30%
	04	~15%
<i>Fusão qualitativa</i>	01	~20%
	02	~35%
	03	~15%
	04	~30%

Com isso, a seguir é demonstrado pelo algoritmo de preenchimento de regiões, como se estabelece a sobreposição dos pré-resultados (classes), para as saídas pretendidas:

Cada saída neuronal acima, também recebe mais de uma classe associada a fusão, a diferença consiste no percentual da taxa de acerto que corresponde a determinada classe (cenas regionais) para outra (cenas totais) - os percentuais de cada classe devem ser os maiores para cada saída, o que caracteriza a classificação dos neurônios de saída.

Assim, os seguintes resultados de sobreposição são apresentados, para as três cenas naturais trabalhadas em comum com as duas bases de dados **A** e **B**.

Na integração dos dados iniciais (figura 5.103), para a saída *fusão relacional*, têm-se primeiramente a sobreposição do mapa de classe EM termográfica nos mapas de classe RGB/HSV, situando a região dentro do dossel. Tal análise é verificada analisando a vizinhança de *pixel*, comparando os segmentos-alvo na mesma densidade de *pixels*, ainda verificando se a matriz rotulada (*label matrix*) se sobrepõe adequadamente na região pretendida. Observa-se que no caso do mapa de classe HSV, como a identificação de regiões é feita de forma

homogênea, o posicionamento do mapa de classe EM termográfica está mais a direita da imagem.

a. Cena natural 01:

Figura 5.103: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por mapa de classe EM termográfico) - cena 01 (região posicionada no dossel) - integração inicial da *fusão relacional*.

Na figura 5.104, é apresentada a integração entre os mapas de classe RGB/HSV e os mapas de distâncias retificadas - para a saída *fusão quantitativa*.

Figura 5.104: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas) - cena 01 - (região do dossel preenchida pela matriz) - integração da *fusão quantitativa*.

Observa-se que para matrizes quadradas (25×25), o posicionamento pelo algoritmo de sobreposição (*label matrix*) é estendido nas dimensões da imagem, dada a distância de captura da câmera VGA/CMOS com mesmo centro geométrico do sonar. Como as linhas de contorno nas cenas em RGB e HSV são similares, a proporção de sobreposição é idêntica nos dois espaços de cores (cada célula da matriz corresponde a $\sim 12800p.$ da imagem RGB/HSV).

Para a integração final da saída fusão relacional (figura 5.105), uma vez tendo sobrepostos os mapas de classe RGB/HSV e as matrizes de distâncias retificadas, o algoritmo de sobreposição verifica as dimensões da cena para reposicionar a região do mapa de classe EM termográfico.

Figura 5.105: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas, e mapas de classe EM termográficos) - cena 01 - (região posicionada no dossel e preenchida pela matriz) - integração final da *fusão relacional*.

b. Cena natural 02:

Figura 5.106: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por mapa de classe EM termográfico) - cena 02 (região posicionada no dossel) - integração inicial da *fusão relacional*.

Ao contrário da primeira cena, a referida na figura 5.106 necessita de uma área maior de sobreposição da região para com o dossel, sendo que no caso HSV, o espalhamento de segmentos-alvo é maior do que em RGB, dada sua distribuição homogênea.

A sobreposição das matrizes de distâncias retificadas nos mapas de classe RGB/HSV também associam a dimensão em sua totalidade, não caracterizando as bordas delimitadas pelo final do dossel, porém alocando as medidas de forma não homogênea no restante da cena, como apresentado na figura 5.107.

Figura 5.107: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas) - cena 02 - (região do dossel preenchida pela matriz) - integração da *fusão quantitativa*.

Com as três sobreposições, observa-se que no caso HSV o maior espalhamento dos segmentos-alvo provê mais condições de localização da região isolada (mapa de classe EM termográfico), ao contrário do caso RGB, que se mantém em apenas uma porção do mapa de classe RGB. Tal diferença é apresentada na figura 5.108.

Figura 5.108: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas, e mapas de classe EM termográficos) - cena 03 - (região posicionada no dossel e preenchida pela matriz) - integração final da *fusão relacional*.

c. *Cena natural 03*:

Figura 5.109: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por mapa de classe EM termográfico) - cena 03 (região posicionada no dossel) - integração inicial da *fusão relacional*.

Na sobreposição dos mapas de classe EM termográfico nos mapas de classe RGB/HSV, a distribuição nos dois espaços de cores é uniforme, dado o espalhamento de segmentos-alvo, similar nos dois mapas, como mostrado na figura 5.109.

Em ambos os casos RGB e HSV, como a imagem mantém proporção de ramos, folhas e galhos em toda a cena, a distribuição dos pontos das matrizes de distâncias retificadas como sobreposição é dada de forma homogênea (figura 5.110).

Figura 5.110: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas) - cena 03 - (região do dossel preenchida pela matriz) - integração da *fusão quantitativa*.

Na etapa final da classificação da saída *fusão relacional*, as mesmas localizações dos mapas de classe EM termográficos são mantidas, correspondendo a distribuição em toda a cena natural, para os dois casos RGB e HSV. A matriz de distâncias é usada para definir o mapeamento da árvore, estimando seu volume, centro axial, largura e outros fatores geométricos, de acordo com as dimensões da imagem RGB/HSV (figura 5.111).

Figura 5.111: Fusão de dados ponderados (mapas de classe RGB/HSV sobrepostos por matrizes de distâncias retificadas, e mapas de classe EM termográficos) - cena 03 - (região posicionada no dossel e preenchida pela matriz) - integração final da *fusão relacional*.

Para a saída *fusão qualitativa*, é discriminado apenas o vetor contendo os índices vegetativos, associados aos respectivos mapas de classe EM termográficas, descrevendo com mais detalhes visuais as características onde as manchas representam, de fato, irregularidades nos frutos, como apresentado na tabela 5.19.

Tabela 5.19: Resultados das quatro classes/percentuais na classificação das saídas pretendidas.

Cena natural	RE	R_{NIR}	R	NDRE	NDVI	Mapa de classe EM termográfico
Cena 01	24,8673	24,3574	90,6477	-0,0104	-0,5764
Cena 02	24,8701	24,3539	90,6417	-0,0105	-0,5764
Cena 03	24,8768	24,3454	90,6364	-0,0108	-0,5765
(...)	(...)	(...)	(...)	(...)	(...)	(...)
Cena n	RE_n	R_{NIRn}	R_n	$NDRE_n$	$NDVI_n$	Imagem $_n$

5.6. Considerações finais

Foram apresentadas neste capítulo, os resultados experimentais para as quatro abordagens propostas e desenvolvidas, relacionando as informações de saída destas abordagens como informações de entrada parametrizadas, uma vez que a fusão sensorial deve

integrar tais dados, demonstrando a convergência das informações qualitativas (para o pomar e fruto/biomassa), e das informações quantitativas (para o pomar e fruto/biomassa).

Na *fusão qualitativa*, o vetor que discrimina os índices vegetativos são associados aos valores estatísticos dos mapas de classe EM termográficos, integrando a informação qualitativa do pomar (abordagem 04 - índices vegetativos do sensor de refletância), com a informação qualitativa do fruto/biomassa (abordagem 02 - EM das imagens térmicas), cujas ponderações destas classificações pelo CgCP são maiores que as demais.

Na *fusão quantitativa*, a informação quantitativa do pomar (abordagem 03 - matrizes de distâncias retificadas) é integrada com a informação quantitativa do fruto/biomassa (abordagem 01 - mapas de classe RGB/HSV), também condicionada pela maior ponderação de suas respectivas classificações pelo CgCP em relação aos demais resultados.

Por fim, na *fusão relacional*, as informações qualitativas e quantitativas, respeitando a ponderação estimada pela etapa 01 do CgCP (*lógica fuzzy*), são associadas, iniciando pela sequência das abordagens 01, 02, 03 e 04, e convergidas pela etapa 02 do CgCP (RNA), com a integração primária da informação quantitativa (frutos/biomassa) dos mapas de classe RGB/HSV, para com a informação qualitativa (frutos/biomassa) dos EM termográficos, correspondendo em seguida com a informação quantitativa (pomar) das matrizes de distâncias retificadas, e finalizando com a informação qualitativa (frutos/biomassa) dos índices de refletância dos dosséis.

6. CONCLUSÕES

Quanto ao objetivo geral do trabalho, a metodologia de classificação conjunta de dados, por fusão sensorial ponderada, foi realizada de acordo com as premissas e técnicas trabalhadas. A análise qualitativa e quantitativa de frutos/produção foi feita através de cenas naturais de ambientes agrícolas, descrevendo características peculiares durante o período de plantio, maturação, conservação e colheita de culturas (citros/frutos) em épocas diferentes, de um mesmo talhão e variedade uniforme (*valência*).

Com relação as etapas que contemplam o objetivo geral:

- a) Foram desenvolvidos métodos e técnicas de aquisição de imagens perspectivas das linhas de plantio, através de câmeras posicionadas na proporção cinemática lateral dos veículos autônomos (câmeras VGA/CMOS com ajuste de orientação e posição) (*D-Link DCS-5635 N H.264 PTZ*).

As técnicas de pré-processamento de imagens, segmentação, extração e classificação de características, reconhecimento de padrões, e pós-processamento integraram plenamente os métodos aplicados de visão computacional neste trabalho, com os objetivos focados na localização e inspeção de frutos.

O algoritmo de segmentação JSEG atendeu às necessidades de aplicação com as câmeras em orientação ortogonal, paralela e diagonal para as imagens: nas cenas que apresentaram pomares distantes foram devidamente segmentadas, dadas as condições de cor e textura, em oposição aos demais objetos da cena (folhas, ramos e galhos). Em cenas com partes das árvores, os frutos foram super-segmentados, com regiões externas aos mesmos que identificam manchas ou supostas incidências de doenças. Neste caso, os parâmetros do algoritmo foram customizados na biblioteca OpenCV para caracterizar apenas as regiões de contorno dos frutos.

- b) Técnicas de determinação de parâmetros para segmentação das regiões de interesse nas imagens térmicas, foram implementadas, pela aquisição de sensor termográfico óptico, e correlação com as características de temperatura de reflexão, distância do objeto refletido e umidade relativa da cena natural (termógrafo FLIR série E-50).

Algoritmos de classificação por modelos de mistura de *Gaussianas* (*MoG*) dos segmentos das imagens térmicas e modelagem de nuvem de pontos por *Expectation Maximization* dos mapas de profundidade obtidos por fluxo óptico e sensores TIR,

foram exaustivamente avaliados, para que a validação dos dados de entrada mantivesse percentual de confirmação aceitável no classificador geral.

- c) Extração e normalização dos vetores de características das imagens RGB/HSV e térmicas por PCA (*Principal Component Analysis*) através dos histogramas de cada canal dos espaços de cores e dos parâmetros topológicos dos segmentos, aplicados as regiões de interesse para a classificação estatística.

A análise das componentes principais foi devidamente aplicada, também no processo de normalização de características da etapa de visão computacional, e se confundem também com os dados processados pós segmentação *watershed* nas imagens térmicas, e classificação *a posteriori* de elementos na superfície do fruto, como informação qualitativa.

- d) Desenvolvidas técnicas de extração de características, e construção de matrizes de distâncias, pela aquisição de sinais por sonares (XL-*MaxSonar* WRC MB7067) - mapas de profundidade, e estimação do modelo espacial, considerando medidas estatísticas para a construção de mapas de profundidade.
- e) Desenvolvidas e aplicadas técnicas de tratamento de dados obtidos do sensor de refletância, para informações sobre índices vegetativos da planta, como características qualitativas.
- f) Proposta de classificação cognitiva neural-*fuzzy* dos elementos classificados *a priori* pela aquisição de cada um dos quatro sensores, como proposta de classificação geral, associando pesos de relevância ao conteúdo computacional, quando integrados: desenvolvidos métodos para a classificação e identificação de aspectos geométricos dos objetos de interesse e fusão sensorial dos dados obtidos pelas imagens RGB/HSV, imagens térmicas, matrizes de distâncias e índices vegetativos, relacionando tamanho, forma, localização, posição e orientação, além de estimativas sobre a qualidade dos frutos.

Os resultados de cada proposta de análise sensorial, apresentam significativos modelos de fusão de informações qualitativas e quantitativas, nos métodos de processamento em visão computacional e sensores relacionados, descrevendo uma alternativa inédita de classificação, baseada em modelos cognitivos, de forma ponderada. Os dados de quantificação de frutos, quantificação da produção, qualificação dos frutos e qualificação da produção, foram devidamente trabalhados, mensurados e classificados, de acordo com a proposta inicial.

APÊNDICE A - Segmentação e classificação na proposta de visão computacional

São apresentadas abaixo, cenas naturais que foram processadas pelo algoritmo de segmentação de regiões não-homogêneas (quantização de cor e distribuição espacial), além dos respectivos mapas de classe em RGB e HSV, classificadas pelo modelo estatístico *Bayes ingênuo*, e as métricas e centróides de área, na detecção de frutos e biomassa.

Figura A.1: Cena natural RGB-a - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.

Figura A.2: Cena natural RGB-b - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.

Figura A.3: Cena natural RGB-c - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.

Figura A.4: Cena natural HSV-a - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.

Figura A.5: Cena natural HSV-b - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.

Figura A.6: Cena natural HSV-c - segmentação por regiões não-homogêneas (quantização de cores e distribuição espacial), mapa de classe, centróide de área e métricas circulares de identificação de frutos e biomassa.

APÊNDICE B - Processamento de imagens termográficas

São apresentadas abaixo, cenas naturais, com suas respectivas termografias, e o processamento de imagens (segmentação *Watershed*), com a implementação do classificador por misturas *gaussianas* EM.

Figura B.1: Cena natural RGB-a - cena de dossel completo com cena regional termográfica.

Figura B.2: Cena natural RGB-a - cena de dossel completo com cena regional termográfica.

Figura B.3: Cena natural RGB-a - cena de dossel completo com cena regional termográfica.

Figura B.4: Cena natural RGB-a - processo de segmentação *Watershed*.

Figura B.5: Cena natural RGB-b - processo de segmentação *Watershed*.

Figura B.6: Cena natural RGB-c - processo de segmentação *Watershed*.

APÊNDICE C - Matrizes de distância pelo sonar e características

São apresentadas abaixo, as características de estimação de volume pelos gráficos das séries e as superfícies tridimensionais, pelas matrizes de distância retificadas, extraídas pelo sonar.

Figura C.1: Cena natural RGB-a - composição da cena pelo gráfico de superfície.

Figura C.2: Cena natural RGB-a - Séries da cena e gráfico tridimensional de superfície.

Figura C.3: Cena natural RGB-b - composição da cena pelo gráfico de superfície.

Figura C.4: Cena natural RGB-b - Séries da cena e gráfico tridimensional de superfície.

Figura C.5: Cena natural RGB-c - composição da cena pelo gráfico de superfície.

Figura C.6: Cena natural RGB-c - Séries da cena e gráfico tridimensional de superfície.

APÊNDICE D - Índices vegetativos das plantas pelo sensor de refletância

São apresentadas abaixo, os índices vegetativos das plantas pelo sensor de refletância, bem como suas médias e distribuição gráfica.

Figura D.1: Cena regional RGB-a - imagem em RGB para aquisição dos índices de refletância.

Tabela D.1: Índices vegetativos obtidos e calculados para a cena regional RGB-a.

RE	R _{NIR}	R	NDRE	NDVI
24,9100	25,1500	90,6700	0,0004	-0,5757
24,7200	24,9100	89,6200	-0,0087	-0,5775
24,7600	24,7200	90,0900	-0,0039	-0,5686
24,7300	24,7600	90,6000	-0,0180	-0,5721
25,1500	24,6300	90,6700	-0,0182	-0,5744
24,9100	24,8300	90,5100	-0,0072	-0,5757
24,7200	24,7300	91,0300	-0,0183	-0,5760
24,1500	25,1500	90,3100	-0,0083	-0,5754
24,1400	24,9100	89,8600	-0,0131	-0,5835
24,9100	24,7200	91,1200	-0,0039	-0,5795
24,7200	24,1500	87,2900	-0,0180	-0,5735
24,7600	24,1400	90,8500	-0,0182	-0,5760
24,1500	24,4400	91,1600	-0,0072	-0,5711
24,1400	25,1500	91,4000	-0,0183	-0,5729
24,4400	24,9100	90,5700	-0,0083	-0,5757
25,1500	24,7200	90,6700	-0,0131	-0,5775
24,9100	24,7600	89,6200	0,0001	-0,5686
24,7200	24,6300	90,0900	-0,0043	-0,5721
24,1500	24,8300	90,6000	-0,0054	-0,5744
24,7000	24,5600	89,6400	-0,0029	-0,5698
24,7900	24,4600	90,3800	-0,0067	-0,5741
24,9000	24,3100	91,2600	-0,0121	-0,5793
25,0000	24,1800	90,4700	-0,0167	-0,5782
24,7400	24,5200	90,7400	-0,0046	-0,5746
25,1600	24,0000	91,5900	-0,0236	-0,5848

Figura D.2: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena regional RGB-a.

Figura D.3: Cena regional RGB-b - imagem em RGB para aquisição dos índices de refletância.

Tabela D.2: Índices vegetativos obtidos e calculados para a cena regional RGB-b.

RE	RNIR	R	NDRE	NDVI
24,7000	25,1500	90,6700	-0,0072	-0,5729
24,7400	24,7300	90,8500	-0,0183	-0,5757
25,1600	25,1500	91,1600	-0,0083	-0,5775
24,9100	24,9100	91,4000	-0,0131	-0,5686
24,7200	24,7200	90,8500	-0,0039	-0,5721
24,1500	24,1500	91,1600	-0,0180	-0,5744
24,1400	24,1400	91,4000	-0,0183	-0,5698
24,9100	24,4400	90,5700	-0,0083	-0,5741
24,7200	25,1500	90,6700	-0,0131	-0,5793
24,7600	24,7200	89,6400	-0,0067	-0,5782
24,1500	24,1500	90,3800	-0,0121	-0,5735
24,1400	24,1400	91,2600	-0,0167	-0,5760
24,4400	24,9100	90,4700	-0,0046	-0,5711

24,1500	24,7200	90,7400	-0,0183	-0,5729
24,1400	24,1500	91,5900	-0,0083	-0,5757
24,4400	24,1400	90,6700	-0,0131	-0,5775
25,1500	24,4400	89,6200	-0,0067	-0,5686
24,9100	25,1500	90,0900	-0,0121	-0,5721
25,1500	24,7200	90,6000	-0,0167	-0,5744
24,9100	24,9100	89,6400	-0,0046	-0,5698
24,7200	24,7200	90,3800	-0,0236	-0,5775
24,1500	24,7600	91,2600	-0,0083	-0,5686
24,7000	24,6300	90,4700	-0,0131	-0,5721
24,7400	24,5200	90,7400	-0,0083	-0,5744
25,1600	24,0000	91,5900	-0,0131	-0,5848

Figura D.4: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena regional RGB-b.

Figura D.5: Cena regional RGB-c - imagem em RGB para aquisição dos índices de refletância.

Tabela D.3: Índices vegetativos obtidos e calculados para a cena regional RGB-c.

RE	RNIR	R	NDRE	NDVI
24,1500	24,6300	90,8500	-0,0180	-0,5754
24,1400	24,8300	91,1600	-0,0182	-0,5835
24,9100	24,7300	91,5900	-0,0072	-0,5746
24,7200	25,1500	90,6000	-0,0183	-0,5848
24,7600	24,9100	91,0300	-0,0083	-0,5744
24,1500	24,7200	90,3100	-0,0131	-0,5757
24,1400	24,4400	89,8600	0,0001	-0,5760
24,1500	25,1500	91,1200	-0,0043	-0,5754
24,1400	24,9100	87,2900	-0,0131	-0,5835
24,9100	24,7200	91,1200	-0,0039	-0,5795
24,7200	24,7600	87,2900	-0,0180	-0,5735
24,7600	24,6300	90,8500	-0,0182	-0,5760
24,1500	24,9100	91,1600	-0,0072	-0,5711
24,1400	25,1500	90,6700	-0,0183	-0,5729
24,4400	24,9100	89,6200	-0,0083	-0,5757
25,1500	24,7200	90,0900	-0,0131	-0,5775
24,7200	24,7600	90,3100	0,0001	-0,5686
24,7600	24,6300	89,8600	0,0001	-0,5721
24,7300	24,9100	91,1200	-0,0043	-0,5744
25,1500	24,7200	89,8600	-0,0131	-0,5757
24,9100	24,7600	91,1200	-0,0039	-0,5760
24,7200	24,6300	87,2900	-0,0180	-0,5760
24,9100	24,8300	90,8500	-0,0182	-0,5754
24,7200	24,5600	91,1600	-0,0072	-0,5835
24,1500	24,0000	91,5900	-0,0183	-0,5795

Figura D.6: Distribuição dos índices vegetativos RE, R_{NIR} , R, NDRE e NDVI para a cena regional RGB-c.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ADRIAN, A. M.; NORWOOD, S. H.; MASK, P. L. *Producers' perceptions and attitudes toward precision agriculture technologies*. Computers and Electronics in Agriculture. v.48, n.3, p.256-271. 2005.

AHAMED, T.; TIAN, L.; ZHANG, Y.; TING, K.C. *A review of remote sensing methods for biomass feedstock production*. Biomass and Bioenergy, v.35, n.7, p.2455-2469. 2011.

AQEEL UR, R.; ABBASI, A.Z.; ISLAM, N.; SHAIKH, Z.A. *A review of wireless sensors and networks' applications in agriculture*. Computer Standards e Interfaces, v.In Press, Corrected Proof. 2011.

AUERNHAMMER, H.; SPECKMANN, H. *Dedicated Communication Systems and Standards for Agricultural Applications*. In: (Ed.). Handbook of Agricultural Engineering.: ASAE, v.7. Dedicated Communication Systems and Standards for Agricultural Applications, p.435-452, 2006.

BACKES, M.; PLUMER, L. *On the adequacy of GIS-generated weed maps for precision farming*. ScanGIS - Scandinavian Research Conference on Geographical Information Science, 2003.

BALSARI, P., DORUCHOWSKI, G., MARUCCO, P., TAMAGNONE, M., ZANDE, J. C., WENNEKER, M. *A System for Adjusting the Spray Application to the Target Characteristics*. Agricultural Engineering International, n.10, p.12. 2008.

BAYES, T., PRICE, M. *An Essay towards solving a Problem in the Doctrine of Chances*. Philosophical Transactions of the Royal Society of London 53: 370–418. doi:10.1098/rstl.1763.0053, 1763.

BELIN, E., ROUSSEAU, D., BOUREAU, T., CAFFIER, V. *Thermography versus chlorophyll fluorescence imaging for detection and quantification of apple scab*. Computers and Electronics in Agriculture - ELSEVIER - Volume 90, Pages 159–163, 2013.

BINNEY, J.; SUKHATME, G. *3D tree reconstruction from laser range data*. Robotics and Automation, 2009. ICRA '09. IEEE International Conference on. [S.l.: s.n.], p. 1321 - 1326, 2009.

BLASCO, J., ALEIXOS, N., GOMEZ, J. e MOLTO, E. *Citrus sorting by identification of the most common defects using multispectral computer vision algorithm*. Journal of Food Engineering 83, 384–391, 2007a.

BLASCO, J., ALEIXOS, N., MOLTO, E. (2007b). *Computer vision detection of peel defects in citrus by means of a region oriented segmentation algorithm*. Journal of Food Engineering 81, 535–543.

BLASCO, J., ALEIXOS, N., GÓMEZ-SANCHIS, J., MOLTÓ, E. *Recognition and classification of external skin damage in citrus fruits using multispectral data and morphological features*. Biosystems Engineering, v 103, n 2, p 137-145, 2009.

BITTENCOURT de, A. *Fotogrametria*. Ed. SBEE. Curitiba, Brasil, 1998.

BOGREKCI, I., LEE, W. S. *Effects of soil moisture content on absorbance spectra of sandy soils in sensing phosphorus concentrations using UV-VIS-NIR spectroscopy*. Transactions of the ASABE, v.49, n.4, Jul-Aug, p.1175-1180. 2006.

BOYLE, W. S. & SMITH, G. E. *Charge Coupled Semiconductor Devices*. Bell Sys. Tech. J. 49 (4): 587–593, 1970.

BRASE, T. *Precision Agriculture*. 1. ed. [S.l.]: Delmar Cengage Learning, 256 p., 2005.

BULANON, D. M., BURKS, T. F. e ALCHANATIS, V. *Fruit visibility analysis for robotic citrus harvesting*. Transactions of the ASABE, v 52, n 1, p 277-283, January-February 2009.

CHANG, C., WANG, H. e FU, S. *Texture image classification using modular radial basis function neural networks*. Journal of Electronic Imaging, v 19, n 1, 2010.

CHEN, T., CHAN, E. *Optimal in-place algorithms for 3-d convex hulls and 2d segment intersection*. Proceedings of the Annual Symposium on Computational Geometry, p 80-87, 2009.

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

CHENG, L. *et al.* *Dynamic triangle based method for 3D building rooftop reconstruction from Lidar data*. Geoinformatics, 19th International Conference on. [S.l.: s.n.], p. 1 - 4, 2011.

CLAY, D. E., SHANAHAN, J. F. *Nutrient Management for Energy Efficiency*. GIS Applications in Agriculture, Volume Two [S.l.]: CRC Press - Taylor and Francis, 472, 2011.

CLAWSON, K. L., JACKSON, R. D., PINTER, P. J. *Evaluating Plant Water-Stress with Canopy Temperature Differences*. Agronomy journal, v.81, n.6, Nov-Dec, p.858-863. 1989.

CORWIN, D. L.; PLANT, R. E. *Applications of apparent soil electrical conductivity in precision agriculture*. computers and electronics in agriculture, v.46, n.1-3, p.1-10. 2005.

COSTA, L. F. & CESAR JÚNIOR, R. M. *Shape analysis and classification - Theory and Practice*. 1.ed. Boca Raton, Florida, EUA: CRC Press LLC. ISBN 0-8493-3493-4, 2001.

CYGANEK, B. & SIEBERT, P. *An Introduction to 3D Computer Vision Techniques and Algorithms*. John Wiley & Sons, Ltd. ISBN: 978-0-470-01704-3; 2009.

DAY, N. E. *Estimating the Components of a Mixture of Normal Distributions*. Biometrika 56 (3): 463–474. doi:10.2307/2334652. JSTOR 2334652, 1969.

DEMPSTER, A. P., LAIRD, N. M., RUBIN, D. B. *Maximum Likelihood from Incomplete Data via the EM Algorithm*. Journal of the Royal Statistical Society, Series B 39 (1): 1–38. JSTOR 2984875, 1977.

DENG, Y., MANJUNATH, B. S. e SHIN, H. (1999a). *Color Image Segmentation*. Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition CVPR'99, Fort Collins, CO, vol. 2, pp. 446-51, 1999.

DENG, Y., KENNEDY, S., MOORE, M. S. e MANJUNATH, B. S. (1999b). *Peer group filtering and perceptual color image quantization*. Proc. IEEE International Symposium on Circuits and Systems VLSI (ISCAS'99), Orlando, FL, vol. 4, pp. 21-24., 1999.

DENG, Y. e MANJUNATH, B. S. (1999c). *An efficient low-dimensional color indexing scheme for region based image retrieval*. Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP-99), Phoenix, Arizona, 1999.

DENG, Y. e MANJUNATH, B. S. *Unsupervised segmentation of color-texture regions in images and video*. IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI '01), 2001.

DORUCHOWSKI, G., HOLOWNICKI, R. *Environmentally friendly spray techniques for tree crops*. Crop Prot. 19, 617–622; 2000.

DUDA, R. O. e HART, P. E. *Pattern Classification and Scene Analysis*. John Wiley & Sons, New York, 1970.

EASTMAN KODAK, C. *CCD Primer*. MTD/PS-0218, 2001.

EGMONT-PETERSEN, M., RIDDER, D. e HANDELS, H. *Image processing with neural networks - a review*. Pattern Recognition, v. 35, n. 10, p. 2279–2301, 2002.

EHLERT, D., HORN, H. J., ADAMEK, R. *Measuring crop biomass density by laser triangulation*. Computers and Electronics in Agriculture, v.61, n.2, May, p.117-125. 2008.

EMMI, L., PAREDES, L., RIBEIRO, A., PAJARES, G., GONZALEZ DE SANTOS, P. *Fleets of robots for precision agriculture: A simulation environment*. Industrial Robot, v 40, n 1, p 41-58, 2013.

ESTEBAN, I., DIJK, J., GROEN, F. *Automatic 3D modeling of the urban landscape*. Ultra Modern Telecommunications and Control Systems and Workshops (ICUMT), International Congress on. [S.l.: s.n.], p. 421 - 428, 2010.

FIGUEIREDO, M. A. T., JAIN, A. K. *Unsupervised learning of finite mixture models*. IEEE Transactions on Pattern Analysis and Machine Intelligence, v. 24, n. 3, p. 381–396. ISSN 0162-8828, 2002.

FLIR Systems. *Termovisores Compactos Série-E - E50*. Manual de dados, 2011.

FLORCZYK, S. *Robot Vision: Video-based Indoor Exploration with Autonomous and Mobile Robots*. WILEY-VCH Verlag GmbH & Co. KGaA, Weinheim ISBN: 3-527-40544-5, 2005.

FORSYTH, D. A., PONCE, J. *Computer Vision: A Modern Approach*. Prentice Hall - US ed., 693 p. - ISBN: 0130851981, 2002.

FREITAG, D. R., SCHAFER, R. L., WISMER, R. D. *Similitude studies of Soil-Machine Systems*. Journal of Terramechanics, v.7, n.2, p.25-58, 1970.

FROEHLICH, O. K. *Druckverteilung im Baudrunde* (Formula of Boussines). Vienna, 1934.

FUNDECITRUS. *Doenças e pragas (cancro cítrico e leprose - sintomas, ciclo e controle)*. Fundo de Defesa da Citricultura. Disponível em: www.fundecitrus.com.br. 2015.

GAO, H., XU, W., SUN, J., TANG, Y. *Multilevel thresholding for image segmentation through an improved quantum-behaved particle swarm algorithm*. IEEE Transactions on Instrumentation and Measurement, v 59, n 4, p 934-946, 2010.

GIL, E., ESCOLÀ, A., ROSELL, J. R., PLANAS, S., VAL, L. *Variable rate application of plant protection products in vineyard using ultrasonic sensors*. Crop Protection 26 1287–1297, 2007.

GILES, D. K., DELWICHE, M. J., DODD, R. B. *Control of orchard spraying based on electronic sensing of target characteristics*. Trans. ASAE 30 (6), 1624–1630, 1987.

GILES, D. K., DELWICHE, M. J., DODD, R. B. *Electronic measurement of tree canopy volume*. Trans. ASAE 31 (1), 264–272, 1988.

GNEDENKO, B. V. *The theory of probability*. Moscow: MIR, p.392., 1982.

GODOY, E. P. *Desenvolvimento de uma ferramenta de análise de desempenho de redes CAN (Controller Area Network) para aplicações em sistemas agrícolas*. 2007. 93 p. (Mestrado). Engenharia Mecânica, Universidade de São Paulo, São Carlos, 2007.

GODOY, E. P. *Desenvolvimento de Sistemas de Controle via Rede (NCS) para Aplicações em Redes com Protocolo CAN*. 249 p. Tese (Doutorado). Engenharia Mecânica, Universidade de São Paulo - Escola de Engenharia de São Carlos, São Carlos, 2011.

GONZAGA, A. *Notas de aula em Visão Computacional (Disciplina Pós-Graduação)*. Universidade de São Paulo, Escola de Engenharia de São Carlos, Departamento de Engenharia Elétrica - Laboratório de Visão Computacional (USP/EESC/SEL/LAVI) - São Carlos, São Paulo - Brasil, 2010.

GONZALEZ, R. C., WOODS, R. E. *Digital Image Processing*. 3.ed. New Jersey, EUA: Prentice-Hall Inc. ISBN 013168728X, 2007.

GOZDOWSK, D., SAMBORSKI, S. *Book Reviews - Precision agriculture*. Journal: Communications in Biometry and Crop Science, v.2, p.90-94, 2007.

GUZMAN, E., VINCENT, B., PIERRA, J. A. F., GARCIA, J. A. *Infrared machine vision system for the automatic detection of olive fruit quality*. ELSEVIER - Volume 116, 15 Pages 894–898, 2013.

HASELGROVE, L., BOTTING, D., VAN HEESWIJCK, R., HØJ, P. B., DRY, P. R., FORD, C., LAND, P. G. I. *Canopy microclimate and berry composition: The effect of bunch exposure on the phenolic composition of Vitis vinifera L cv. Shiraz grape berries*. Australian Journal of Grape and Wine Research, v.6, n.2, p.141-149, 2000.

HASTIE, T., TIBSHIRANI, R. e FRIEDMAN, J. *The elements of statistical learning*. 1.ed. New York, EUA: Springer. ISBN 0-387-95284-5, 2003.

HATFIELD, J. L., GITELSON, A. A., SCHEPERS, J. S., WALTHALL, C. L. *Application of Spectral Remote Sensing for Agronomic Decisions*. Agron. J., v.100, n.Supplement_3, 2008/5, p.S-117-S-131. 2008.

HAYKIN, S. *Neural Networks and Learning Machines*. 3.ed. McMaster University, Canada: Prentice-Hall. ISBN 0131471392, 2008.

HE, Q., CHU, C. H., CAMARGO, A. *Architectural building detection and tracking under rural environment in video sequences taken by Unmanned Aircraft System (UAS)*.

Proceedings of the 2012 International Conference on Image Processing, Computer Vision, and Pattern Recognition, IPCV. v 1, p 138-143, 2012.

HOLLAND SCIENTIFIC. *Fabricante do sensor óptico de refletância Crop Circle*. Disponível em www.hollandscientific.com, 2015.

HONG-WEI, L. *et al.* *The reconstruction of three-dimensional tree models from terrestrial Lidar*. Computer Science and Automation Engineering (CSAE), 2011 IEEE International Conference on. [S.l.: s.n.], 2011. v. 4, p. 371 - 374, 2011.

HUETE, A. R. *A Soil-Adjusted Vegetation Index (SAVI)*. Remote Sensing of Environment, v.25, n.3, Aug, p.295-309, 1988.

HUNG, C., BRYSON, M., SUKKARIEH, S. *Multi-class predictive template for tree crown detection*. ISPRS Journal of Photogrammetry and Remote Sensing, v 68, n 1, p 170-183, March, 2012.

IDSO, S. B., JACKSON, R. D., PINTER, P. J., REGINATO, R. J., HATFIELD, J. L. *Normalizing the Stress-Degree-Day Parameter for Environmental Variability*. Agricultural Meteorology, v.24, n.1, p.45-55, 1981.

IGEL, C., HÜSKEN, M. *Improving the RPROP learning algorithm*. In: Proceedings of the Second International ICSC Symposium on Neural Computation (ICSC Academic Press), p. 115–121, 2000.

INAMASU, R. Y., SOUZA, R. V., PORTO, A. J. V., FORTES, C., LUCHIARI, A., SCHEPES, J. S., FRANCIS, D. D. *Acesso ao estado nutricional da cana de açúcar por meio de sensor ativo de refletância*. In: Congresso Brasileiro de Agricultura de Precisão, Anais... São Pedro: ESALQ/USP, 8p., 2006.

JACKSON, R. D., IDSO, S. B., REGINATO, R. J., JR, P. J. P. *Canopy temperature as a crop water stress indicator*. Water Resources Research, v.17, n.4, p.1133-1138, 1981.

JAHN, O. L. *Penetration of Photosynthetically Active Radiation as a Measurement of Canopy Density of Citrus Trees*. Journal of the American Society for Horticultural Science, v.104, n.4, p.557-560, 1979.

JENSEN, J. R. *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. Tradução da segunda edição. São José dos Campos, SP: Parêntese. 598 p., 2009.

JEON, H. Y., ZHU, H., DERKSEN, R., OZKAN, E., KRAUSE, C. *Evaluation of ultrasonic sensor for variable-rate spray applications*. Computers and Electronics in Agriculture 75 213–221, 2011.

JIANYUAN, D., CHONGYANG, H. *3D fast level set image segmentation based on Chan-Vese model*. 3rd International Conference on Bioinformatics and Biomedical Engineering, iCBBE 2009.

JORDAN, C. F. *Derivation of Leaf-Area Index from Quality of Light on the Forest Floor*. Ecology, v.50, n.4, p.663-666. 1969.

KANO, Y., MCCLURE, W. F., SKAGGS, R. W. *A near-Infrared Reflectance Soil-Moisture Meter*. Transactions of the ASAE, v.28, n.6, Nov-Dec, p.1852-1855. 1985.

KHOSLA, R., INMAN, D., REICH, R., WESTFALL, D. G. *Normalized difference vegetation index and soil color-based management zones in irrigated maize*. Agronomy journal, v.100, n.1, Jan-Feb, p.60-66. 2008.

KNIPLING, E. B. *Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation*. Remote Sensing of Environment, 1970.

KRISHNAN, P., ALEXANDER, J. D., BUTLER, B. J., HUMMEL, J. W. *Reflectance Technique for Predicting Soil Organic-Matter*. Soil Science Society of America Journal, v.44, n.6, p.1282-1285. 1980.

KUCKENBERG, J., TARTACHNYK, I., NOGA, G. *Temporal and spatial changes of chlorophyll fluorescence as a basis for early and precise detection of leaf rust and powdery mildew infections in wheat leaves*. Precision Agriculture, v.10, n.1, p.34-44. 2009.

LADONI, M., BAHRAMI, H., ALAVIPANAH, S., NOROUZI, A. *Estimating soil organic carbon from soil reflectance: a review*. Precision Agriculture, v.11, n.1, p.82-99. 2010.

LAINI, A.; BARTOLI, M.; LAMASTRA, L.; CAPRI, E.; BALDERACCHI, M.; TREVISAN, M. *Herbicide contamination and dispersion pattern in lowland springs*. Science of the Total Environment, v 438, p 312-318, November 1, 2012.

LAMB, D. W., HUANG, W., NIU, Z., ZHANG, Y., LIU, L., WANG, J. *Identification of yellow rust in wheat using in-situ spectral reflectance measurements and airborne hyperspectral imaging*. Precision Agriculture, v.8, n.4-5, Oct, p.187-197. 2007.

LAROSE, D. T. *Data Mining and predictive analytics*. John Wiley and Sons, Inc, 2015.

LEE, G., WILFRED, O., YEOM, J., CHO, B. *Extraction of Key Postures using Shape Contexts*. International Conference on Advanced Communication Technology, ICACT, v 2, p 1311-1314, 2009.

LEE, W.S.; ALCHANATIS, V.; YANG, C.; HIRAFUJI, M.; MOSHOU, D.; LI, C. *Sensing technologies for precision specialty crop production*. Computers and Electronics in Agriculture, v.74, n.1, p.2-33. 2010.

LEKHAL, F., NASRI, M., HITMY, M. *A general scheme for texture images classification, by a genetic method, for artificial vision quality control*. Proceedings of the 2008 International Conference on Image Processing, Computer Vision, and Pattern Recognition, IPCV 2008, p 435-439, 2008.

LEON, C. T., SHAW, D. R., COX, M. S., ABSHIRE, M. J., WARD, B., WARDLAW, M. C., WATSON, C. *Utility of Remote Sensing in Predicting Crop and Soil Characteristics*. Precision Agriculture, v.4, n.4, p.359-384. 2003.

LEVINE, M. D. *Vision in man and machine*. 1. ed. Nova Iorque, EUA: McGraw-Hill, Inc. ISBN 0-07-037446-5, 1985.

LI, J., RAO, X., YING, Y., MA, B., GUO, J. *Background and external defects segmentation of navel orange based on mask and edge gray value compensation algorithm*. Transactions of the Chinese Society of Agricultural Engineering, v 25, n 12, p 133-137, 2009.

LI, Z., HONG, T., WANG, W., SONG, S. *Automatic detection of growing orange fruits by machine vision*. ASABE Annual International Meeting, Technical Papers, v 8 BOOK, 2007.

LIMING, X., TANCHAO, Z. *Automated strawberry grading system based on image processing*. Computers and Electronics in Agriculture, v 71, n SUPPL. 1, p S32-S39, 2010.

LOPEZ, J. J., AGUILERA, E., COBOS, M. *Defect detection and classification in citrus using computer vision*. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), v 5864 LNCS, n PART 2, p 11-18, 2009, Neural Information Processing - 16th International Conference, ICONIP 2009.

LÜ, K., CAI, J., ZHAO, J., WANG, F., TANG, M. *Real-time recognition of citrus on trees in natural scene*. Transactions of the Chinese Society of Agricultural Machinery, v 41, n 2, p 185-188+170, 2010.

LUCCHESI, L., MITRA, S. K. *A new method for color image equalization*. IEEE International Conference on Image Processing, v 1, p 133-136, 2001.

LUCCHESI, L., MITRA, S. K. *A new class of chromatic filters for color image processing*. Theory and applications. IEEE Transactions on Image Processing, v 13, n 4, p 534-548, 2004.

LULIO, L. C., TRONCO, M. L., PORTO, A. J. V. *JSEG-based Image Segmentation in Computer Vision for Agricultural Mobile Robot Navigation*. In: CIRA - IEEE International Symposium on Computational Intelligence in Robotics and Automation, 2009, Daejeon. Proceedings of IEEE CIRA 2009a.

LULIO, L. C., TRONCO, M. L., PORTO, A. J. V. *Mobile Robot Navigation with JSEG-based Image Segmentation Technique in Computer Vision*. In: 30th CILAMCE - Iberian-Latin-American Congress on Computational Methods in Engineering, 2009, Armação dos Búzios - RJ. Proceedings of ABMEC (Brazilian Association for Computational Methods in Engineering), 2009b.

LULIO, L. C., PORTO, A. J. V., TRONCO, M. L. *Pattern Recognition Structured Heuristics Methods for Image Processing in Mobile Robot Navigation* - IEEE International Conference on Robotics Systems (IROS'10). IEEE Robotics e Automation Magazine, 2010.

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

LULIO, L. C., TRONCO, M. L., PORTO, A. J. V. *JSEG Algorithm and Statistical ANN Image Segmentation Techniques for Natural Scenes* - Capítulo de Livro – Image Segmentation – INTECH Publishing. ISBN 978-953-307-228-9. 2011b.

LULIO, L. C., TRONCO, M. L., PORTO, A. J. V. *Cognitive-Merged Statistical Pattern Recognition Method for Image Processing in Mobile Robot Navigation*. Brazillian Robotics Symposium e Latin American Robotics Symposium (SBR-LARS), Fortaleza, Brazil, 2012a.

MALYSZCO, D., STEPANIUK, J. *Rough entropy based K-means clustering*. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), v 5908 LNAI, p 406-413, 2009, Rough Sets, Fuzzy Sets, Data Mining and Granular Computing - 12th International Conference, RSFDGrC, 2009.

MALYSZCO, D., STEPANIUK, J. *Adaptive multilevel rough entropy evolutionary thresholding*. Information Sciences, v 180, n 7, p 1138-1158, April 1, 2010.

MCCULLOCH, W., PITTS, W. *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics, 7:115 - 133, 1943.

MENEGATTI, L. A. A., MOLIN, J. P. *Remoção de erros em mapas de produtividade via filtragem de dados brutos*. Revista Brasileira de Engenharia Agrícola e Ambiental, v.8, n.1, p.126-134, 2004.

MEURIE, C., RUICHEK, Y., COHEN, A., MARAIS, J. *A hybrid and adaptive segmentation method using color and texture information*. Proceedings of SPIE - The International Society for Optical Engineering, v 7538, 2010, Proceedings of SPIE-IS and T Electronic Imaging - Image Processing: Machine Vision Applications III, 2010.

MEWADA, H., PATNAIK, S. *Variable Kernel based Chan-Vese model for image segmentation*. Proceedings of INDICON - An IEEE India Council Conference, 2009.

MCBRATNEY, A., WHELAN, B., ANCEV, T., BOUMA, J. *Future Directions of Precision Agriculture*. Precision Agriculture, v.6, n.1, p.7-23. 2005.

MERON, M., TSIPRIS, J., ORLOV, V., ALCHANATIS, V., COHEN, Y. *Crop water stress mapping for site-specific irrigation by thermal imagery and artificial reference surfaces*. Precision Agriculture, v.11, n.2, April, p.148-162. 2010.

MOLIN, J. P. *Agricultura de Precisão - O Gerenciamento da Variabilidade*. Piracicaba, v.1. 2001.

MOLLER, M., ALCHANATIS, V., COHEN, Y., MERON, M., TSIPRIS, J., NAOR, A., OSTROVSKY, V., SPRINTSIN, M., COHEN, S. *Use of thermal and visible imagery for estimating crop water status of irrigated grapevine*. Journal of Experimental Botany, v.58, n.4, Mar, p.827-838, 2007.

MOORTHY, I. *et al. Extracting tree crown properties from ground-based scanning laser data*. Geoscience and Remote Sensing Symposium IGARSS. IEEE International. [S.l.: s.n.], 2007. p. 2830 - 2832, 2007.

MOTTUS, M., SULEV, M., LANG, M. *Estimation of crown volume for a geometric radiation Model from detailed measurements of tree structure*. ecological modeling 198 506-514, 2006.

NAIDU, R. A., PERRY, E. M., PIERCE, F. J., MEKURIA, T. *The potential of spectral reflectance technique for the detection of Grapevine leaf roll-associated virus-3 in two red-berried wine grape cultivars*. Computers and Electronics in Agriculture, v.66, n.1, Apr, p.38-45. 2009.

NANDEDKAR, A. *Supervised colour image segmentation using granular reflex fuzzy min-max neural network*. Proceedings of SPIE - The International Society for Optical Engineering, v 7546, 2010, 2nd International Conference on Digital Image Processing, 2010.

NIEUWENHUIZEN, A., TANG, L., HOFSTEE, J., MÜLLER, J., VAN HENTEN, E. *Colour based detection of volunteer potatoes as weeds in sugar beet fields using machine vision*. Precision Agriculture, v.8, n.6, p.267-278. 2007.

NISSEN, H. J. e HENNINGER, G. *ISOBUS Status of Standardization and Implementation*. Workshop ISOBUS Brasil. Nissen H. J. is the Supervisor Systems Engineering of John Deere AMS Europe, 2008.

OLIVEIRA, C. *Montagem e Utilização de Ambientes Virtuais Agrícolas em um Sistema de Multiprojeção Imersivo a partir de Cenas Naturais*. 200p. Tese de Doutorado - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

PAYNE, A.B., WALSH, K.B., SUBEDI, P.P., JARVIS, D. *Estimation of mango crop yield using image analysis – Segmentation method*. Computers and Electronics in Agriculture - ELSEVIER Volume 91, February 2013, Pages 57–64, 2013.

PEDRO, L. M. (2008a). *Fixação de objetos por garras de robôs: aplicações de redes neurais e proposta de auto-aprendizagem para os casos 2D e 3D*. (Dissertação Mestrado). Escola de Engenharia de São Carlos/Universidade de São Paulo (EESC/USP). São Carlos, São Paulo - Brasil, 2008.

PEDRO, L. M., DIAS, A. L., MASSARO, L. C. e CAURIN, G. A. P. (2008b). *Dynamic Modeling and hardware-in-the-loop Simulation applied to a Mechatronic Project*. In: ABCM Symposium Series in Mechatronics, vol.3, 2008.

PEDRO, L. M. e CAURIN, G. A. P. (2008c). *Algoritmo de Rápido Processamento Baseado em Redes Neurais Artificiais para Fixação de Objetos Desconhecidos por Garras Industriais*. Revista Minerva, v. 4, p. 1-14, 2008.

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

PORTILLO, J., CABANES, I., MARCOS, M., ESTEVEZ, E. *CANopen Network for μ controller-based Real Time Distributed Control Systems*. IEEE, p. 4644-4649, 2006.

RAO, X. Q., YING, Y. *Grading a fruit by it's surface color*. Proceedings of SPIE - The International Society for Optical Engineering, v 5996 (Optical Sensors and Sensing Systems for Natural Resources and Food Safety and Quality), 2009.

RATLE, F., CAMPS, V., WESTON, J. *Semisupervised neural networks for efficient hyperspectral image classification*. IEEE Transactions on Geoscience and Remote Sensing, v 48, n 5, p 2271-2282, May, 2010.

RIVERA, N. V., SANCHIS, J. G., PÉREZ, J. C., CASSARSCO, J. J., GIRALDO, M. M., LORENTE, D., CUBERO, S., BLASCO, J. *Early detection of mechanical damage in mango using NIR hyperspectral images and machine learning*. Biosystems Engineering Journal, Elsevier. <http://dx.doi.org/10.1016/j.biosystemseng.2014.03.009>. 2014.

ROUSE, J. W., HAAS, R. H., SCHELL, J. A., DEERING, D. W. *Monitoring vegetation systems in the Great Plains with ERTS*. Proceedings of the Third ERTS Symposium. Washington DC, 309-317 p., 1973.

RUSSELL, S., NORVIG, P. *Artificial Intelligence: A Modern Approach*. Prentice-Hall, 3rd edition - USA. ISBN: 0136042597, 2009.

SALEEM, S., UZ ZAMAN, Q, SCHUMANN, A., MADANI, A., PERCIVAL, D. *Impact of variable rate fertilization on ground water contamination in wild blueberry cropping system*. American Society of Agricultural and Biological Engineers Annual International Meeting, v 4, p 2956-2966, 2011.

SANTOS, D. P. *Seleção de características: abordagem via redes neurais aplicada a segmentação de imagens*. (Dissertação de Mestrado) - Instituto de Ciências Matemáticas e de Computação/Universidade de São Paulo (ICMC/USP). São Carlos, São Paulo - Brasil, 2006.

SARKATE, R.; KAYANKAR, N. V., KHANALE, P. B.; *Application of computer vision and color image segmentation for yield prediction precision*. Proceedings of the International Conference on Information Systems and Computer Networks, ISCON 2013, p 9-13, 2013.

SAVAKAR, D., ANAMI, B. S. *Recognition and classification of food grains, fruits and flowers using machine vision*. International Journal of Food Engineering, v 5, n 4, 2009.

SCHELLBERG, J., HILL, M. J., GERHARDS, R., ROTHMUND, M., BRAUN, M. *Precision agriculture on grassland: Applications, perspectives and constraints*. European Journal of Agronomy, v.29, n.2-3, p.59-71. 2008.

SHIIGI, T., KONDO, N., KURITA, M., KAMATA, J. *Strawberry harvesting robot for fruits grown on table top culture*. American Society of Agricultural and Biological Engineers Annual International Meeting 2008, v 5, p 3139-3148, 2008.

SHIRATSUCHI, L. S., BRANDÃO, Z. N., VICENTE, L. E., VICTORIA, D. C., DUCATI, J. R., OLIVEIRA, R. P., VILELA, M. F. *Sensoriamento remoto: conceitos básicos e aplicações na agricultura de precisão*. In: Agricultura de precisão: um novo olhar. São Carlos, SP: Embrapa Instrumentação, p. 307-313, 2014.

SHOU, Z., WANG, Q., GUI, J., WANG, Y. *Fruit shape detection by optimizing Chan-Vese model*. Proceedings of SPIE - The International Society for Optical Engineering, v 7495, 2009, MIPPR 2009 - Automatic Target Recognition and Image Analysis, 2009.

SEBE, N., COHEN, I., GARG, A. e HUANG, T. S. *Machine Learning in Computer Vision (Computational Imaging and Vision)*. Springer - 1. ed., 242 p. - ISBN: 1402032745, 2005.

SI, Y., LIU, G., GAO, R. *Segmentation algorithm for green apples recognition based on k-means algorithm*. Transactions of the Chinese Society of Agricultural Machinery, v 40, n SUPPL. 1, p 100-104, 2009.

SIMION, G., GUI, V., OTESTEANU, M. *Hand posture recognition using compositional techniques*. Proceedings - 5th International Symposium on Applied Computational Intelligence and Informatics, SACI 2009, p 435-439, 2009.

SIRAKOV, N., USHKALA, K. *An integral active contour model for convex hull and boundary extraction*. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), v 5876 LNCS, n PART 2, p 1031-1040, 2009, Advances in Visual Computing - 5th International Symposium, ISVC, 2009.

SLAUGHTER, D. C., STAAB, E. S., GILES, D. K., DOWNEY, D., ZHANG, Y. *Precision automated weed control using hyperspectral vision identification and heated oil*. American Society of Agricultural and Biological Engineers Annual International Meeting, v 6, p 3567-3583, 2009.

SOLANELLESI, F., ESCOLÀ, A., PLANAS, S., ROSELL, F., GRACIA, F. *An Electronic Control System for Pesticide Application Proportional to the Canopy Width of Tree Crops*. Biosystems Engineering 95 (4), 473-481, 2006.

SOLANELLES, F., PLANAS, S., ESCOLA, A., ROSELL, J.R. *Spray application efficiency of an electronic control system for proportional application to the canopy volume*. Aspects Appl. Biol. Int. Adv. Pestic. Appl. 66, 139-146, 2002.

SOUZA, R. V. *CAN (Controller Area Network): Uma abordagem para automação e controle na área agrícola*. Dissertação (Mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo. p. 84. São Carlos, SP Brasil, 2002.

SRINIVASAN, A. *Handbook of precision agriculture: principles and applications*. Bringhamton, NY: Food Products Press. xxv, 683 p., 2006.

STOLLER, J. *Guia de sintomas, características e elementos químicos reagentes em doenças na citricultura*. Disponível em: www.stoller.com.br, 2015.

STORY, D., KACRIA, M., KUBOTA, C., AKOGLU, A. e AN, L. *Lettuce calcium deficiency detection with machine vision computed plant features in controlled environments*. Computers and Electronics in Agriculture, 2010.

STROTHOFF, S. *et al. Interactive generation of virtual environments using mUAVs*. Proceedings of International Symposium on VR innovation (ISVRI). [S.l.: s.n.], 2011.

SUVINEN, A., SAARILAHTI, M. *Measuring the mobility parameters of forwarders using GPS and CAN bus techniques*. Journal of Terramechanics, v. 43, p. 237-252, 2006.

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

TANGERINO, G. T. *Sistemas de sensoriamento embarcado para uso em controle de aplicações de insumos agrícolas à taxa variável*. 2009. 125p. Mestrado. Engenharia Mecânica, Universidade de São Paulo, São Carlos, 2009.

TANGERINO, G. T. *Método de amostragem de área agrícola com sensores embarcados: uma abordagem que leva em conta a variabilidade do campo*. São Carlos, 131p. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2014.

THAMRIN, N. M., ARSHAD, N. M., ADNAN, R., SAM, R., RAZAK, N. *Simultaneous localization and mapping based real-Time inter-row tree tracking technique for unmanned*

aerial vehicle. Proceedings - IEEE International Conference on Control System, Computing and Engineering, ICCSCE 2012. p 322-327, 2012.

THRUN, S., BURGARD, W. e FOX, D. *Probabilistic Robotics (Intelligent Robotics and Autonomous Agents)*. The MIT Press, 667 p. - ISBN: 0262201629, 2005.

TILLET, N. D., HAGUE, T., GRUNDY, A. C., DEDOUSIS, A. P. *Mechanical within-row weed control for transplanted crops using computer vision*. Biosystems Engineering, v.99, n.2, Feb, p.171-178. 2008.

TRONCO, M. L. *Sistema de reconhecimento de imagens baseado no modelo GSN de rede neural*. (Tese Doutorado). Escola de Engenharia de São Carlos/Universidade de São Paulo (EESC/USP). São Carlos, São Paulo - Brasil, 1999.

TRONCO, M. L. *Segmentação de cenas agrícolas - uma contribuição à geração de parâmetros para uso em sistema de multiprojeção imersiva*. Tese de Livre Docência. EESC/USP. São Carlos/SP, Brasil, janeiro de 2013.

TUCKER, C. J., HOLBEN, B. N., ELGIN, J. H., MCMURTREY, J. E. *Relationship of Spectral Data to Grain-Yield Variation*. Photogrammetric Engineering and Remote Sensing, v.46, n.5, p.657-666. 1980.

VIÑA, A., GITELSON, A. A., NGUY-ROBERTSON, A. L., PENG, Y. *Comparison of different vegetation indices for the remote assessment of green leaf area index of crops*. Remote Sensing of Environment, v. Article in Press, n.0. 2011.

WACHS, J., STERN, H., BURKS, T., ALCHANATIS, V. *Multi-modal Registration Using a Combined Similarity Measure*. Applications of Soft Computing. In: E. Avineri, 2009.

WALKLATE, P. J., Cross, J. V., Richardson, G. M., Baker, D. E. *Optimizing the adjustment of label-recommended dose rate for orchard spraying*. Crop Prot. 25, 1080–1086, 2006.

WANG, J., ZHAO, D., JI, W. e ZHANG, C. *Apple fruit recognition based on support vector machine using in harvesting robot*. Transactions of the Chinese Society of Agricultural Machinery, v 40, n 1, p 148-151+147, 2009.

WENG, S.; ZHAO, G.; HE, B. *Rapid reconstruction of 3D building models from aerial images and Lidar data*. Advanced Computer Theory and Engineering (ICACTE), 3rd International Conference on. [S.l.: s.n.], 2010. v. 2, p. V2-195-V2-198, 2010.

WEI, J., WANG, J. J., ZHAO, D. e TU, J. J. *Application of support vector machine to apple recognition using in apple harvesting robot*. IEEE International Conference on Information and Automation, ICIA 2009, p 1110-1115, 2009.

WILES, L. J. *Software to quantify and map vegetative cover in fallow fields for weed management decisions*. Computers and Electronics in Agriculture, v 78, n 1, p 106-115, August, 2011.

WIENER, N. *Extrapolation, Interpolation and Smoothing of Stationary Time Series*. The MIT Press, Cambridge, USA, 1942.

WISMER, R. D., LUTH, H. J. *Off-Road Traction Prediction for Wheeled Vehicles*. Transactions of the ASAE, v.17, n.1, p.8-&. 1974.

XIA, Y., FENG, D. *A general image segmentation model and its application*. Proceedings of the 5th International Conference on Image and Graphics, ICIG 2009, p 227-231, 2010.

YANG, C. H., EVERITT, J. H., BRADFORD, J. M., ESCOBAR, D. E. *Mapping grain sorghum growth and yield variations using airborne multispectral digital imagery*. Transactions of the ASAE, v.43, n.6, Nov-Dec, p.1927-1938. 2000.

YANG, C. H., EVERITT, J. H., BRADFORD, J. M. *Comparison of QuickBird satellite imagery and airborne imagery for mapping grain sorghum yield patterns*. Precision Agriculture, v.7, n.1, Mar, p.33-44. 2006.

YE, X., SAKAI, K., SASAO, A., ASADA, S. I. *Potential of airborne hyperspectral imagery to estimate fruit yield in citrus*. Chemometrics and Intelligent Laboratory Systems, v.90, n.2, p.132-144. 2008.

YIN, J., MAO, H., HU, Y., WANG, X., CHEN, S. *Segmentation methods of fruit image and comparative experiments*. Proceedings - International Conference on Computer Science and Software Engineering, CSSE 2008, v 1, p 1098-1102., 2008.

ZADEH, L. A. *Fuzzy sets: information and control*. V. 8: 338-353.1965, 1965.

ZHANG, F., YING, Y., SHEN, C., JIANG, H. e ZHANG, Q. *Stereovision-based 3D field recognition for automatic guidance system of off-road vehicle*. Proceedings of SPIE - The International Society for Optical Engineering, v 6000, 2005, Two- and Three-Dimensional Methods for Inspection and Metrology III, 2005.

ZHANG, H. Image segmentation evaluation: *A survey of unsupervised methods*. Computer Vision and Image Understanding, v 110, n 2, p 260-280, 2008.

ZHANG, F., XU, G., ZHANG, Y., CHENG, Y., WANG, J. e TIAN, J. *Color image segmentation using combined information of color and texture*. Proceedings of the 2009 Chinese Conference on Pattern Recognition, CCPR 2009, and the 1st CJK Joint Workshop on Pattern Recognition, CJKPR, p 290-293, 2009.

ZHANG, X. F., ZHAO, J. P., SUN, Q. A., WANG, X. Y., GUO, Y. L., LI, J. *Soil Moisture Retrieval From AMSR-E Data in Xinjiang (China): Models and Validation*. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, v.4, n.1, Mar, p.117-127. 2011.

ZHAO, J., LIU, S., ZOU, X., SHI, J., YIN, X. *Recognition of defect Chinese dates by machine vision and support vector machine*. Transactions of the Chinese Society of Agricultural Machinery, v 39, n 3, p 113-115+147, 2008.

ZHU, C. *et al.* *Cluster-based construction of tree crown from scanned data. Plant Growth Modeling, Simulation, Visualization and Applications (PMA)*. Third International Symposium on. [S.l.: s.n.], 2009. p. 352 - 359, 2009.

ZYL, J.L.V. *Canopy temperature as a water stress indicator in vines*. Vitivultural and Oenological Research Institute, v.7, n.2, p.53-60. 1986.