

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

**ESTIMATIVA DO NÚMERO DE FRUTOS VERDES EM
LARANJEIRAS COM O USO DE IMAGENS DIGITAIS**

Walter Maldonado Junior
Engenheiro agrônomo

2016

**UNIVERSIDADE ESTADUAL PAULISTA – UNESP
CÂMPUS DE JABOTICABAL**

**ESTIMATIVA DO NÚMERO DE FRUTOS VERDES EM
LARANJEIRAS COM O USO DE IMAGENS DIGITAIS**

Walter Maldonado Junior
Orientador: José Carlos Barbosa

Tese apresentada à Faculdade de Ciências
Agrárias e Veterinárias - Unesp, Câmpus de
Jaboticabal, como parte das exigências para
a obtenção do título de Doutor em Agronomia
(Produção Vegetal)

M244e Maldonado Jr, Walter
Estimativa do número de frutos verdes em laranjeiras com o uso de imagens digitais / Walter Maldonado Junior. – – Jaboticabal, 2016
xiv, 110 p. : il. ; 28cm

Tese (doutorado) – Universidade Estadual Paulista, Faculdade de Ciências Agrárias e Veterinárias, 2016
Orientador: José Carlos Barbosa
Banca examinadora: Eduardo Sanches Stuchi, Haroldo Xavier Linhares Volpe, José Antonio Alberto da Silva, Cristiano Zerbato

Bibliografia

1. Laranja. 2. Previsão de safra. 3. Visão computacional. 4. Agricultura de precisão. 5. Detecção de frutos. I. Título. II. Jaboticabal – Faculdade de Ciências Agrárias e Veterinárias.

CDU 634.31:004.932

Ficha catalográfica elaborada pela Seção Técnica de Aquisição e Tratamento da Informação – Serviço Técnico de Biblioteca e Documentação - UNESP, Câmpus de Jaboticabal.
E-mail: walter@agroestat.com.br

DADOS CURRICULARES DO AUTOR

Walter Maldonado Junior, nascido em nove de agosto de 1987 na cidade de Bebedouro-SP, Brasil. Concluiu o curso de graduação em agronomia pela Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal (UNESP) no ano de 2010 com iniciação científica na área de distribuição espacial de pragas doenças recebendo o prêmio “Agronomia” de melhor trabalho de graduação nesse ano, no qual foi desenvolvido um plano de amostragem seqüencial para o ácaro da leprose dos citros *Brevipalpus phoenicis*. Obteve o título de Mestre em Agronomia (Produção Vegetal) no ano de 2013 desenvolvendo sua dissertação também na área de distribuição espacial de pragas e doenças, desenvolvendo um plano de amostragem sequencial agora para o gorgulho da bananeira *Cosmopolites sordidus*. Obteve, pela defesa desta tese, o título de Doutor em Agronomia (Produção Vegetal) no ano de 2016 na área de ciência da computação aplicada à Agronomia, desenvolvendo um método automático para a contagem de frutos verdes em imagens de laranjeiras para ser utilizado em procedimentos de estimativa de produção de talhões isolados da cultura. Desempenhou função de estagiário no Departamento de Ciência Exatas dessa mesma instituição prestando assessoria na área de estatística, experimentação agrônômica e ciência da computação aplicada à Agronomia. Atua também na área de estatística experimental aplicada à Agronomia sendo autor do livro “Experimentação Agronomia & AgroEstat – Sistema para Análises Estatísticas de Ensaaios Agronômicos” e do software para realização de análises estatísticas que automatiza os métodos abordados no livro que o acompanha.

“Todo o conhecimento tem origem na nossa percepção”

Leonardo da Vinci

A meus pais e à minha esposa

AGRADECIMENTOS

Ao Criador pela oportunidade.

A meus pais Walter e Eunice e à minha esposa Ana Paula pelo apoio e compreensão. Especialmente à minha esposa pela colaboração com as contagens manuais dos frutos nas imagens deste trabalho.

Ao Prof. Dr. José Carlos Barbosa pela orientação e apoio.

À Citrosuco pela colaboração com a obtenção das imagens utilizadas neste trabalho.

À Associação de Pós-graduandos desta unidade, que me propiciou a oportunidade de aprender e servir.

À FCAV/UNESP Jaboticabal pela infra-estrutura fornecida.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo financiamento deste projeto (Processo n. 140600/2013-2).

Ao programa de pós-graduação em Agronomia (Produção Vegetal) pelas disciplinas de excelente qualidade, contando com professores altamente capacitados e pelo suporte e infra-estrutura oferecidos.

A meus colegas Paulo, Ricardo e Gilberto pelo aprendizado e pelos momentos de descontração.

SUMÁRIO

	Página
LISTA DE TABELAS	vii
LISTA DE FIGURAS	ix
1 INTRODUÇÃO	1
2 REVISÃO DE LITERATURA	5
2.1 Estimativa da produção de citros	5
2.2 Processamento de imagens digitais	7
2.3 Filtros de Gabor	8
2.4 O baixo-relevo simulado	8
2.5 Reconhecimento e Interpretação	11
2.5.1 <i>O Aprendizado de Máquina e a Teoria de Aprendizado Estatístico</i>	11
2.5.2 <i>Máquinas de Vetores de Suporte (SVMs)</i>	13
3 MATERIAL E MÉTODOS	15
3.1 Estimativa do número de frutos por planta	15
3.2 Filtros de Gabor	16
3.3 Geração das imagens de baixo-relevo simulado	18
3.3.1 <i>Conversão do modelo de cores</i>	19
3.3.2 <i>Limiarização global simples</i>	21
3.3.3 <i>Convolução</i>	21
3.3.4 <i>Filtragem espacial</i>	22
3.3.5 <i>Ajustes de iluminação</i>	23
3.3.6 <i>O operador de Sobel</i>	23
3.3.7 <i>O operador laplaciano</i>	25
3.4 Segmentação e contagem dos frutos	27
3.4.1 <i>Máscaras espaciais</i>	27
3.4.2 <i>Máquinas de Vetores de Suporte (SVMs)</i>	28
3.4.3 <i>A transformada de Hough</i>	29
3.4.4 <i>Estratégia utilizada pelo algoritmo de reconhecimento dos frutos</i>	30
3.5 Determinação do número de imagens necessário para a estimativa do número de frutos visíveis por planta	32
4 RESULTADOS E DISCUSSÃO	33
4.1 Extração das características dos frutos com uso dos filtros de Gabor	33

4.2	Extração das características dos frutos com o uso de imagens de baixo-relevo simulado	34
4.3	Comparação do método de contagem automática com o método de contagem manual nas imagens	45
4.3.1	<i>Influência da qualidade das imagens nos resultados do algoritmo de detecção e contagem automática</i>	53
4.3.2	<i>Tempo despendido nos métodos de contagem</i>	55
4.3.3	<i>Avaliação do desempenho do algoritmo quanto à detecção dos frutos</i>	55
4.3.4	<i>Determinação do número de imagens necessário para a estimativa do número de frutos visíveis</i>	56
4.4	Comparação dos métodos de contagem de frutos manual e automático em imagens para a estimativa do total de frutos por planta	60
4.5	Considerações finais	69
5	CONCLUSÕES	73
6	REFERÊNCIAS	75
APÊNDICE A	Exemplos de geração de imagens de baixo-relevo simulado a partir de imagens digitais de laranjeiras	87
APÊNDICE B	Resultado da detecção automática de frutos verdes em imagens obtidas em boas condições	93
APÊNDICE C	Resultado da detecção automática de frutos verdes em imagens obtidas em más condições	99
APÊNDICE D	Códigos-fonte	103

ESTIMATIVA DO NÚMERO DE FRUTOS VERDES EM LARANJEIRAS COM O USO DE IMAGENS DIGITAIS

RESUMO – A estimativa da produtividade é um fator importante no planejamento de um processo produtivo. No caso dos citros, pode colaborar com o gerenciamento do processo industrial e servir como orientação para os produtores, apresentando papel decisivo no mercado do produto e no manejo de tratos culturais. Vários estudos de técnicas para estimativa da produção da cultura vêm sendo realizados mas ainda apresentando limitações. Devido à correlação entre o número de frutos visíveis na imagem de uma planta e o número real de frutos na mesma já apontada em estudos anteriores, foi desenvolvido um método de amostragem automático e não-destrutivo, por meio da extração das características de frutos verdes em imagens digitais. Utilizou-se uma combinação das técnicas de conversão do modelo de cores, limiarização, equalização do histograma de níveis de cinza, filtragem espacial com os operadores de Laplace e Sobel e suavização gaussiana. Além disso, foi desenvolvido e testado um algoritmo para o reconhecimento e contagem dos frutos nessas imagens, com taxas de detecção de falso-positivos de 3% em imagens de boa qualidade. É possível se estimar a média do número de frutos visíveis por planta com um erro tolerado de 5% com até 46 imagens e em aproximadamente 8 minutos, sem nenhuma interação humana. A ausência de flash e a incidência de luz solar direta sobre a planta podem prejudicar consideravelmente o desempenho do algoritmo.

Palavras-chave: laranja, previsão de safra, visão computacional, agricultura de precisão, detecção de frutos

ESTIMATION OF THE NUMBER OF GREEN FRUITS IN ORANGE TREES USING DIGITAL IMAGES

ABSTRACT – Yield estimation is an important factor in a production process planning. In the case of citrus orchards, can be useful for processing plants management and as guidance for farmers, showing a decisive role in the product market strategies and cultivation practices. Several techniques are being studied for estimating citrus crop yield, but still presenting significant limitations. On the basis of the known correlation between the number of visible fruits in a digital image and the total of fruits present in an orange tree, an automatic and non-destructive method for green fruit feature extraction was developed with a combination of the techniques of color model conversion, thresholding, histogram equalization, spatial filtering with Laplace and Sobel operators and Gaussian blur. In addition, we built and tested an algorithm to recognize and count the fruits, with detection rates of false-positives of 3% for images acquired in good conditions. It is possible to estimate the mean number of visible fruits in the trees within a tolerated error of 5% with up to 46 images and taking approximately 8 minutes without any human interaction. The absence of flash light or the direct incidence of solar light on the plant can significantly detract the algorithm results.

Keywords: orange, yield estimation, computer vision, precision agriculture, fruit detection

LISTA DE TABELAS

	Página
1 Classificação das plantas fotografadas para posterior estratificação dos resultados	15
2 Motivos e número de descartes de imagens do conjunto de dados (1382 imagens) para avaliação do método automático de contagem de frutos em laranjeiras na safra de 2011	54
3 Estatística descritiva do tempo despendido em segundos por imagem nas contagens de frutos, em 1182 imagens pelos métodos manual e automático	55
4 Avaliação do desempenho do algoritmo de detecção automática de frutos em imagens de laranjeiras por meio das porcentagens de detecções $\pm$ o erro padrão da média em diversos estratos e em 1182 imagens individuais da safra de 2011	57
5 Avaliação do desempenho do algoritmo de detecção automática de frutos em imagens de laranjeiras pelas porcentagens de detecções $\pm$ o erro padrão da média agrupadas por qualidade da imagem em 1182 imagens individuais da safra de 2011	57
6 Número de imagens necessário para a estimativa do número de frutos visíveis por planta para os erros tolerados de 5, 10, 15 e 20%, em que foram sempre tomadas duas imagens de uma mesma planta	58
7 Número de imagens necessário para a estimativa do número de frutos visíveis por planta para os erros tolerados de 5, 10, 15 e 20% dentro de cada combinação entre variedades e grupos de idade, em que foram sempre tomadas duas imagens de uma mesma planta	59

LISTA DE FIGURAS

	Página
1 “Milagre do coração do homem avaro”, de Donatello (DONATO DI NICCOLO DI BETTO BARDI, 1447), esculpida em bronze, 57 × 123 cm, Basilica di Sant’Antonio (Pádua, Itália) (WahooArt.com)	9
2 Três possíveis preditores para a separação entre “círculos” e “triângulos” .	12
3 Diagrama de fluxo do algoritmo proposto para a geração de imagens de baixo-relevo simulado	19
4 Hiperplanos para separação entre classes de “círculos” e “triângulos” por meio de Máquinas de Vetores de Suporte (SVMs)	29
5 Diagrama de fluxo da estratégia de reconhecimento e contagem de frutos em imagens de baixo-relevo simulado de laranjeiras	31
6 Resultados de duas aplicações do filtro circular de Gabor com diferentes valores para o parâmetro σ à componente brilho do modelo HSV em imagem da copa de uma laranjeira	34
7 Imagem original e banco de filtros tradicionais de Gabor aplicados à componente de brilho do modelo HSV em cinco direções	35
8 Imagem original de uma laranjeira com frutos verdes, tomada com uma câmera digital comum	36
9 Imagem original e camada V após a conversão para o modelo de cores HSV	37
10 Camada de brilho da imagem no modelo de cores HSV antes e após a equalização do histograma de níveis de cinza	38
11 Camada de brilho da imagem no modelo de cores HSV com equalização do histograma de níveis de cinza antes e após a aplicação da suavização gaussiana	39
12 Resultado da primeira aplicação do filtro direcional passa-altas de Sobel na horizontal em imagem de uma laranjeira	41
13 Resultado da segunda aplicação do filtro direcional passa-altas de Sobel na horizontal em imagem de uma laranjeira	41
14 Resultado da aplicação do filtro passa-altas laplaciano da gaussiana para a evidenciação de folhas e outros elementos alheios aos frutos em imagem de uma laranjeira	43
15 Limiarização da imagem de uma laranjeira para a remoção das características inerentes ao céu captadas pela imagem digital	44

16	Limiarização da imagem de uma laranjeira para a remoção das características inerentes ao solo e outros elementos alheios à planta captados pela imagem digital	44
17	Imagem de baixo-relevo simulado de uma laranjeira, evidenciando os frutos verdes com base em análise de textura e brilho. Nesta imagem ficam destacados os frutos pelo efeito de baixo valor de brilho (cor preta) em suas partes inferiores	45
18	Regressão linear entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011	46
19	Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011 e estratificadas por grupos de idade	47
20	Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011 e estratificadas por variedades	48
21	Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011 e estratificadas por setores do estado de São Paulo	49
22	Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011 e estratificadas por regiões do estado de São Paulo	51
23	Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na na safra de 2011 e estratificadas pelas combinações entre as variedades e os grupos de idades estudados	52
24	Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na na safra de 2011 e estratificadas pelas combinações entre os setores do estado de São Paulo e os grupos de idades estudados	53

25	Regressões lineares entre as contagens e o total de frutos por planta para os métodos manual e automático avaliados em imagens tomadas na safra de 2011 (610 imagens de 305 plantas)	61
26	Comparação entre os métodos manual e automático de contagem de frutos em imagens de laranjeiras para estimativa do total de frutos por planta. Imagens estratificadas por grupos de idade e tomadas na safra de 2011 (610 imagens de 305 plantas)	62
27	Regressões lineares entre as contagens e o total de frutos por planta para os métodos manual e automático de contagem de frutos em imagens de laranjeiras. Imagens estratificadas por grupos de idade e tomadas na safra de 2011 (610 imagens de 305 plantas)	63
28	Comparação entre os métodos manual e automático de contagem de frutos em imagens de laranjeiras para estimativa do total de frutos por planta. Imagens estratificadas por variedades e tomadas na safra de 2011 (610 imagens de 305 plantas)	64
29	Regressões lineares entre as contagens e o total de frutos por planta para os métodos manual e automático de contagem de frutos em imagens de laranjeiras. Imagens estratificadas por variedades e tomadas na safra de 2011 (610 imagens de 305 plantas)	65
30	Regressões lineares entre as contagens e o total de frutos por planta para o método manual de contagem de frutos em imagens de laranjeiras. Imagens estratificadas pelas combinações entre variedades e grupos de idade e tomadas na safra de 2011 (610 imagens de 305 plantas)	66
31	Regressões lineares entre as contagens e o total de frutos por planta para o método automático de contagem de frutos em imagens de laranjeiras. Imagens estratificadas pelas combinações entre variedades e grupos de idade e tomadas na safra de 2011 (610 imagens de 305 plantas)	67
32	Comparação entre os métodos manual e automático de contagem de frutos em imagens de laranjeiras para estimativa do total de frutos por planta. Imagens estratificadas por setores do estado de São Paulo e tomadas na safra de 2011 (610 imagens de 305 plantas)	68
33	Regressões lineares entre as contagens e o total de frutos por planta para os métodos manual e automático de contagem de frutos em imagens de laranjeiras. Imagens estratificadas por setores do estado de São Paulo e tomadas na safra de 2011 (610 imagens de 305 plantas)	68

34	Comparação entre os métodos manual e automático de contagem de frutos em imagens de laranjeiras para estimativa do total de frutos por planta. Imagens estratificadas por regiões do estado de São Paulo e tomadas na safra de 2011 (610 imagens de 305 plantas)	69
35	Regressões lineares entre as contagens e o total de frutos por planta para os métodos manual e automático de contagem de frutos em imagens de laranjeiras. Imagens estratificadas por regiões do estado de São Paulo e tomadas na safra de 2011 (610 imagens de 305 plantas)	70
1A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 6 e 10 anos	87
2A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 6 e 10 anos	87
3A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 6 e 10 anos	88
4A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 6 e 10 anos	88
5A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade maior que 10 anos	88
6A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade maior que 10 anos	89
7A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 6 e 10 anos	89
8A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 6 e 10 anos	89
9A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 3 e 5 anos	90
10A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 3 e 5 anos	90
11A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 3 e 5 anos	90
12A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 3 e 5 anos	91
13A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 3 e 5 anos	91
14A	Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 3 e 5 anos	91

1B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 3 e 5 anos	93
2B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 3 e 5 anos	93
3B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 3 e 5 anos	94
4B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 3 e 5 anos	94
5B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com idade entre 6 e 10 anos	94
6B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com idade entre 6 e 10 anos	95
7B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Natal com mais de 11 anos de idade	95
8B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 6 e 10 anos	95
9B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com mais de 11 anos de idade	96
10B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com mais de 11 anos de idade	96
11B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Natal com mais de 11 anos de idade	96
12B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 6 e 10 anos	97
13B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Pêra com mais de 11 anos de idade	97
14B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com idade entre 3 e 5 anos	97
15B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com idade entre 3 e 5 anos	98
16B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Natal com idade entre 6 e 10 anos	98
17B	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com idade entre 6 e 10 anos	98
1C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada sem flash	99

2C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem desfocada	99
3C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada contra a luz do sol e desfocada	100
4C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada com a câmera muito próxima à copa da planta	100
5C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada sem flash	100
6C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada com a câmera muito próxima à copa da planta	101
7C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem com incidência de luz solar direta sobre a planta	101
8C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem desfocada	101
9C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada contra o Sol	102
10C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada sem flash	102
11C	Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem de laranjeira com idade menor que 3 anos	102
1D	Implementação do filtro circular de Gabor em C++ para a geração de uma máscara espacial a ser utilizada nas funções de filtragem da biblioteca OpenCV (BRADSKI, 2015)	103
2D	Implementação do algoritmo de reconhecimento e contagem de frutos verdes em imagens de laranjeiras. O algoritmo é aplicado a todos os arquivos .jpg do diretório informado como parâmetro no método e escreve os resultados em um arquivo de texto chamado <i>results.txt</i> nessa mesma pasta	109

1 INTRODUÇÃO

Dentre as tecnologias empregadas para melhorar o gerenciamento e a produtividade das culturas nos processos produtivos modernos, destacam-se o sistema de posicionamento global (GPS), sistemas de informações geográficas (GIS), sensoria-mento remoto (RS), tecnologia de taxa variada (VRT), mapeamento de produtividade e avanços em sensores e tecnologia da informação. Tais melhorias têm capacitado o pro-dutor a visualizar o campo de maneira ampla e detalhada, auxiliando no planejamento e diminuindo o desperdício de recursos, considerando a variabilidade observada no campo (ANNAMALAI; LEE; BURKS, 2004).

A cultura do citros é caracterizada por apresentar um comportamento alternado quanto à produção, resultado de mecanismos inerentes à planta relacionados com as reservas internas de energia. Esses mecanismos fazem com que exista uma variação temporal grande tanto na produtividade de frutos quanto na qualidade dos mesmos (ISAGI et al., 1997; NOGUCHI et al., 2003). Esse comportamento faz com que os métodos conhecidos de previsão não apresentem resultado satisfatório, tornando-se mais imprecisos à medida que o tempo da previsão aumenta (SAKAI; NOGUCHI; ASADA, 2008). Dessa maneira, é necessário um método de amostragem prático e eficiente, que possa ser efetuado regularmente a fim de se acompanhar a evolução das plantas.

É importante destacar que o conhecimento e acompanhamento do comporta-mento das plantas individualmente torna-se cada vez mais importante, já que essa dinâmica de alteração de produtividade tem origem comprovadamente endógena, inerente à cada planta (SAKAI; NOGUCHI; ASADA, 2008), fazendo com que seja crucial um método de amostragem não destrutivo. Tradicionalmente, os métodos de recomendação de tratos culturais como adubação e calagem consideram as condições de solo e de clima, porém não consideram as condições inerentes às plantas, ou as tratam de maneira uniforme, como é o caso de análises foliares. Com o advento

da agricultura de precisão, um acompanhamento mais minucioso começa a ganhar vantagens práticas, tornando possível o tratamento individual das plantas por meio de mapas detalhados e de equipamentos capazes de variar as taxas de aplicação com precisão espacial de centímetros.

Importantes tentativas de padronização e automatização da previsão de safra de citros foram realizadas. Sakai, Noguchi e Asada (2008) demonstraram que é possível prever com razoável precisão ($R^2 = 0,78$) a produtividade de plantas individuais para uma determinada estação usando a produtividade de dois anos anteriores como entradas para o modelo. Um sistema de previsão em tempo real mostrou resultados precisos (ANNAMALAI; LEE; BURKS, 2004), porém pode ser utilizado somente quando os frutos estão em estádios de maturação mais avançados, pois são segmentados nas imagens com base na sua coloração. Nessas condições, já não é mais possível a aplicação de práticas culturais para melhorias na produtividade e nem tempo hábil para o planejamento comercial ou de industrialização do produto.

O sistema desenvolvido por Triboni e Barbosa (2004) também incorre nesse problema, pois mostrou-se efetivo somente para a identificação e contagem de frutos maduros nas plantas. Há também um sistema desenvolvido e implementado para *smartphones* Android que se mostrou eficiente nas mesmas condições que os anteriores. Mesmo com taxas de determinação de até 90% entre os valores de produtividade reais e os estimados para uma única árvore, o sistema é eficiente somente quando os frutos estão em estádios de maturação mais avançado (GONG et al., 2013).

Nesse âmbito, as técnicas de amostragem ganham destaque especial tendo em vista que são essenciais para a descrição das áreas quanto às variáveis desejadas. Para que se possa tomar decisões de manejo da cultura, de compra e venda do produto ou a definição de mapas precisos de produtividade para uma determinada área, é necessário que se defina um método de amostragem confiável com um mínimo de amostras. O objetivo deste trabalho foi desenvolver um método automático e não-destrutivo para a contagem de frutos de laranja verdes em imagens de laranjeiras e

avaliar seu desempenho para a estimativa do número total de frutos presentes nas árvores.

2 REVISÃO DE LITERATURA

2.1 Estimativa da produção de citros

Atualmente, o Brasil é o maior produtor de citros do mundo, com produção anual de aproximadamente 290 milhões de caixas de 40,8 kg. Nesse contexto, estado de São Paulo merece destaque por possuir a maior parte da área cultivada do país (FUNDECITRUS, 2016).

A estimativa da produtividade é um importante fator no planejamento de um processo produtivo. No caso dos citros, pode colaborar com o gerenciamento do processo industrial e servir como orientação para os produtores, apresentando papel decisivo no mercado do produto. Atualmente, não existe um método confiável e não-destrutivo bem estabelecido de estimativa da produção de citros. As estimativas utilizadas para planejamento da cadeia produtiva dependem das decisões baseadas na experiência de técnicos ao visitar os talhões, o que torna o procedimento altamente subjetivo e impreciso.

Vários estudos de técnicas para estimativa da produção da cultura foram realizados. Folhas e frutos de citros foram analisadas a fim de se encontrar diferenças no espectro eletromagnético refletido (ANNAMALAI; LEE; BURKS, 2004) e facilitar o seu reconhecimento com o uso de imagens hiperespectrais. Imagens aéreas adquiridas com o auxílio de um veículo aéreo não tripulado foram utilizadas para segmentação e reconhecimento de frutos para a estimativa de produção (MACARTHUR et al., 2006). Sensores embarcados foram utilizados para a aquisição de imagens e posterior tratamento foi efetuado para a identificação e contagem de frutos (ANNAMALAI, 2004). Métodos de processamento de imagens digitais como a transformada de *watershed* são relatados na segmentação e divisão de frutos agrupados para contagens mais acuradas (CHINCHULUUN; LEE; BURKS, 2006).

Ainda com relação às tentativas de estimativa da produção, imagens aéreas hiperespectrais foram utilizadas para o desenvolvimento preliminar de uma rede neural

artificial (YE et al., 2006) e, em um trabalho posterior, considerando que o número de folhas novas e vegetações florais estão relacionados com o número de frutos da planta (NOGUCHI et al., 2003), foram desenvolvidos modelos de quadrados mínimos para a predição de produtividade de citros utilizando também imagens hiperespectrais vários meses antes da colheita (YE et al., 2007), concluindo-se que a utilização de índices de vegetação e regressão múltipla linear não resultaram em boas predições. Mais recentemente foi avaliada a performance do índice TBVI (*Two-Band Vegetation Index*) na estimativa de produtividade de citros (YE et al., 2008) e a detecção de frutos verdes por meio de imagens hiperespectrais foi avaliada para estimativa (OKAMOTO; LEE, 2009). O uso de imagens digitais para a estimativa da produção de citros é promissor, já que é sabido que existe relação funcional entre o número de frutos visíveis nas fotografias da copa das árvores e a produção total de frutos (TRIBONI; BARBOSA, 2004).

No entanto, todos esses métodos citados apresentam limitações, exigindo mão-de-obra altamente especializada, equipamentos caros e geralmente baixo rendimento operacional (GONG et al., 2013), tornando-os inacessíveis a pequenos e médios produtores. De uma maneira geral, os métodos de previsão da produtividade necessitam de melhorias, haja vista que mesmo em imagens hiperespectrais, a detecção e contagem de frutos apresentou um grande número de falso-positivos, impossibilitando sua aplicação em um método de previsão. Dessa maneira, são necessários estudos mais aprofundados (OKAMOTO; LEE, 2009) já que a detecção de frutos maduros, mesmo com resultados bons para a estimativa, baixo custo e fácil aplicação (GONG et al., 2013) deve ser revista para que seja possível ser aplicada em fases mais anteriores à colheita.

A detecção de frutos imaturos não é uma tarefa simples principalmente devido à sua coloração, o que torna sua distinção da copa da planta e do plano de fundo da imagem uma tarefa desafiadora dada a sua similaridade com as folhas e outros frutos. Além disso, outras dificuldades importantes na identificação e segmentação dos frutos

ainda na árvore são: oclusão por folhas, ramos, outros frutos e iluminação não uniforme em condições de campo (KURTULMUS; LEE; VARDAR, 2011).

2.2 Processamento de imagens digitais

O conceito de imagem refere-se a uma função de intensidade luminosa bidimensional, denotada por $f(x, y)$, em que o valor ou amplitude de f nas coordenadas espaciais (x, y) consiste na intensidade (brilho) da imagem naquele ponto. Por convenção, a intensidade de uma imagem monocromática f nas coordenadas (x, y) será limitada a um intervalo $[L_{min}, L_{max}]$ (escala de cinza) e é denominada de nível de cinza daquele ponto. Cada ponto é denominado um elemento de imagem, ou *pixel*. Ao tomarmos uma imagem com uma câmera, estamos realizando nada mais que um procedimento de amostragem dessa função contínua (GONZALEZ; WOODS, 2000). O resultado desse procedimento é aproximado por amostras igualmente espaçadas, arranjadas na forma de uma matriz $N \times M$, em que cada elemento é uma quantidade discreta:

$$f(x, y) = \begin{bmatrix} f(0, 0) & f(0, 1) & \cdots & f(0, M - 1) \\ f(1, 0) & f(1, 1) & \cdots & f(1, M - 1) \\ \vdots & & & \\ f(N - 1, 0) & f(N - 1, 1) & \cdots & f(N - 1, M - 1) \end{bmatrix}$$

Assim, fica evidente que, quanto maiores os valores de N e M , maior a quantidade de detalhes que uma imagem pode expressar. A isso denomina-se resolução espacial, em que quanto maior o seu valor, maior o tamanho da imagem. O mesmo raciocínio é válido para o número de níveis de cinza da imagem, responsáveis pela variação no brilho de cada *pixel*.

As técnicas de processamento de imagens digitais se caracterizam por tentar reproduzir, fazendo uso de métodos estatísticos e matemáticos, os mecanismos de reconhecimento e interpretação do sistema de visão do ser humano. Nesse contexto, a textura dos objetos assume um papel de destaque na capacidade humana. Aparente-

mente, a interpretação de textura apresenta papel primordial, que pode ser facilmente salientado pela nossa interpretação de imagens em “preto-e-branco”. Mesmo sem o componente cor, ainda é possível reconhecer e identificar objetos com uma boa precisão. Secundariamente, as cores nos fornecem detalhes adicionais que irão complementar as nossas inferências sobre os objetos em questão, servindo como um classificador mais detalhista e minucioso.

2.3 Filtros de Gabor

Dentre os descritores estatísticos de textura, os filtros de Gabor são utilizados com frequência para essa finalidade (ZHANG; TAN; MA, 2002). Uma tentativa utilizando tal técnica foi feita por Kurtulmus, Lee e Vardar (2011) utilizando os filtros circulares de Gabor (ZHU; TANG; LU, 2004), que são relatados como bons descritores de textura assim como a aplicação do algoritmo de Gabor (GABOR, 1946) em diversos ângulos para a obtenção de matrizes características. É feita uma análise de componentes principais após sua aplicação para a definição de um classificador denominado “*eigen-fruit*”, calculado com base nos autovalores e autovetores da matriz de covariâncias de subamostras de imagens de frutos. Os autores conseguiram classificar corretamente 75,3% do número real de frutos nas imagens, em condições de campo com iluminação variável, porém com taxas de falso-positivos chegando a mais de 40%.

2.4 O baixo-relevo simulado

Um relevo é uma forma de escultura na qual um pedaço sólido de determinado material é cravado de maneira que figuras tridimensionais sejam representadas se destacando de um plano, geralmente relizadas em madeira, pedra ou metal. Os tipos de relevo mais importantes são o alto-relevo e o baixo-relevo. Alto-relevo é o tipo de escultura em que as figuras representadas se sobressaem ao plano de fundo, enquanto que, no baixo-relevo, as figuras são representadas com aprofundamentos mais discretos no material sólido sendo esculpido (JI; MA; SUN, 2014).

Para um melhor entendimento do conceito de relevo (mais especificamente de baixo-relevo), segue uma obra de Donatello esculpida em bronze utilizando a técnica de baixo-relevo (Figura 1). Nessa obra, ficam evidenciadas as características básicas desse tipo de representação:

- Modelagem: toda a cena é modelada de acordo com as leis da perspectiva (notável no arco presente no fundo e na parede à direita, perpendicular ao fundo);
- Elevação: as figuras mais próximas apresentam maior elevação;
- Linearidade: a forma e curvatura da representação ainda representam as formas originais, com as paredes, piso e teto sendo achatadas e não deformadas.

Com base nessas considerações, dada a projeção perspectiva de uma cena tridimensional em um plano de visão, o baixo-relevo pode ser interpretado como uma representação em gravura tridimensional onde a elevação de cada ponto depende da distância do mesmo ao observador (CIGNONI; MONTANI; SCOPIGNO, 1997).




Figura 1. “Milagre do coração do homem avaro”, de Donatello (DONATO DI NICCOLO DI BETTO BARDI, 1447), esculpida em bronze, 57 × 123 cm, Basilica di Sant’Antonio (Pádua, Itália) (WahooArt.com)

Como se pode notar na imagem, a representação em baixo relevo nos dá uma noção mais aprimorada de profundidade e textura. Assim, técnicas computadorizadas de obtenção de imagens de baixo-relevo a partir de cenas em três dimensões têm sido estudadas e avaliadas (BELHUMEUR; KRIEGMAN; YUILLE, 1999; CIGNONI; MONTANI; SCOPIGNO, 1997; JI; MA; SUN, 2014). Apesar da imagem ser uma representação em duas dimensões somente, a ideia central da obtenção dessas imagens é a simulação do efeito de escultura manual em um material sólido.

A obtenção de imagens de baixo-relevo partindo-se de imagens digitais em duas dimensões envolve diversas técnicas de processamento de imagens digitais como detecção de contornos, melhoria da imagem, filtragem espacial e fusão, dentre outras (DURAND; DORSEY, 2002; PARIS; DURAND, 2006; WEISS, 2006; WANG, 2011). A detecção de contornos é um dos problemas fundamentais do processamento de imagens digitais e da visão computacional, podendo ser obtida por meio de diversos operadores já bem conhecidos como o Laplaciano, operador de Sobel, operador cruzado de Robert, operador de Prewitt e algoritmo de detecção de fronteiras de Canny (WANG, 2011). Uma imagem de baixo-relevo pode ser obtida como resultado da combinação desses métodos aplicados a uma imagem obtida com uma câmera digital comum, por exemplo.

Dessa maneira, os filtros de baixo-relevo são importantes por destacarem características inerentes à textura dos objetos, o que fica claro com relação às formas esféricas, que apresentam uma região de alto brilho e uma de baixo brilho, considerando-se uma única fonte de iluminação. O conceito de textura é importante na descrição de regiões em imagens, possibilitando a existência de medidas de propriedades como suavidade, rugosidade e regularidade. Sendo assim, podemos definir a textura como o padrão diferença de intensidade entre *pixels* em determinada proximidade ou vizinhança (GONZALEZ; WOODS, 2000), e o baixo-relevo simulado como um potencial descritor de textura.

2.5 Reconhecimento e Interpretação

Após a etapa de extração de características, segue a etapa de identificação e reconhecimento dessas características seguida de sua classificação. Neste caso, trata-se da classificação de uma determinada região da imagem como sendo um fruto ou não. Para essa tarefa, há relatos da utilização de métodos de aprendizado de máquina como as redes neurais artificiais na estimativa do tamanho de frutos de laranja (REGUNATHAN; LEE, 2005), por exemplo.

2.5.1 O Aprendizado de Máquina e a Teoria de Aprendizado Estatístico

O Aprendizado de Máquina (AM) consiste em um princípio de inferência no qual se obtém conclusões genéricas a partir de um conjunto de exemplos. Esse aprendizado pode ser de dois tipos: supervisionado ou não-supervisionado. No aprendizado supervisionado há um treinador, responsável pelo ajuste do algoritmo para a execução da tarefa, com exemplos na forma de entrada e saída desejada (exemplos positivos e negativos) (HAYKIN, 2004). Já o aprendizado não supervisionado dispensa o treinador, e as saídas do algoritmo são avaliadas segundo um padrão de qualidade. Este tipo de aprendizado é aplicado com o objetivo de se encontrar padrões e tendências não definidos que auxiliem na compreensão de dados e não serão abordados neste trabalho.

Nesse caso, portanto, há um conjunto de exemplos rotulados na forma de $(\mathbf{x}_i, y_i)$ onde cada $\mathbf{x}_i$ representa um exemplo e cada y_i representa sua classificação. Esse conjunto deverá ser apresentado ao algoritmo, também chamado preditor ou classificador para o seu treinamento e posterior classificação de novos dados de entrada. Quando esse procedimento assume a saída de valores contínuos, há um problema de regressão. Quando assume a saída de inteiros, há um problema de classificação e quando há somente duas saídas possíveis (positivo ou negativo, por exemplo), há um problema de classificação binária (LORENA; CARVALHO, 2007).

Assim é introduzida a Teoria de Aprendizado Estatístico (TAE), na qual seja

f um preditor ou classificador e F o conjunto de todos os possíveis preditores que um algoritmo de aprendizado de máquina pode gerar. Esse algoritmo, durante seu processo de treinamento, faz uso de um conjunto de exemplos composto de n pares $(\mathbf{x}_i, y_i)$, a fim de se estabelecer um preditor $\hat{f} \in F$. A Figura 2 (SCHÖLKOPF; SMOLA, 2002) mostra três possíveis preditores f para a classificação dos padrões em “círculos” ou “triângulos”. O primeiro, dito super-ajustado (*overfitted*), classifica corretamente os padrões do conjunto de treinamento, porém, por ser muito rigoroso e específico, pode gerar erros quando dados diferentes o são apresentados. O último, dito sub-ajustado (*underfitted*), é passível de cometer muitos erros, pois não há precisão na separação de exemplos bem próximos. O melhor classificador nesse caso seria o intermediário, que apresenta um erro tolerável e uma boa separação de elementos próximos à fronteira de separação.

As redes neurais artificiais, usualmente chamadas somente de “redes neurais”, são um método de aprendizagem e modelagem computacional que tenta imitar as funções do cérebro humano. Sua aplicação é extremamente ampla em áreas com classificação, reconhecimento de padrões (como reconhecimento de faces e objetos, por exemplo), tomada de decisão, processamento de dados e agrupamento de informações. Regunathan e Lee (2005) relataram que a aplicação de tal técnica de reconhecimento e classificação nas matrizes características de Gabor apresentaram




Figura 2. Três possíveis preditores para a separação entre “círculos” e “triângulos”

um resultado de até 80% de identificação correta de frutos de laranja, nas imagens utilizadas para a validação do método.

Uma outra técnica muito importante para o reconhecimento de padrões são as máquinas de vetores de suporte (ou *SVM*, do inglês *Support Vector Machines*). Assim como as redes neurais, as *SVMs* necessitam de uma etapa de aprendizagem e, após a calibração, atuam como um classificador de padrões. Sua utilização também é bastante ampla, com resultados positivos em diversas aplicações, como o reconhecimento e classificação de maçãs, combinada com a extração de características utilizando a limiarização de Otsu (OTSU, 1975), por exemplo (MIZUSHIMA; LU, 2013). Os autores verificaram erros na segmentação variando de 3 a 25% usando uma *SVM* linear e erros menores que 2% utilizando um método ajustável para o classificador.

2.5.2 Máquinas de Vetores de Suporte (SVMs)

As Máquinas de Vetores de Suporte são classificadores de margem máxima. Ao invés de atribuir modelos distribuições de probabilidade aos vetores de treinamento, as *SVMs* tentam separar as diferentes classes buscando diretamente as fronteiras adequadas entre elas. Para esse propósito, elas constroem hiperplanos na região de separação entre tais classes (KEUCHEL et al., 2003).

Esse método de reconhecimento tem larga aplicação no processamento de imagens na área da agricultura. Sua aplicação é relatada como melhor método de reconhecimento e classificação de áreas de dendezeiro (*Elaeis guineensis*) através de imagens de satélite, tendo destaque por apresentar resultados positivos de desempenho na classificação mesmo com um conjunto de treinamento pequeno (LI et al., 2015). Também é reportado como um dos melhores métodos no reconhecimento e classificação de diferentes variedades de sementes de colza (*Brassica napus*) (KURTULMUS; ÜNAL, 2015), e atingiu 100% de classificações corretas quanto à qualidade de mangas (*Mangifera indica*), superando todos os outros métodos de classificação testados (SA'AD et al., 2015). Além do mais, seu uso estende-se à área da flori-

cultura, apresentando bons resultados na detecção de folhas de roseiras (*Rosa sp.*) doentes (NAGASAI; RANI, 2015).

3 MATERIAL E MÉTODOS

3.1 Estimativa do número de frutos por planta

A relação entre o número de frutos visíveis nas imagens digitais das plantas e o número total de frutos presente na mesma foi avaliada através de análise de regressão linear. As imagens foram obtidas com a colaboração da empresa Citrosuco, durante o mês de maio, na safra de 2011. Foram coletadas 1328 imagens, obtidas em condições de campo, em diversas horas do dia e diferentes condições de clima e de iluminação. Foram utilizadas câmeras digitais amadoras (Sony modelo DSC-W530), na resolução de 2592×1944 pixels (aproximadamente 5 Megapixels), com flash ligado e sem aplicação de zoom ótico ou digital.

A foto foi identificada quanto à variedade, idade da planta, setor e região do estado de São Paulo. Os testes foram realizados em fotos de laranjeiras de quatro variedades, três grupos de idade, dois setores e cinco regiões (Tabela 1).

Cada planta foi fotografada duas vezes (uma de cada lado acessível da copa), a 2 m da copa e, logo após, todos os seus frutos foram derriçados e contados manualmente. A automação de um método ou procedimento é sempre algo muito atrativo, pois traz o potencial de ganho de tempo e precisão ao executar tarefas. Portanto, a avaliação do desempenho de um novo método deve ser realizada com a comparação desse método com um já conhecido e confiável. Nesse caso, o método automático desenvolvido para a contagem de frutos de laranja em imagens digitais foi comparado

Tabela 1. Classificação das plantas fotografadas para posterior estratificação dos resultados

Variedades	Idades	Setores	Regiões
Hamlin	de 3 a 5 anos	Centro	Araraquara
Natal	de 6 a 10 anos	Sul	Bauru
Pêra	11 anos ou mais		Itápolis
Valência			Matão
			Taquaritinga

com um método preciso, onde todos os frutos visíveis das imagens foram contados manualmente por avaliadores em monitores digitais.

Foi desenvolvido um aplicativo para auxiliar no procedimento de contagem dos frutos visíveis nas imagens manualmente. Assim, tornaram-se possíveis os estudos da relação entre o número de frutos visíveis nas imagens e o número total de frutos derriçados da planta, da relação entre o número de frutos contados pelo método automatizado desenvolvido neste trabalho e o número de frutos visíveis nas imagens e, por fim, entre o número de frutos contados automaticamente e o número de frutos total obtido na derriça das plantas. O tempo despendido nas contagens manuais e automáticas dos frutos nas imagens também foi monitorado e avaliado.

O método automático de contagem, assim como o manual, foi aplicado a todas as imagens. Nas análises de regressão linear, efetuadas com o uso do *software* R (R CORE TEAM, 2015), foram observados os valores do coeficiente angular da reta, do intercepto, do coeficiente de determinação (R^2) e do teste F para o ajuste do modelo.

Todos os procedimentos de processamento de imagens utilizados neste trabalho foram realizados pela implementação de procedimentos em C++ fazendo uso da biblioteca de visão computacional OpenCV (BRADSKI, 2015) em um computador com sistema operacional baseado em Unix e com processador de 2,4 GHz Intel Core i5 e 8 GB de memória RAM de 1600 MHz DDR3. A extração das características dos frutos verdes baseou-se em análise de textura, contexto no qual foram testados os descritores de textura de Gabor e um método de geração de imagens de baixo-relevo simulado a partir de imagens digitais tradicionais de duas dimensões.

3.2 Filtros de Gabor

Os filtros de Gabor (GABOR, 1946) são amplamente utilizados em processamento de sinais e também processamento de imagens digitais. Tais filtros têm sido utilizados com frequência para a extração de características, baseando-se na textura

dos objetos (KURTULMUS; LEE; VARDAR, 2011; GRIGORESCU; PETKOV; KRUIZINGA, 2002; FOGEL; SAGI, 1989; PRASAD; DOMKE, 2005; LAGAE et al., 2009; JAIN; MURTY; FLYNN, 1999). Basicamente, uma imagem (ou uma janela da imagem durante o processo de convolução) $I(x, y)$, $(x, y) \in \Omega$, com Ω sendo o conjunto de pontos da imagem, é convoluída por de uma função de duas dimensões de Gabor dada por $g(x, y)$, $(x, y) \in \Omega$ para se obter uma imagem característica de Gabor $r(x, y)$, dada por:

$$r(x, y) = \iint_{\Omega} I(\xi, \eta) g(x - \xi, y - \eta) d\xi d\eta$$

Foi utilizada a seguinte família dos filtros de Gabor:

$$g_{\lambda, \theta, \phi}(x, y) = e^{-\left(\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right)} \cos\left(2\pi \frac{x'}{\lambda} + \phi\right)$$

onde,

$$x' = x \cos \theta + y \sin \theta,$$

$$y' = -x \sin \theta + y \cos \theta,$$

$$\sigma = 0,56\lambda \quad \text{e}$$

$$\gamma = 0,5.$$

Para o experimento, foi avaliado um banco de filtros de Gabor simétricos. O banco foi composto por cinco filtros resultantes de cinco diferentes orientações equidistantes ($\theta = k(\phi/8)$, $k = 0, 1, 2, 3, 4$).

Além disso, os filtros de Gabor são muito úteis na detecção da direção de texturas. Essa é a principal vantagem do filtro de Gabor tradicional, desenvolvido para sinais de uma única dimensão. No entanto, o comportamento sinuoidal do filtro tradicional de Gabor se torna menos importante na análise de texturas rotacionadas, quando a orientação da textura não é levada em consideração. Assim, se a sinuosidade varia em todas as direções, pode-se dizer que ela é circular simétrica, resultando em uma nova versão dos filtros de Gabor. O filtro circular de Gabor é definido por (ZHANG;

TAN; MA, 2002; PORTER; CANAGARAJAH, 1997):

$$G(x, y) = g(x, y) e^{2\pi i F(\sqrt{x^2+y^2})}$$

onde F é a frequência central do filtro circular de Gabor e $g(x, y)$ é um envelope gaussiano de duas dimensões, definido como isotrópico e obtido por:

$$g(x, y) = \left(\frac{1}{2\pi\sigma^2} \right) e^{-\frac{x^2+y^2}{2\sigma^2}}$$

Assim, pela fórmula de Euler $e^{ix} = \cos x + i \sin x$ (HAZEWINDEL, 2013) podemos obter as partes real e imaginária resultantes da aplicação do filtro. A parte real portanto é dada por:

$$G_R(x, y) = \left(\frac{1}{2\pi\sigma^2} \right) e^{-\frac{x^2+y^2}{2\sigma^2}} \cos 2\pi F \left(\sqrt{x^2 + y^2} \right)$$

e a parte imaginária por:

$$G_I(x, y) = \left(\frac{1}{2\pi\sigma^2} \right) e^{-\frac{x^2+y^2}{2\sigma^2}} \sin 2\pi F \left(\sqrt{x^2 + y^2} \right)$$

As propriedades dos filtros circulares de Gabor podem também ser explicitadas em seu respectivo domínio da frequência, sendo a representação de Fourier do filtro circular de Gabor dada por:

$$F(u, v) = \frac{\sqrt{2\pi}}{2} \alpha e^{-\frac{(\sqrt{u^2+v^2}-F)^2}{2\alpha^2}}$$

onde $\alpha = \frac{1}{2\pi\sigma}$.

Para a execução dos testes, foi feita uma implementação dos filtros circulares de Gabor com o auxílio dos métodos e classes da biblioteca OpenCV (BRADSKI, 2015) em C++ (Figura 1D).

3.3 Geração das imagens de baixo-relevo simulado

As imagens em baixo-relevo foram obtidas por meio da combinação das técnicas de conversão do modelo de cores, limiarização, equalização do histograma de níveis de cinza, filtragem espacial pelos operadores Laplaciano e de Sobel e suavização gaussiana (Figura 3).




Figura 3. Diagrama de fluxo do algoritmo proposto para a geração de imagens de baixo-relevo simulado

3.3.1 Conversão do modelo de cores

Os modelos de cores têm como propósito facilitar a exibição ou especificação de cores de acordo com um determinado padrão. Sendo assim, um modelo de cores é uma especificação de um sistema de coordenadas tridimensionais e um subespaço dentro desse sistema, onde cada cor é representada por um único ponto (GONZALEZ; WOODS, 2000). O modelo padrão em que imagens digitais são tomadas e

armazenadas é o RGB (*Red, Green, Blue*).

Neste trabalho foi utilizado essencialmente o modelo HSV (*Hue, Saturation, Value*, ou Matiz, Saturação e Valor). Nesse modelo, o primeiro valor desceve uma cor pura, o segundo dá uma medida do grau de pureza dessa cor (variando de totalmente preto a totalmente pura) e o terceiro representa o brilho daquele ponto. Os valores de H, S e V foram obtidos por meio da conversão do modelo RGB, dada por:

$$R' = R/255$$

$$G' = G/255$$

$$B' = B/255$$

$$C_{max} = \max(R', G', B')$$

$$C_{min} = \min(R', G', B')$$

$$\Delta = C_{max} - C_{min}$$

$$H = \begin{cases} 0^\circ, & \text{se } \Delta = 0 \\ 60^\circ \times \left(\frac{G' - B'}{\Delta} \bmod 6 \right), & \text{se } C_{max} = R' \\ 60^\circ \times \left(\frac{B' - R'}{\Delta} + 2 \right), & \text{se } C_{max} = G' \\ 60^\circ \times \left(\frac{R' - G'}{\Delta} + 4 \right), & \text{se } C_{max} = B' \end{cases}$$

$$S = \begin{cases} 0, & \text{se } C_{max} = 0 \\ \frac{\Delta}{C_{max}}, & \text{se } C_{max} \neq 0 \end{cases}$$

$$V = C_{max}$$

3.3.2 Limiarização global simples

Assumindo-se que a cada *pixel* da imagem é atribuído um valor numérico inteiro (valor do nível de cinza), é possível se elaborar um histograma de níveis de cinza, indicando as frequências em que cada valor ocorre. A limiarização global simples consiste no particionamento do histograma por um limiar arbitrário. A segmentação é então efetuada, varrendo-se a imagem *pixel* a *pixel* e rotulando-se cada um como pertencente a uma das duas classes obtidas no particionamento do histograma (GONZALEZ; WOODS, 2000). De uma maneira mais abrangente, a limiarização pode ser definida como uma operação que testa uma função T da forma

$$T = T[x, y, p(x, y), f(x, y)]$$

onde $f(x, y)$ é o nível de cinza do ponto (x, y) e $p(x, y)$ se refere a uma propriedade local desse ponto, como o nível de cinza médio de uma vizinhança com centro em (x, y) . A imagem limiarizada $g(x, y)$ é então

$$g(x, y) = \begin{cases} 1, & \text{se } f(x, y) > T \\ 0, & \text{se } f(x, y) \leq T. \end{cases}$$

Após a conversão para o modelo de cores HSV, o primeiro canal do modelo (*Hue*, ou ângulo da cor) foi utilizado para a limiarização, removendo-se as faixas de valores referentes aos tons avermelhados e azulados das imagens, responsáveis por representar ramos, solo e céu.

3.3.3 Convolução

A convolução de duas funções $f(x)$ e $g(x)$, representada por $f(x) * g(x)$ é obtida por meio da integral

$$f(x) * g(x) = \int_{-\infty}^{\infty} f(\alpha)g(x - \alpha) d\alpha$$

que, analogamente, para o caso de duas dimensões, é definida por

$$f(x, y) * g(x, y) = \iint_{-\infty}^{\infty} f(\alpha, \beta) g(x - \alpha, y - \beta) d\alpha d\beta.$$

Para a aplicação em imagens, a convolução bidimensional de $f(x, y)$ por uma matriz $g(x, y)$ deve ser discretizada. Portanto, considerando-se os erros de revestimento, o que na prática se resume à perda das bordas de $f(x, y)$ com tamanho dependendo das dimensões de $g(x, y)$, a convolução bidimensional discreta de $f_e(x, y)$ por $g_e(x, y)$ é definida pela relação

$$f_e(x, y) * g_e(x, y) = \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f_e(m, n) g_e(x - m, y - n).$$

Neste trabalho, diferentes $g_e(x, y)$ serão denominadas máscaras espaciais, que serão aplicadas com a finalidade de se extrair ou destacar determinadas características nas imagens $f_e(x, y)$.

3.3.4 Filtragem espacial

A utilização de máscaras espaciais no processamento de imagens digitais é denominada filtragem espacial. Basicamente, os filtros ou máscaras espaciais são classificados de acordo com as frequências das características que eles destacam. Pelo conceito de frequência, entende-se que transições de níveis de cinza mais abruptas entre *pixels* vizinhos qualificam altas frequências enquanto que transições mais suaves caracterizam baixas frequências.

Os filtros passa-baixas atenuam ou eliminam os componentes de alta frequência enquanto mantém as baixas frequências inalteradas, resultando em um efeito de borramento na imagem e suavizando bordas e outros detalhes finos. Já os filtros passa-altas são utilizados frequentemente como detectores de fronteiras, pois atenuam ou eliminam os componentes de baixa frequência mantendo inalterados os de alta frequência, gerando um efeito de realce de detalhes.

Como exemplo de filtro passa-baixas tem-se a máscara da média da vizinhança, dada por

$$\frac{1}{9} \times \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

e, como exemplo de filtro passa-altas, tem-se

$$\frac{1}{9} \times \begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}.$$

3.3.5 Ajustes de iluminação

Como as imagens são obtidas em áreas abertas, suscetíveis a variações nas condições de iluminação, e as copas das plantas são irregulares, é imprescindível uma etapa de ajuste e equalização do histograma de níveis de cinza das imagens. Dentre as técnicas empregadas para essa finalidade, as mais comuns são a utilização do logaritmo e a equalização do histograma de níveis de cinza (SAVVIDES; KUMAR, 2003; KURTULMUS; LEE; VARDAR, 2011; GONZALEZ; WOODS, 2000), que foram aplicadas ao componente de intensidade (V) do modelo de cores HSV.

3.3.6 O operador de Sobel

A detecção de descontinuidades é comumente efetuada por meio da varredura da imagem por uma máscara específica, capaz de salientar as características desejadas. Dessa maneira, tais máscaras são definidas a fim de serem detectores de pontos, linhas e bordas.

Uma borda é um limite entre duas regiões com propriedades relativamente distintas de nível de cinza. Basicamente, a ideia por trás da maioria das técnicas para a detecção de bordas é a computação de um operador local diferencial. Dessa maneira, a transição entre níveis de cinza é modelada de acordo com a diferença entre esses

níveis, e representada de acordo com a intensidade da variação. Dentre os operadores responsáveis pela detecção de bordas, podemos citar os operadores de gradiente. Neles, o gradiente de uma imagem $f(x, y)$ na posição (x, y) é dado pelo vetor:

$$\nabla \mathbf{f} = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix}.$$

A partir de análise vetorial é sabido que o vetor gradiente aponta na direção de mudança mais rápida de f na posição (x, y) . A magnitude desse vetor é denominada gradiente e dada por:

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

Essa quantidade equivale à maior taxa de aumento de $f(x, y)$ por unidade de distância na direção de $\nabla \mathbf{f}$. Uma aproximação para o gradiente com valores absolutos, de mais simples implementação, é dada por:

$$\nabla f \approx |G_x| + |G_y|.$$

É possível também se obter a direção do vetor gradiente, dado por $\alpha(x, y)$ como sendo o ângulo com o eixo x da direção do vetor $\nabla \mathbf{f}$ na posição (x, y) e obtida por meio de análise vetorial por:

$$\alpha(x, y) = \tan^{-1} \left(\frac{G_y}{G_x} \right).$$

Assim, podemos definir os operadores de Sobel como sendo operadores de gradiente, responsáveis pela detecção de bordas na horizontal e na vertical, com a vantagem de fornecerem de uma única vez, os efeitos de diferenciação e de suavização. Uma vez que a derivação aumenta o ruído da imagem, o efeito de suavização é uma característica particularmente atrativa dos operadores de Sobel (GONZALEZ; WOODS, 2000). Em uma região de uma imagem de tamanho 3×3 dada por:

$$\begin{bmatrix} z_1 & z_2 & z_3 \\ z_4 & z_5 & z_6 \\ z_7 & z_8 & z_9 \end{bmatrix},$$

ao utilizarmos as máscaras de Sobel, dadas por:

$$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

e

$$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix},$$

ficam definidas as respectivas derivadas baseadas nessas máscaras:

$$G_x = (z_7 + 2z_8 + z_9) - (z_1 + 2z_2 + z_3)$$

e

$$G_y = (z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7)$$

em que os valores de z são os níveis de cinza dos *pixels* sobrepostos pelas máscaras em qualquer posição da imagem. Os cálculos resultam em um único valor no centro da máscara aplicada e um novo valor deve ser calculado para cada *pixel* da imagem, respeitando-se as limitações das bordas e do tamanho da máscara. Após o cálculo para todos os pontos tem-se como resultado uma nova imagem indicando as bordas encontradas.

3.3.7 O operador laplaciano

O laplaciano de uma função bidimensional $f(x, y)$ é uma derivada de segunda ordem definida por:

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}.$$

Como no caso dos operadores de Sobel, essa equação pode ser implementada na forma digital de diferentes maneiras. Para o caso de uma região 3×3 , as formas de

máscaras mais frequentemente encontradas na prática são:

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix}$$

e

$$\begin{bmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{bmatrix}$$

em que ficam definidas as equações derivadas dessas máscaras como:

$$\nabla^2 f = 4z_5 - (z_2 + z_4 + z_6 + z_8)$$

e

$$\nabla^2 f = 8z_5 - (z_1 + z_2 + z_3 + z_4 + z_6 + z_7 + z_8 + z_9),$$

onde novamente os valores de z são os níveis de cinza dos *pixels* sobrepostos pela máscara. Para a definição do laplaciano digital, é necessário que o coeficiente associado com o *pixel* central seja positivo e que os outros coeficientes externos sejam negativos. Além disso, uma vez que esse operador é uma derivada, a soma de seus coeficientes deve ser nula. Dessa maneira, o resultado da aplicação da máscara é nulo sempre que os *pixels* vizinhos de coeficiente não nulo apresentem mesmo valor que o *pixel* central.

No entanto, mesmo apresentando resposta a transições na intensidade dos *pixels*, ele é pouco utilizado dessa maneira para a detecção de bordas. Isso é explicado pelo fato de ser uma derivada de segunda ordem, o operador laplaciano é especialmente sensível a ruídos de uma maneira inaceitável. Também é importante o fato que ele produz bordas duplas, o que o torna incapaz de detectar a direção das bordas. Por esses motivos, o operador laplaciano comumente ocupa papel secundário como um detector para evidenciar se um *pixel* está no lado claro ou escuro de uma borda (GONZALEZ; WOODS, 2000).

O laplaciano apresenta um uso mais geral de localização de bordas por meio da propriedade dos cruzamentos por zero, baseada na convolução da imagem com o laplaciano de uma função gaussiana bidimensional dada por:

$$\nabla^2(x, y) = -\frac{1}{\pi\sigma^4} \left[1 - \frac{x^2 + y^2}{2\sigma^2} \right] e^{-\frac{x^2 + y^2}{2\sigma^2}}$$

onde σ é o desvio padrão (MARR; HILDRETH, 1980).

3.4 Segmentação e contagem dos frutos

3.4.1 Máscaras espaciais

As gravuras de baixo-relevo destacam as formas esféricas de maneira particular. Quando há uma fonte de iluminação de incidência superior à posição da forma esférica, fica estabelecido um padrão de brilho bem definido: a parte visível da semi-esfera superior apresentando um alto valor de brilho e a parte visível da semi-esfera inferior um baixo valor. Isso permitiu a definição de duas máscaras de filtragem espacial, capazes de detectar os frutos nas imagens pré-processadas, de diversas dimensões. No caso das máscaras 6×6 , temos:

$$\begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

e

$$\begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix}.$$

A filtragem da imagem por cada uma dessas máscaras dá origem a duas novas matrizes. A divisão da primeira pela segunda (*pixel a pixel* correspondente) resulta na etapa de início da identificação, com os frutos evidenciados por meio de valores mais altos do que o restante da imagem. Foi definido um limiar arbitrariamente para a segmentação dos mesmos, que seguirão para as próximas etapas de reconhecimento.

3.4.2 Máquinas de Vetores de Suporte (SVMs)

Logo após uma primeira identificação dos frutos por meio dos valores de razão de suas partes superior e inferior, faz-se necessário o uso de métodos mais robustos para o reconhecimento, tendo-se em vista que as imagens das laranjeiras trazem inúmeros formatos, posições e texturas de folhas, que poderão ser confundidas com frutos mesmo nas imagens de baixo-relevo simulado. Para essa próxima etapa de reconhecimento foram utilizadas Máquinas de Vetores de Suporte (SVMs).

SVMs de margens rígidas definem limites lineares a partir de dados linearmente separáveis. Seja T um conjunto de treinamento com n dados $\mathbf{x}_i \in X$ e seus respectivos rótulos $y_i \in Y$, em que X constitui o espaço dos dados e $Y = \{-1, +1\}$. T é linearmente separável caso seja possível separar os dados das classes $+1$ e -1 por meio de um hiperplano dado por

$$f(x) = \mathbf{w} \cdot \mathbf{x} + b = 0$$

onde $\mathbf{w} \cdot \mathbf{x}$ é o produto escalar entre os vetores, $\mathbf{w} \in X$ é o vetor normal ao hiperplano descrito e $\frac{b}{\|\mathbf{w}\|}$ é a distância do hiperplano em relação à origem, com $b \in \mathbb{R}$. Assim é possível se obter uma função sinal $g(\mathbf{x}) = \text{sgn}(f(\mathbf{x}))$ para ser empregada na obtenção das classificações, como exemplifica a Figura 4 (LORENA; CARVALHO, 2007).

$$g(\mathbf{x}) = \text{sgn}(f(\mathbf{x})) = \begin{cases} +1, & \text{se } \mathbf{w} \cdot \mathbf{x} + b > 0 \\ -1, & \text{se } \mathbf{w} \cdot \mathbf{x} + b < 0. \end{cases}$$

Os limites da margem de separação dos dados devem ser calculados mediante restrições que garantam que não haja dados de treinamento entre as margens de




Figura 4. Hiperplanos para separação entre classes de “círculos” e “triângulos” por meio de Máquinas de Vetores de Suporte (SVMs)

separação das classes, o que dá o nome a esse tipo de SVM como SVM de margens rígidas. A etapa final de definição desses limites para classificação recai em um problema de otimização quadrático, cuja solução possui uma ampla e estabelecida teoria matemática (SCHÖLKOPF; SMOLA, 2002). Como a função objetivo sendo minimizada é convexa e os pontos que satisfazem as restrições formam um conjunto convexo, o problema possui um mínimo global. Tal tipo de problema pode ser resolvido com a introdução de uma função Lagrangiana, englobando as restrições à função objetivo, associadas a parâmetros denominamos multiplicadores de Lagrange α_i , podendo ser expressa por

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i (y_i (\mathbf{w} \cdot \mathbf{x}_i + b) - 1).$$

3.4.3 A transformada de Hough

A transformada de Hough (HOUGH, 1962) propõe uma abordagem eficiente para o reconhecimento de retas em imagens. Considerando o ponto (x_i, y_i) e uma

reta $y_i = ax_i + b$, infinitas retas passam por (x_i, y_i) satisfazendo a equação citada, para diferentes valores de a e b . No entanto, é possível escrever essa reta como $b = -x_i a + y_i$ e, como os valores de x_i e y_i são conhecidos, a representação dessa nova notação no espaço de parâmetros (eixos x e y substituídos por a e b) é dada que cada ponto (x_i, y_i) descreve uma reta correspondente. Quando três ou mais retas se interceptam em um único ponto (a', b') , os pontos correspondentes (x_i, y_i) pertencem a uma mesma reta $y_i = ax_i + b$.

Agora considerando-se a equação de uma circunferência

$$(x - c_1)^2 + (y - c_2)^2 = c_3^2$$

a aplicação da transformada de Hough para a detecção de círculos ocorre de forma análoga. A diferença básica é a presença de três parâmetros (c_1 , c_2 e c_3), que resultam em um espaço de parâmetros tridimensional. O procedimento então é incrementar c_1 e c_2 e achar o c_3 que resolve a equação da circunferência, seguido da atualização do acumulador correspondente (GONZALEZ; WOODS, 2000).

3.4.4 Estratégia utilizada pelo algoritmo de reconhecimento dos frutos

Como as imagens das plantas foram obtidas por diversos amostradores, em diversos tamanhos de plantas e com diversos tamanhos de frutos, foi necessária a implementação de cinco classificadores distintos para a detecção dos frutos. Isso significa que cada classificador ficou responsável pela classificação de um tamanho de fruto (Figura 5).

Tanto os classificadores preliminares (baseados em máscaras espaciais) quanto as SVMs foram subdivididos. Essa subdivisão permitiu um treinamento mais específico das SVMs, aumentando consideravelmente o seu poder de detecção, sem aumentar a quantidade de falso-positivos.

Foi observado nos testes que quanto menor a distância entre a câmera e a copa da planta, maior a quantidade de falso-positivos detectados. Esses casos ocorriam em sua quase totalidade nos padrões de detecção de menores dimensões, por confundirem




Figura 5. Diagrama de fluxo da estratégia de reconhecimento e contagem de frutos em imagens de baixo-relevo simulado de laranjeiras

as folhas (maiores nesses casos) com frutos. Por esse motivo, foi implementada uma regra que desconsiderava os resultados desses padrões dependendo da quantidade de frutos detectada pelos padrões de maiores dimensões.

Por fim, todas as detecções foram armazenadas em uma imagem binária representadas por círculos de raio proporcional ao tamanho do padrão reconhecido. Assim, os frutos reconhecidos por mais de um padrão resultavam em marcações sobrepostas na imagem, evitando a contagem múltipla de um único fruto. Essa imagem binária foi submetida ao detector de círculos de Hough (YUEN et al., 1989) e a contagem de frutos final foi igual ao número de círculos detectados.

3.5 Determinação do número de imagens necessário para a estimativa do número de frutos visíveis por planta

Após a definição dos modelos para a estimativa do número de frutos visíveis por planta, calcularam-se os desvios proporcionais das estimativas, a fim de se calcular o número de unidades amostrais necessário para uma estimativa da média considerando um erro D tolerável, dado em porcentagem. O cálculo foi efetuado com base no método do dimensionamento de amostras para amostragem de tamanho fixo, calculado com base nas definições de intervalo de confiança para a média e após a coleta de uma amostra prévia (THOMPSON, 1992), e dado por

$$n = \frac{t^2 s^2}{D^2}$$

onde t é o valor encontrado para a distribuição t de Student com $n - 1$ graus de liberdade ao nível $\alpha = 5\%$ de probabilidade, s^2 é a variância dos desvios proporcionais e D é a porcentagem de erro tolerada para a estimativa da média.

4 RESULTADOS E DISCUSSÃO

4.1 Extração das características dos frutos com uso dos filtros de Gabor

A etapa mais complexa e desafiadora do processamento de imagens digitais é a segmentação da característica desejada, principalmente em condições variadas de aquisição das imagens (ZHAO et al., 2015). A extração de características texturais por meio dos filtro de Gabor é muito utilizada no processamento de imagens digitais, apresentando um bom desempenho em diversas aplicações, como em imagens de satélite (JAIN; SINHA, 2015) e também tendo seu uso relatado na detecção de padrões circulares (ZHU; TANG; LU, 2004). Motivando-se no trabalho de Kurtulmus, Lee e Vardar (2011), que faz uso de tais filtros para a detecção de laranjas verdes, testes dessa técnica foram efetuados para avaliação de sua capacidade de extração das características dos frutos.

Esses filtros são conhecidos por aplicações em duas variantes: o filtro tradicional e o filtro circular de Gabor. A variante tradicional do filtro permite a extração das características de textura em um determinado ângulo, enquanto que a variante circular executa tal tarefa de maneira radial (ZHU; TANG; LU, 2004). Foram avaliados os efeitos do filtro circular (Figura 6) e do filtro tradicional em cinco direções (0° , 45° , 90° , 135° e 180°) (Figura 7).

Como esperado, os filtros se mostraram bons descritores de textura, evidenciando razoavelmente alguns frutos nas imagens. No entanto, uma observação mais minuciosa revela que existem diversas regiões da imagem onde folhas são facilmente confundidas com frutos. Isso explica o motivo pelo qual, mesmo utilizando uma tomada de decisão baseada na maioria de votos entre as técnicas de limiarização adaptativa, banco de filtros de Gabor e filtro circular de Gabor, a quantidade de detecções incorretas variou entre 27% e 40%, aproximadamente (KURTULMUS; LEE; VARDAR, 2011). Esses resultados demonstraram que o método não apresenta o desempenho necessário para uma segmentação aceitável dos frutos verdes, levando-o a ser rejeitado




Figura 6. Resultados de duas aplicações do filtro circular de Gabor com diferentes valores para o parâmetro σ à componente brilho do modelo HSV em imagem da copa de uma laranjeira

para os testes de reconhecimento e interpretação.

4.2 Extração das características dos frutos com o uso de imagens de baixo-relevo simulado

Foi possível evidenciar os frutos nas imagens das copas das laranjeiras por meio de uma combinação das técnicas de conversão do modelo de cores, limiarização, suavização gaussiana e de filtragem espacial com as máscaras de Sobel e Laplace. Como pode ser observado na Figura 8, as fotos tomadas em campo apresentam uma grande quantidade de elementos indesejáveis que precisam ser identificados e removidos antes dos procedimentos de reconhecimento e contagem dos frutos, como o solo, o céu e as plantas daninhas. Além disso, é importante se atentar para a dificuldade de reconhecimento dos frutos na própria planta, que se confundem muito facilmente com os outros elementos da copa. Nesta seção serão descritos e ilustrados os passos para a obtenção das imagens de baixo relevo simulado que possibilitaram o destacamento dos frutos verdes em diferentes tamanhos.

A conversão do modelo de cores da imagem para HSV é muito utilizada como




Figura 7. Imagem original e banco de filtros tradicionais de Gabor aplicados à componente de brilho do modelo HSV em cinco direções



Figura 8. Imagem original de uma laranjeira com frutos verdes, tomada com uma câmera digital comum

técnica preliminar de processamento de imagens, por possibilitar a segmentação das cores através de uma escala numérica. Na agricultura, sua aplicação inclui a segmentação das plantas do solo em diferentes condições de iluminação (YANG et al., 2015a), segmentação e classificação de diversas culturas com plantas verdes do solo e céu (GUIJARRO et al., 2015), classificação de fibras coloridas de algodão (MUSTAFIC; LI, 2015), determinação dos parâmetros de cor de cerejas durante o processo de maturação (TAGHADOMI-SABERI et al., 2015), acompanhamento do crescimento do milho (YANG et al., 2015b), além da detecção de doenças em plantas (MAHLEIN, 2015).

As fotos das laranjeiras com frutos verdes, obviamente, apresentam essa cor como predominante, o que fez com que o parâmetro cor (ou matiz) fosse descartado das tentativas de destacamento das características dos frutos. Assim, os canais H (*Hue*) e S (*Saturation*) não foram utilizados na extração de suas características. Já o canal V (*Value*) traz informações importantes quanto ao brilho dos frutos, fundamentais

para a criação do baixo-relevo simulado, tornando-o o canal selecionado para o início dos procedimentos de extração de suas características (Figura 9).

A equalização do histograma de níveis de cinza é também muito utilizada no processamento de imagens aplicado à agricultura. Suas propriedades de aumento de contraste são utilizadas na detecção de doenças em folhas de algodão (WARNE; GANORKAR, 2015), por exemplo. Além do mais, a equalização do histograma de níveis de cinza desempenha um papel importante na padronização das condições de iluminação de imagens tomadas em diferentes condições, como no caso deste trabalho. A contagem de copas de plantas com o auxílio de um sistema de câmera móvel a céu aberto é um exemplo da aplicação desta técnica de correção de iluminação (NGUYEN et al., 2015). Sua utilização na melhoria de imagens para segmentação é muito ampla (RANA; CHOPRA, 2015; XU et al., 2015), e já foi relatada em tentativas de segmentação de frutos verdes de laranja (KURTULMUS; LEE; VARDAR, 2011). Com as mesmas finalidades desses casos, o resultado de sua aplicação na camada de brilho de uma imagem de uma laranjeira pode ser observado na Figura 10.

Alguns algoritmos de filtragem espacial têm como consequência de sua aplicação o aumento do ruído da imagem (GONZALEZ; WOODS, 2000). Por ruído entende-se




Figura 9. Imagem original e camada V após a conversão para o modelo de cores HSV




Figura 10. Camada de brilho da imagem no modelo de cores HSV antes e após a equalização do histograma de níveis de cinza

a presença de pequenos *pixels* ou conjuntos de *pixels* alheios à característica que a imagem representa em determinada região de interesse. Assim, faz-se necessária aplicação de métodos com a finalidade de se eliminar ou ao menos reduzir esse efeito negativo. Uma das principais técnicas utilizadas para esse fim é a filtragem gaussiana, também conhecida como suavização gaussiana. Sua aplicação abranda as altas frequências da imagem, diminuindo a quantidade de detalhes e gerando um efeito com aspecto de “borramento”.

A suavização gaussiana é largamente utilizada no processamento de imagens, incluindo-se nos casos aplicados à agricultura. Sua aplicação prévia à utilização do filtro de Laplace é uma das mais comuns e é utilizada na inspeção de qualidade e avaliação de produtos agrícolas e alimentícios através de visão computacional, identificando defeitos e ocorrência de lesões por ataque de pragas ou doenças, por exemplo (NARENDRA; HAREESHA, 2011; DUBEY; JALAL, 2014; KALMEGH; DHOPTE, 2015a). O filtro gaussiano também faz parte do conjunto de técnicas utilizado para a determinação do grau de maturação de bananas por meio de imagens (MUSTAFA et al., 2008). Imagens hiperespectrais também são tratadas utilizando os filtros passa-baixas gaussi-

anos, para a classificação e mapeamento de métodos de cultivo agrícola com o uso de imagens de satélite (RAN et al., 2015). A detecção e segmentação de frutos de manga também faz uso da suavização gaussiana no pré-processamento das imagens (KADIR et al., 2015). Levando em consideração a aplicação da técnica nesses casos, a sua utilização neste trabalho é equivalentemente preliminar, tendo como finalidade somente a eliminação de ruídos excessivos que irão prejudicar a análise de textura, com o cuidado de não serem removidas as altas frequências que serão responsáveis pela diferenciação das folhas (Figura 11).

A próxima etapa de preparação das imagens para a extração das características é a análise de textura. Para essa finalidade foram utilizados os filtros de Laplace e Sobel. A análise de textura consiste basicamente na convolução da imagem por uma máscara espacial que irá destacar as características desejadas considerando-se a vizinhança dos *pixels*. Dessa maneira, um *pixel* ou conjunto de *pixels* que têm vizinhos com níveis de cinza similares aos seus, representam uma região de textura mais suave (baixa frequência) e *pixels* com vizinhos que apresentam valores de níveis de cinza muito distintos dos seus representam uma região com texturas mais abruptas (altas





Figura 11. Camada de brilho da imagem no modelo de cores HSV com equalização do histograma de níveis de cinza antes e após a aplicação da suavização gaussiana

frequências) (GONZALEZ; WOODS, 2000).

Como pode ser observado na Figura 8, os frutos apresentam uma textura mais branda e regular do que as folhas, o que permitiu a sua segmentação através da análise de textura. O filtro direcional passa-altas de Sobel foi utilizado na direção horizontal para a extração da característica de brilho inerente aos frutos (que apresentam formato aproximadamente esférico), caracterizados por um alto brilho na parte visível da semi-esfera superior e um baixo brilho na parte visível da semi-esfera inferior, já que a fonte de iluminação em condições de campo (luz solar) é sempre de origem superior à planta.

O filtro de Sobel é um filtro de detecção de fronteiras e gradiente de intensidade, presente no processamento de imagens digitais para solução de problemas agronômicos. É utilizado na avaliação da qualidade de maçãs por visão computacional (SADEGAONKAR; WAGH, 2015), na determinação de deficiência de nitrogênio em soja (KALMEGH; DHOPTE, 2015b) e na tentativa de extração de lesões complexas em folhas de milho (KELLY et al., 2015). Também é utilizado na determinação do tamanho e do grau de maturação de bananas (MUSTAFA et al., 2008), na detecção de fronteiras para inspeção e avaliação de produtos agrícolas (NARENDRA; HAREESHA, 2011) e na segmentação de solo, plantas daninhas e cultura em imagens de plantações (BURGOS-ARTIZZU et al., 2010; DEEPA; HEMALATHA, 2015). Para a extração das características dos frutos das laranjeiras, considerando sua utilização nesses trabalhos, o filtro de Sobel é aplicado duas vezes na imagem e uma combinação das aplicações irá fazer parte da geração da imagem final de baixo-relevo simulado. É possível se avaliar o efeito das aplicações desse filtro nas Figura 12 e Figura 13.


Na Figura 13 começa a ficar mais evidente o efeito desejado. As partes inferiores dos frutos estão agora apresentando grandes quantidades de *pixels* com valores baixos (cores mais próximas ao preto) e as partes superiores apresentam grande quantidade de *pixels* com valores altos (cores mais próximas ao branco). No entanto, algumas regiões da imagem que não representam frutos ainda podem ser confundidas, o que faz necessária a aplicação de mais algum procedimento para melhorar a diferenciação.



(a) Imagem original

(b) Aplicação do filtro de Sobel

Figura 12. Resultado da primeira aplicação do filtro direcional passa-altas de Sobel na horizontal em imagem de uma laranjeira



(a) Imagem original

(b) Aplicação do filtro de Sobel

Figura 13. Resultado da segunda aplicação do filtro direcional passa-altas de Sobel na horizontal em imagem de uma laranjeira

Um outro método de filtragem espacial, conhecido como laplaciano da gaussiana, é um bom detector de bordas e, por se tratar de um filtro passa-altas, não prejudica a extração das características dos frutos. O efeito esperado dessa filtragem espacial é que as folhas, por possuírem formato irregular, tamanhos muito distintos e transições de intensidade de brilho mais abruptas, sejam salientadas (representadas por níveis de cinza mais altos, ou seja, cores mais próximas do branco) enquanto que os frutos

permaneçam com sua representação inalterada. A aplicação da suavização gaussiana previamente à filtragem espacial com a máscara de Laplace é imprescindível pois, por se tratar de um operador de derivada de segunda ordem, ele tende a ser muito sensível e aumentar consideravelmente o nível de ruído na imagem (GONZALEZ; WOODS, 2000).

O laplaciano da gaussiana desempenha um papel especial na detecção de fronteiras sendo a base de técnicas avançadas de detecção de características-chave para reconhecimento de objetos em imagens, como a SIFT (*Scale-invariant feature transform*) e as SURF (*Speed-up robust features*), capazes de efetuar tal tarefa independentemente da orientação, tamanho do objeto ou distância câmera-objeto em que a imagem foi tomada. Tais técnicas são utilizadas na agricultura para o reconhecimento de espécies de plantas, por exemplo (KAZEROUNI; SCHLEMPERZ; KUHNERT, 2015). É também apontado como o melhor método para a classificação de áreas com base em textura com o uso de imagens de satélite (LEWINSKI; ALEKSANDROWICZ; BANASZ-KIEWICZ, 2015) e no reconhecimento de doenças em plantas com base no padrão das folhas (VISHNU; RAM, 2015). O efeito do laplaciano da gaussiana com a finalidade de detecção de bordas tal qual nos trabalhos citados pode ser observado na imagem de uma laranjeira na Figura 14.

Agora, atentando para as Figura 12, 13 e 14, nota-se que o plano de fundo e o solo não receberam nenhum tratamento específico para a sua separação da copa da planta e dos frutos. Para essa finalidade foi utilizada a limiarização, uma técnica básica do processamento de imagens digitais. A remoção das características inerentes ao solo ocorre através desta técnica aplicada à camada H (*Hue*) do modelo de cores HSV. A escala numérica de 0 a 255 representa diferentes matizes, possibilitando a identificação do solo pela sua cor, que se aproxima de tons marrom-avermelhados. As características do céu foram removidas com base nos valores excessivos de brilho que este apresenta nas imagens.

A remoção do plano de fundo em imagens de objetos usualmente trabalha com





Figura 14. Resultado da aplicação do filtro passa-altas laplaciano da gaussiana para a evidênciação de folhas e outros elementos alheios aos frutos em imagem de uma laranjeira

as técnicas de limiarização. É relatada sua utilização na segmentação de árvores em imagens de satélite (OZCAN et al., 2015), na detecção de doenças em folhas de algodão (WARNE; GANORKAR, 2015), na identificação e contagem de insetos-praga em culturas (MARTIN et al., 2015), na identificação de nós e entrenós para a estimativa de biomassa de milho (POTHULA; IGATHINATHANE; KRONBERG, 2015) e na avaliação da qualidade de grãos de arroz (BIRLA; CHAUHAN, 2015). É também importante na mensuração de altura e largura de partes vegetais como folhas, no caso das folhas de pimenteiras bétete (NAYAK; DEY; SHARMA, 2015). Da mesma maneira que nesses trabalho, a limiarização desempenho papel primordial para a segmentação e remoção das características do céu, do solo e de outros elementos alheios à planta nas imagens, e os resultados podem ser verificados nas Figura 15 e 16.


A imagem de baixo-relevo simulado é agora construída como uma combinação dessas técnicas descritas. Como pode ser verificado na Figura 17, os frutos são destacados como em uma escultura de baixo-relevo, ou seja, com as partes superiores apresentando um alto valor de brilho (níveis de cinza mais altos) e com as partes inferiores mais escuras, já que a fonte de iluminação (luz solar) é sempre de origem



(a) Imagem original

(b) Limiarização (céu)

Figura 15. Limiarização da imagem de uma laranjeira para a remoção das características inerentes ao céu captadas pela imagem digital



(a) Imagem original

(b) Limiarização (solo e outros elementos)

Figura 16. Limiarização da imagem de uma laranjeira para a remoção das características inerentes ao solo e outros elementos alheios à planta captados pela imagem digital

superior à planta. Essa imagem gerada automaticamente possibilita a aplicação de técnicas de reconhecimento e interpretação para a contagem do número de frutos visíveis na planta, caracterizando a primeira etapa para um sistema de estimativa de produção automatizado. Os resultados da aplicação da técnica em outras imagens podem ser verificados no Apêndice A.




Figura 17. Imagem de baixo-relevo simulado de uma laranjeira, evidenciando os frutos verdes com base em análise de textura e brilho. Nesta imagem ficam destacados os frutos pelo efeito de baixo valor de brilho (cor preta) em suas partes inferiores

4.3 Comparação do método de contagem automática com o método de contagem manual nas imagens

A Figura 18 ilustra o desempenho geral do método em comparação com as contagens manuais. Para a obtenção dessa relação foram utilizadas 1182 imagens de 591 plantas. Foram removidas 200 imagens de 100 plantas do conjunto inicial por estarem em más condições para as contagens automáticas e em alguns casos até para as contagens manuais. Cada ponto nos gráficos desta seção expressa a soma das contagens automáticas das duas fotos tiradas de uma mesma planta no eixo x e a soma das contagens manuais das duas fotos no eixo y .

Dentre os fatores que poderiam influenciar no desempenho do algoritmo foi dada importância principalmente à idade e à variedade das plantas. Um efeito da idade era esperado devido ao tamanho da planta, que poderia influenciar na nitidez dos frutos no interior da copa, na quantidade de frutos oclusos pelas folhas e também quanto ao tamanho dos frutos nas imagens, mesmo com uma distância padronizada para a tomada das imagens. Já quanto à variedade era esperado um efeito da quantidade de




Figura 18. Regressão linear entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011

frutos menos nítidos no interior da planta. Os efeitos dos grupos de idade podem ser observados na Figura 19 e das variedades na Figura 20.

Assim, ainda com relação à Figura 19, fica possível se observar uma diferença no resultado das contagens automáticas para o grupo de idade 1 (de 3 a 5 anos). Basicamente, o intercepto desse modelo linear foi menor do que para as outras idades, tal ocorrido podendo ser explicado pela quantidade de frutos não contados automaticamente mas que foram reconhecidos pelos avaliadores nas imagens. Tais frutos seriam os parcialmente oclusos, que não são tão evidentes para uma classificação confiável automática mas são passíveis de reconhecimento pela capacidade humana de classificação.

Já com relação às variedades, não foi possível se notar efeito importante para a diferenciação dos modelos. Isso indica que, caso haja algum efeito dessas variedades na quantidade de frutos visíveis na planta, tal efeito não foi suficiente para que o método automático apresentasse diferenças regulares nas contagens quando comparadas às feitas manualmente.

Os resultados do algoritmo também foram agrupados de acordo com os setores




Figura 19. Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011 e estratificadas por grupos de idade

do estado de São Paulo, a fim de se estabelecer diferenças entre o desempenho da detecção. Foi observada uma pequena diferença entre os setores Centro e Sul, que não justifica a diferenciação dos resultados quanto à esse critério. Essa pequena diferença pode ser atribuída a presença de plantas com maior quantidade de frutos visíveis no setor Centro, o que alterou levemente o coeficiente angular do modelo (Figura 21)). Assim, a utilização de modelos distintos quanto ao setor do estado não traz maior precisão à estimativa do número de frutos visíveis pois o único efeito que se pode descrever nesse caso é o do erro do método.

Na mesma linha que a explicação anterior estão os efeitos das regiões do estado




Figura 20. Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011 e estratificadas por variedades




Figura 21. Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011 e estratificadas por setores do estado de São Paulo

de São Paulo. Aparentemente, a variação do erro do método foi muito similar em todas as regiões, levando à conclusão que não há provável influência das regiões no desempenho do algoritmo de detecção automática de frutos (Figura 22).

Levando em conta os dois principais fatores dos quais se esperam algum efeito no desempenho do algoritmo, foi efetuado um desdobramento para cada combinação de variedades com grupos de idade, a fim de se detectar variações quanto ao desempenho do método automático. Os resultados demonstram que o modelo linear é capaz de representar a relação entre as contagens do método automático com as contagens manuais em 11 das 12 combinações entre variedades e grupos de idade. As contagens da variedade Natal com idade dos 3 aos 5 anos não obtiveram resultado significativo no ajuste do modelo provavelmente pelo pequeno número de pontos disponíveis para o ajuste. Os valores do coeficiente de determinação do ajuste dos modelos (R^2) variaram de 0,19 (Pêra de 3 a 5 anos de idade) a 0,74 (Natal com 11 anos ou mais de idade) (Figura 23).

O efeito dos grupos de idade foi avaliado também dentro de cada setor produtivo do estado de São Paulo. Isso foi feito para a determinação de possíveis melhores desempenhos das contagens dentro de cada combinação entre setores e idades. Mais uma vez o efeito mais evidente é o dos grupos de idade, devido a variações principalmente no intercepto dos modelos, com destaque para o grupo de 3 a 5 anos de idade, que apresentou valores menores deste parâmetro (Figura 24).

Com base nos ajustes dos modelos lineares, pode-se perceber um desempenho similar do algoritmo de detecção automática de frutos para os estratos estudados. As diferenças observadas apontam que a estratificação por variedades e grupos de idade pode trazer maior precisão às estimativas de alguns casos. No entanto, alguns casos apresentaram uma baixa precisão do algoritmo (valores de R^2 muito baixos), devida principalmente à qualidade das imagens.




Figura 22. Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011 e estratificadas por regiões do estado de São Paulo




Figura 23. Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011 e estratificadas pelas combinações entre as variedades e os grupos de idades estudados




Figura 24. Regressões lineares entre o número de frutos contados pelo método automático e o número de frutos contados manualmente nas imagens de 591 plantas (1182 imagens) tomadas na safra de 2011 e estratificadas pelas combinações entre os setores do estado de São Paulo e os grupos de idades estudados

4.3.1 Influência da qualidade das imagens nos resultados do algoritmo de detecção e contagem automática

Na avaliação do método automático de contagem dos frutos foram identificadas diversas imagens que tiveram que ser descartadas do conjunto de dados utilizado nos ajustes por estarem em condições desfavoráveis para a aplicação do algoritmo. Aproximadamente 14% das imagens foram removidas por estarem desfocadas, muito próximas das plantas, por terem sido tomadas sem o uso de flash ou contra a luz do Sol (Tabela 2). De maneira geral, a distância de 2 m da copa da planta apresentou bons resultados para a identificação dos frutos, porém algumas imagens apresentaram frutos muito grandes, prejudicando os resultados das contagens. Os padrões de frutos aos quais os classificadores foram submetidos durante a etapa de treinamento das SVMs

mostraram um bom resultado para a classificação de frutos com diâmetro variando entre 20 *pixels* e 40 *pixels*, aproximadamente, nas imagens redimensionadas para 1024×768 *pixels*. Assim, imagens muito próximas não tiveram frutos reconhecidos além de apresentarem um alto número de falso-positivos.

O método de extração das características dos frutos baseado na geração de imagens de baixo-relevo simulado é extremamente sensível à iluminação direta. Como descrito na Seção 4.2, a base para o reconhecimento se dá no fato de que a fonte de iluminação deve ser superior aos frutos, para que o efeito característico de baixo relevo possa ser extraído. Sendo assim, quando há incidência de luz solar direta na lateral da planta o desempenho do reconhecimento de frutos é afetado drasticamente. Na maior parte dos casos, a incidência de luz solar direta sobre as plantas, independente do ângulo, é prejudicial ao método e deve ser evitada. Esse efeito negativo da incidência solar também já foi relatado ao se utilizar outras técnicas para a extração das características dos frutos (KURTULMUS; LEE; VARDAR, 2011). Por fim, algumas imagens também foram removidas do conjunto de interesse por não apresentarem as informações necessárias para a sua estratificação.

Um conjunto de imagens obtidas em boas condições pode ser visualizado no Apêndice B e um conjunto com exemplos de imagens obtidas em más condições está disponível no Apêndice C.

Tabela 2. Motivos e número de descartes de imagens do conjunto de dados (1382 imagens) para avaliação do método automático de contagem de frutos em laranjeiras na safra de 2011

Motivo do descarte	Quantidade	Porcentagem
Imagem desfocada	36	2,6%
Muito próximo da planta	46	3,3%
Imagem tomada sem flash	14	1,0%
Iluminação lateral	16	1,2%
Falta de informações sobre o estrato	88	6,4%
Total	200	14,5%

4.3.2 Tempo despendido nos métodos de contagem

Ambos os métodos foram avaliados quanto ao tempo necessário para a contagem dos frutos em cada imagem (Tabela 3). No método manual, o maior tempo despendido foi devido ao reconhecimento e identificação por parte do avaliador, fazendo com que os recursos computacionais tivessem influência desprezível nos resultados finais.

A execução das contagens pelo método automático propiciou uma redução de aproximadamente 85% do tempo médio necessário para a contagem em uma imagem em relação ao método manual e uma redução de aproximadamente 90% do tempo despendido pelo método de Kurtulmus, Lee e Vardar (2011). Esse ganho de tempo será de extrema importância para sua aplicação prática, viabilizando a utilização de um número maior de imagens para a estimativa do total de frutos por planta.

4.3.3 Avaliação do desempenho do algoritmo quanto à detecção dos frutos

O algoritmo desenvolvido não foi capaz de detectar todos os frutos presentes nas imagens. Além disso, ocorreram detecções de partes das imagens que não eram frutos, chamados de falso-positivos. Esses erros de classificação são devidos à desuniformidade de iluminação, qualidade da imagem, ausência de luz de flash na tomada da imagem, distância entre a câmera e a planta e diferentes tamanhos de

Tabela 3. Estatística descritiva do tempo despendido em segundos por imagem nas contagens de frutos, em 1182 imagens pelos métodos manual e automático

Estatística	Manual	Automático
Média	64,9	9,79
Mediana	63,2	9,80
Mínimo	49,8	8,50
Máximo	94,7	11,8
Amplitude	45,0	3,30
Desvio padrão	13,1	0,31
Coeficiente de variação	20%	3%

frutos. A performance do algoritmo pode ser avaliada na Tabela 4.

Esses resultados da apuração da performance demonstram que a porcentagem de frutos corretamente identificados é constante e que a taxa de falso-positivos foi baixa. Valores de falso-positivos maiores foram obtidos pelo método de Kurtulmus, Lee e Vardar (2011), que chegaram a até 40,3% em avaliações de apenas duas imagens, confirmando uma maior precisão no reconhecimento e uma maior resiliência do algoritmo proposto neste trabalho. Vale ressaltar que esses valores foram obtidos para um conjunto de 1182 imagens, onde somente foram removidas as imagens de qualidade muito ruim para a aplicação dos testes de detecção.

Para se avaliar a performance do algoritmo em função da qualidade das imagens, considerando principalmente os fatores iluminação e distância entre a câmera e a copa da planta, no momento da avaliação elas foram classificadas em muito boa, boa, regular ou ruim. Os resultados da porcentagem de frutos corretamente identificados se mantiveram constantes nos estratos em que a qualidade da foto não era ruim e aumentaram nesse último caso. Já a porcentagem de falso-positivos aumentou consideravelmente à medida que a qualidade da imagem caiu (Tabela 5). Além disso, o erro padrão da média também foi maior nas imagens de qualidade inferior, tanto para as detecções corretas quanto para os falso-positivos, deixando claro o efeito negativo das imagens em más condições de obtenção no desempenho do algoritmo.

4.3.4 Determinação do número de imagens necessário para a estimativa do número de frutos visíveis

A última etapa da avaliação do método automático de estimativa do número de frutos visíveis nas imagens foi o dimensionamento do tamanho de amostra necessário para a estimativa da média de frutos visíveis dentro de uma determinada margem de erro. Os resultados podem ser observados na Tabela 6.

Os valores encontrados para o número de unidades amostrais necessário para as estimativas corroboram mais uma vez para a conclusão que o método automático

Tabela 4. Avaliação do desempenho do algoritmo de detecção automática de frutos em imagens de laranjeiras por meio das porcentagens de detecções $\pm$ o erro padrão da média em diversos estratos e em 1182 imagens individuais da safra de 2011

Estrato	Imagens	Corretamente identificados	Falso-positivos
Geral	1182	49,03 $\pm$ 1,42%	14,68 $\pm$ 0,52%
<i>Variedades</i>			
Hamlin	184	44,27 $\pm$ 1,29%	11,24 $\pm$ 0,89%
Natal	150	46,48 $\pm$ 1,78%	14,22 $\pm$ 1,29%
Pêra	346	52,21 $\pm$ 1,94%	17,75 $\pm$ 0,91%
Valência	502	49,32 $\pm$ 2,99%	13,96 $\pm$ 0,90%
<i>Grupos de idade</i>			
3 a 5 anos	246	53,53 $\pm$ 2,03%	17,27 $\pm$ 1,02%
6 a 10 anos	368	47,30 $\pm$ 1,02%	12,66 $\pm$ 0,78%
11 anos ou mais	568	48,22 $\pm$ 2,73%	14,86 $\pm$ 0,84%
<i>Setores do estado de São Paulo</i>			
Centro	766	49,61 $\pm$ 2,06%	11,98 $\pm$ 0,50%
Sul	416	47,93 $\pm$ 1,34%	19,72 $\pm$ 1,12%
<i>Regiões do estado de São Paulo</i>			
Araraquara	166	48,60 $\pm$ 1,41%	8,34 $\pm$ 1,03%
Bauru	416	47,93 $\pm$ 1,34%	19,72 $\pm$ 1,12%
Itápolis	386	49,69 $\pm$ 1,53%	14,53 $\pm$ 0,72%
Matão	106	42,89 $\pm$ 1,53%	9,85 $\pm$ 1,19%
Taquaritinga	108	57,51 $\pm$ 13,64%	10,31 $\pm$ 1,25%

Tabela 5. Avaliação do desempenho do algoritmo de detecção automática de frutos em imagens de laranjeiras pelas porcentagens de detecções $\pm$ o erro padrão da média agrupadas por qualidade da imagem em 1182 imagens individuais da safra de 2011

Estrato	Imagens	Corretamente identificados	Falso-positivos
Geral	1182	49,03 $\pm$ 1,42%	14,68 $\pm$ 0,52%
<i>Qualidade da imagem</i>			
Muito boa	281	46,63 $\pm$ 0,74%	3,20 $\pm$ 0,21%
Boa	349	44,74 $\pm$ 0,93%	8,34 $\pm$ 0,41%
Regular	464	51,06 $\pm$ 1,54%	20,90 $\pm$ 0,71%
Ruim	88	62,91 $\pm$ 16,45%	42,40 $\pm$ 3,70%

Tabela 6. Número de imagens necessário para a estimativa do número de frutos visíveis por planta para os erros tolerados de 5, 10, 15 e 20%, em que foram sempre tomadas duas imagens de uma mesma planta

Estrato	Imagens	Unidades amostrais			
		5%	10%	15%	20%
Geral	1182	278	70	30	18
<i>Variedades</i>					
Hamlin	184	78	20	8	4
Natal	150	212	52	24	14
Pêra	346	324	80	36	20
Valência	502	332	84	36	20
<i>Grupos de idade</i>					
3 a 5 anos	246	404	102	44	26
6 a 10 anos	368	134	34	14	8
11 anos ou mais	568	308	76	34	20
<i>Setores do estado de São Paulo</i>					
Centro	766	298	74	34	18
Sul	416	240	60	26	14
<i>Regiões do estado de São Paulo</i>					
Araraquara	166	72	18	8	4
Bauru	416	240	60	26	14
Itápolis	386	304	76	34	20
Matão	106	86	22	10	6
Taquaritinga	108	866	216	96	54

pode substituir o método manual na execução das estimativas do número de frutos visíveis em plantas de laranja de diversas variedades e idades. Como o método de contagem automática é rápido e completamente independente de assistência humana, se torna viável a utilização de diversas imagens para a estimativa. Com exceção da região de Taquaritinga, os resultados obtidos na precisão de 10% apresentaram um número cabível de amostras para a utilização prática.

Dadas as diferenças estruturais das plantas devido às variedades e aos grupos de idade, foram determinados os números de unidades amostrais necessários para cada combinação entre tais fatores (Tabela 7), independentemente da qualidade das imagens.

Tabela 7. Número de imagens necessário para a estimativa do número de frutos visíveis por planta para os erros tolerados de 5, 10, 15 e 20% dentro de cada combinação entre variedades e grupos de idade, em que foram sempre tomadas duas imagens de uma mesma planta

Estrato	Imagens	Unidades amostrais			
		5%	10%	15%	20%
Geral	1182	278	70	30	18
<i>Variedades × grupos de idade</i>					
Hamlin × 3 a 5 anos	54	140	36	16	8
Hamlin × 6 a 10 anos	70	46	12	6	2
Hamlin × 11 anos ou mais	60	48	12	6	2
Natal × 3 a 5 anos	18	208	52	24	14
Natal × 6 a 10 anos	66	386	96	42	24
Natal × 11 anos ou mais	66	62	16	6	4
Pêra × 3 a 5 anos	58	824	206	92	52
Pêra × 6 a 10 anos	102	112	28	12	6
Pêra × 11 anos ou mais	186	254	64	28	16
Valência × 3 a 5 anos	116	338	84	38	22
Valência × 6 a 10 anos	130	88	22	10	6
Valência × 11 anos ou mais	256	458	114	50	28

Nas combinações Hamlin de 6 a 10 anos de idade e Hamlin com 11 anos ou mais são apresentados os melhores resultados do algoritmo. Nesses casos é possível se estimar a média de frutos visíveis com uma precisão de 5% utilizando apenas 48 imagens. Isso significa que, se tomadas 100 amostras com 48 imagens cada de uma população de plantas da variedade Hamlin de 6 ou mais anos de idade, em 95 delas ($t_{\alpha=5\%}$) o valor da média estimada na amostra estará dentro do intervalo da média populacional $\pm 5\%$. Convém destacar também que o procedimento de contagem dos frutos em 48 imagens levará aproximadamente 470 segundos (7,8 minutos) para ser concluído, sem nenhum tipo de intervenção humana.

4.4 Comparação dos métodos de contagem de frutos manual e automático em imagens para a estimativa do total de frutos por planta

A primeira etapa para a construção de um método automatizado para a estimativa da produção de citros por meio de imagens da copa da planta é a avaliação da relação entre o número de frutos visíveis e o número total de frutos na árvore. Tal relação já foi investigada previamente e é sabido que a estimativa visual é possível (TRIBONI; BARBOSA, 2004). Essa relação foi reavaliada neste trabalho.

Uma fonte de variação que prejudicou a definição dos modelos e a avaliação do desempenho de ambos os métodos foi a falta de padronização quanto a área da copa da planta abrangida pela imagem. Em 572 imagens as plantas não foram completamente enquadradas no momento da tomada das imagens, o que levou à existência de tamanhos de fruto muito grandes nas imagens e também ocasionou problemas para a modelagem do número total de frutos presentes na árvore, já que grande parte das plantas que continham frutos simplesmente foi “cortada” da imagem. Por essa razão foram removidas as imagens das plantas que não apresentavam sua copa inteira, pois verificou-se que é preciso amostrar toda a copa da planta para se obter uma boa relação entre o número de frutos visíveis e o total de frutos nas plantas. Após a remoção das imagens impróprias, restaram 610 imagens de 305 laranjeiras para a definição dos modelos.

Como o método automático demonstrou um resultado constante na contagem dos frutos visíveis nas imagens e um baixo valor de falso-positivos, os resultados das contagens manuais e automáticas foram também relacionados com o total de frutos por planta, obtido após a derriça e contagem manual de cada uma delas no campo. A Figura 25 ilustra o resultado dessa relação por análise de regressão linear para ambos os métodos de contagem nas imagens.

Ao comparar-se os dois métodos, fica evidente pelo coeficiente angular dos modelos ajustados que o método automático conta menos frutos que o método manual. Esse comportamento é esperado, já que o rigor do algoritmo foi elevado com a finalidade

de se diminuir a quantidade de detecções de falso-positivos, os principais responsáveis pela imprecisão do método nos testes. Mesmo assim, há uma relação funcional entre o número de frutos contados automaticamente com o total de frutos por planta observado nas derriças, fazendo com que o método apresente potencial para a estimativa desse valor.

Relacionando agora os valores das contagens nas imagens com o total de frutos nas plantas fica claro o efeito dos grupos de idade sobre o ajuste dos modelos lineares. Esse comportamento ocorre devido ao tamanho da copa da planta, fazendo com que, quanto mais velha ela é, maior a quantidade de frutos não visíveis nas imagens que deixaram de ser contados tanto pelo método manual quanto pelo método automático (Figura 26). Comparando os valores dos coeficientes angulares para ambos os métodos de contagem entre os grupos de idade, é possível se notar apenas um leve aumento para o grupo de idade de 6 a 10 anos. Porém o mesmo não pode ser afirmado para os valores dos interceptos, que variaram expressivamente entre tais grupos, corroborando com teoria de que o número de frutos ocultos aumenta




Figura 25. Regressões lineares entre as contagens e o total de frutos por planta para os métodos manual e automático avaliados em imagens tomadas na safra de 2011 (610 imagens de 305 plantas)

com a idade da planta (Figura 27). É possível se observar também, avaliando os valores do coeficiente de determinação do ajuste, que os métodos manual e automático apresentaram resposta similar às subdivisões nesses estratos.

Já com relação às variedades, podemos observar um padrão diferente principalmente para os casos da Hamlin e da Valência. Tanto no método de contagem manual quanto no método automático essa diferença é visível (Figura 28). Esse efeito pode também ser avaliado pelos diferentes resultados dos modelos estratificados (Figura 29), que apresentaram valores de R^2 mais elevados indicando um melhor ajuste no caso da Natal, Pêra e Valência. Esse efeito não foi verificado para a Hamlin, essencialmente pelo fato de que as plantas mais velhas dessa variedade possuem uma grande quantidade de frutos não visíveis nas imagens, aumentando os valores do coeficiente angular do modelo no estrato da combinação entre Hamlin e idade maior que 11 anos (Figura 30 e Figura 31).

Buscando uma precisão maior nas estimativas dos modelos lineares, ajustes mais específicos foram procedidos para cada combinação entre variedades e idades para ambos os métodos. Todas as combinações apresentaram ajuste significativo do modelo linear para as contagens manuais, com valores de R^2 sempre maiores que




Figura 26. Comparação entre os métodos manual e automático de contagem de frutos em imagens de laranjeiras para estimativa do total de frutos por planta. Imagens estratificadas por grupos de idade e tomadas na safra de 2011 (610 imagens de 305 plantas)




Figura 27. Regressões lineares entre as contagens e o total de frutos por planta para os métodos manual e automático de contagem de frutos em imagens de laranjeiras. Imagens estratificadas por grupos de idade e tomadas na safra de 2011 (610 imagens de 305 plantas)




Figura 28. Comparação entre os métodos manual e automático de contagem de frutos em imagens de laranjeiras para estimativa do total de frutos por planta. Imagens estratificadas por variedades e tomadas na safra de 2011 (610 imagens de 305 plantas)

0,49 (Figura 30). O método automático também apresentou bons resultados para os modelos ajustados nesses estratos, com exceção da Hamlin com 11 anos ou mais de idade, Natal de 6 a 10 anos de idade, Pêra de 3 a 5 anos de idade e Valência de 6 a 10 anos de idade (Figura 31). Essa disparidade entre os métodos é devida à incapacidade do método em reconhecer os frutos nas imagens e ao elevado grau de falso-positivos em alguns casos.

Os dados também foram estratificados por setores e regiões do estado de São Paulo. Não foi possível delimitar diferenças importantes entre os modelos que justifiquem a sua utilização nas estimativas (Figura 32 e Figura 34). Os valores dos coeficientes de determinação dos ajustes também apresentaram resultados inferiores para o método automático, indicando que o método não foi capaz de efetuar o reconhecimento e a contagem dos frutos com a mesma precisão que o ser humano (Figura 33 e Figura 35).

Os resultados apontam que é importante trabalhar com modelos distintos para cada combinação entre variedades e idades, tendo em vista que a quantidade de frutos visíveis e o tamanho das plantas alteram a resposta quanto ao total de frutos na planta. O método automático mostrou bons resultados em algumas dessas combinações, sali-




Figura 29. Regressões lineares entre as contagens e o total de frutos por planta para os métodos manual e automático de contagem de frutos em imagens de laranjeiras. Imagens estratificadas por variedades e tomadas na safra de 2011 (610 imagens de 305 plantas)




Figura 30. Regressões lineares entre as contagens e o total de frutos por planta para o método manual de contagem de frutos em imagens de laranjeiras. Imagens estratificadas pelas combinações entre variedades e grupos de idade e tomadas na safra de 2011 (610 imagens de 305 plantas)




Figura 31. Regressões lineares entre as contagens e o total de frutos por planta para o método automático de contagem de frutos em imagens de laranjeiras. Imagens estratificadas pelas combinações entre variedades e grupos de idade e tomadas na safra de 2011 (610 imagens de 305 plantas)




Figura 32. Comparação entre os métodos manual e automático de contagem de frutos em imagens de laranjeiras para estimativa do total de frutos por planta. Imagens estratificadas por setores do estado de São Paulo e tomadas na safra de 2011 (610 imagens de 305 plantas)




Figura 33. Regressões lineares entre as contagens e o total de frutos por planta para os métodos manual e automático de contagem de frutos em imagens de laranjeiras. Imagens estratificadas por setores do estado de São Paulo e tomadas na safra de 2011 (610 imagens de 305 plantas)




Figura 34. Comparação entre os métodos manual e automático de contagem de frutos em imagens de laranjeiras para estimativa do total de frutos por planta. Imagens estratificadas por regiões do estado de São Paulo e tomadas na safra de 2011 (610 imagens de 305 plantas)

entando o potencial do algoritmo para o desenvolvimento de um sistema de estimativa completamente automatizado. Valores de R^2 maiores que 0,90 foram observados por Triboni e Barbosa (2004) para a relação entre o número de frutos visíveis em imagens digitais e o total de frutos nas plantas para alguns estratos das combinações variedades $\times$ grupos de idade, possivelmente por diferenças nas condições das imagens utilizadas.

4.5 Considerações finais

O presente trabalho traz o desenvolvimento de um método de geração de imagens de baixo-relevo simulado a partir de imagens comuns de duas dimensões. Além da aplicação nele relatada, com a finalidade de se detectar e contar automaticamente frutos verdes em laranjeiras, é importante situar sua importância em outras áreas.

Como já exposto no texto, a extração de características é uma etapa desafiadora no processamento de imagens digitais, citada por vários autores como a mais desafiadora de todo o processo. No entanto, o método mostrou resultados muito positivos para a segmentação de formas esféricas sob as mais diversas condições de iluminação encontradas no campo. Isso traz, além de um potencial para a utilização em outras




Figura 35. Regressões lineares entre as contagens e o total de frutos por planta para os métodos manual e automático de contagem de frutos em imagens de laranjeiras. Imagens estratificadas por regiões do estado de São Paulo e tomadas na safra de 2011 (610 imagens de 305 plantas)

culturas (como limão, tangerina, manga, maçã, etc.), o potencial de utilização em robótica e visão computacional com outras finalidades, como o desenvolvimento de equipamentos de colheita inteligentes, por exemplo.

Além do mais, vale reiterar que o sistema foi desenvolvido em C++ utilizando a biblioteca OpenCV (BRADSKI, 2015). Tal fato faz com que essa tecnologia seja facilmente portátil para um dispositivo móvel como um *smartphone* (*Android* ou *iOS*). Obviamente, dados os essenciais ajustes e testes para essa finalidade, fica passível de obtenção uma ferramenta de acesso muito fácil para a execução das tarefas de amostragem e estimativa de produção da cultura do citros. O ganho operacional, econômico e em precisão, com a padronização da atividade em detrimento das atuais estimativas subjetivas dos técnicos, se torna assim indiscutível.

Por fim, com o atual advento dos veículos aéreos não tripulados (VANTs), não se pode deixar de discutir sua relação com a proposta deste trabalho. Tais dispositivos apresentam também todos os requisitos para terem embarcados os métodos desenvolvidos para a extração de características e para a execução totalmente automática de procedimentos de amostragem. Considerados os estudos, ajustes e testes a serem ainda realizados, fica evidente mais uma aplicação potencial deste estudo, com perspectivas de progresso indiscutíveis.

5 CONCLUSÕES

Foi desenvolvido um método para a extração das características de frutos verdes em imagens digitais de laranjeiras através da geração de imagens de baixo-relevo simulado.

Foi desenvolvido um algoritmo para o reconhecimento e contagem automática de frutos verdes em imagens de laranjeiras de diversas variedades e idades, com grande potencial de ganho econômico e operacional.

O método automático apresentou uma baixa taxa de falso-positivos em imagens obtidas em boas condições.

O método automático é capaz de estimar a média do número de frutos visíveis por planta nas imagens com 5% de confiança utilizando até 46 imagens, em um tempo de aproximadamente 8 minutos.

A ausência de flash e a incidência de luz solar direta sobre a planta prejudicam o desempenho do algoritmo nas detecções de frutos, ocasionando elevada ocorrência de falso-positivos.

Há um efeito das variedades e dos grupos de idade das plantas na relação entre o número frutos visíveis nas imagens e total de frutos na planta.

6 REFERÊNCIAS

- ANNAMALAI, P. **Citrus yield mapping system using machine vision**. 2004. Tese (Doutorado) — University of Florida, 2004. Disponível em: http://etd.fcla.edu/UF/UFE0006901/annamalai_p.pdf. Acesso em: 27 jun. 2015.
- ANNAMALAI, P.; LEE, W. S.; BURKS, T. F. Color vision system for estimating citrus yield in real-time. In: ASAE/CSAE Annual International Meeting. 1., 2004, Ontario. **Anais...**, Ontario: ASAE/CSAE, 2004.
- BELHUMEUR, P. N.; KRIEGMAN, D. J.; YUILLE, A. L. The Bas-Relief Ambiguity. **International Journal of Computer Vision**, v. 35, n. 1, p. 33–44, nov. 1999. Disponível em: <http://link.springer.com/article/10.1023/A%3A1008154927611>. Acesso em: 13 out. 2015.
- BIRLA, R.; CHAUHAN, A. P. S. An Efficient Method for Quality Analysis of Rice Using Machine Vision System. **Journal of Advances in Information Technology**, p. 140–145, 2015. Disponível em: <http://www.jait.us/index.php?m=content&c=index&a=show&catid=168&id=895>. Acesso em: 23 nov. 2015.
- BRADSKI, G. **Open Source Computer Vision Library**. 2015. Disponível em: <https://github.com/Itseez/opencv>. Acesso em: 31 maio 2015.
- BURGOS-ARTIZZU, X. P.; RIBEIRO, A.; TELLAECHÉ, A.; PAJARES, G.; FERNÁNDEZ-QUINTANILLA, C. Analysis of natural images processing for the extraction of agricultural elements. **Image and Vision Computing**, v. 28, n. 1, p. 138–149, jan. 2010. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0262885609001140>. Acesso em: 20 nov. 2015.
- CHINCHULUUN, R.; LEE, W. S.; BURKS, T. F. Machine vision-based Citrus yield mapping system. In: PROC. Fla. State Hort. Soc. 119., 2006. **Anais...**, [S.l.: s.n.], 2006. p. 142–147.
- CIGNONI, P.; MONTANI, C.; SCOPIGNO, R. Computer-Assisted Generation of Bas-and High-Reliefs. **Journal of Graphics Tools**, v. 2, n. 3, p. 15–28, jan. 1997. Disponível em: <http://dx.doi.org/10.1080/10867651.1997.10487476>. Acesso em: 15 out. 2015.
- DEEPA, S.; HEMALATHA, R. Weed Detection Using Image Processing. **International Journal of Research in Computer Applications and Robotics**, v. 3, n. 7, p. 29–31, 2015. Disponível em: http://ijrcar.com/Volume_3_Issue_7/v3i706.pdf. Acesso em: 20 nov. 2015.

DONATO DI NICCOLO DI BETTO BARDI. **Milagre do coração do homem avaro**. 1447. Disponível em: <http://www.wahooart.com>.

DUBEY, S. R.; JALAL, A. S. Application of Image Processing in Fruit and Vegetable Analysis: A Review. **Journal of Intelligent Systems**, v. 24, n. 4, 2014.

DURAND, F.; DORSEY, J. Fast Bilateral Filtering for the Display of High-dynamic-range Images. In: PROCEEDINGS OF THE 29TH Annual Conference ON Computer Graphics AND Interactive Techniques. 2002, New York, NY, USA. **Anais eletrônicos...**, New York, NY, USA: ACM, 2002. p. 257–266. ISBN 1-58113-521-1. Disponível em: <http://doi.acm.org/10.1145/566570.566574>. Acesso em: 13 out. 2015.

FOGEL, I.; SAGI, D. Gabor filters as texture discriminator. **Biological cybernetics**, v. 61, n. 2, p. 103–113, 1989. Disponível em: <http://link.springer.com/article/10.1007/BF00204594>. Acesso em: 21 maio 2015.

FUNDECITRUS. **Fundo de Defesa da Citricultura**. 2016. Disponível em: <http://www.fundecitrus.com.br/pes>. Acesso em: 27 mar. 2016.

GABOR, D. Theory of communication. Part 1: The analysis of information. **Journal of the Institution of Electrical Engineers - Part III: Radio and Communication Engineering**, v. 93, n. 26, p. 429–441, nov. 1946. Disponível em: <http://digital-library.theiet.org/content/journals/10.1049/ji-3-2.1946.0074>. Acesso em: 29 set. 2015.

GONG, A.; YU, J.; HE, Y.; QIU, Z. Citrus yield estimation based on images processed by an Android mobile phone. **Biosystems Engineering**, v. 115, n. 2, p. 162–170, jun. 2013. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1537511013000500>. Acesso em: 27 jun. 2015.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. São Paulo: Edgard Blucher, 2000. ISBN 85-212-0264-4 978-85-212-0264-6.

GRIGORESCU, S.; PETKOV, N.; KRUIZINGA, P. Comparison of texture features based on Gabor filters. **IEEE Transactions on Image Processing**, v. 11, n. 10, p. 1160–1167, out. 2002. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1042386>. Acesso em: 21 maio 2015.

GUIJARRO, M.; RIOMOROS, I.; PAJARES, G.; ZITINSKI, P. Discrete wavelets transform for improving greenness image segmentation in agricultural images. **Computers and Electronics in Agriculture**, v. 118, p. 396–407, out. 2015. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0168169915002860>. Acesso em: 19 nov. 2015.

HAYKIN, S. A Comprehensive Foundation. 2004, 00000. Disponível em: http://www.znu.ac.ir/data/members/fazli.saeid/ANN/Books/Haykin/HAYKIN_TOC.PDF. Acesso em: 22 dez. 2015.

HAZEWINDEL, M. **Encyclopaedia of Mathematics**. [S.l.]: Springer Science & Business Media, 2013. ISBN 978-94-009-5994-1.

HOUGH. **Method and means for recognizing complex patterns**. 1962. 03189 Classificação nos Estados Unidos 382/281, 382/202, 342/176, 342/190; Classificação internacional G06K9/46, G01T5/02, G01T5/00; Classificação cooperativa G06K9/4633, G01T5/02; Classificação europeia G06K9/46A2, G01T5/02. Disponível em: <http://www.google.com/patents/US3069654>. Acesso em: 29 dez. 2015.

ISAGI, Y.; SUGIMURA, K.; SUMIDA, A.; ITO, H. How Does Masting Happen and Synchronize? **Journal of Theoretical Biology**, v. 187, n. 2, p. 231–239, jul. 1997. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0022519397904422>. Acesso em: 28 jun. 2015.

JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data clustering: a review. **ACM computing surveys (CSUR)**, v. 31, n. 3, p. 264–323, 1999. Disponível em: <http://dl.acm.org/citation.cfm?id=331504>. Acesso em: 21 maio 2015.

JAIN, M.; SINHA, A. Classification of Satellite Images through Gabor Filter using SVM. **International Journal of Computer Applications**, v. 116, n. 7, 2015. Disponível em: <http://search.proquest.com/openview/0dfbff75c8a88302a15a0448326ffd13/1?pq-origsite=gscholar>. Acesso em: 23 nov. 2015.

Jl, Z.; MA, W.; SUN, X. Bas-relief modeling from normal images with intuitive styles. **Visualization and Computer Graphics, IEEE Transactions on**, v. 20, n. 5, p. 675–685, 2014. Disponível em: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=6684153. Acesso em: 21 maio 2015.

KADIR, M. F. A.; YUSRI, N. A. N.; RIZON, M.; MAMAT, A. R. b.; MAKHTAR, M.; JAMAL, A. A. Automatic mango detection using texture analysis and randomised Hough transform. **Applied Mathematical Sciences**, 2015. Disponível em: <http://www.m-hikari.com/ams/ams-2015/ams-129-130-2015/53290.html>. Acesso em: 19 nov. 2015.

KALMEGH, S. M.; DHOPTE, S. V. Detection of Edges in Color Images to Estimate Plant Diseases. 2015a. Disponível em: <http://www.ijsr.net/archive/v4i4/SUB153659.pdf>. Acesso em: 19 nov. 2015.

KALMEGH, S. M.; DHOPTÉ, S. V. Determination of Nitrogen Deficiency in Soya Bean Using Edge Detection. **International Journal of Mechanical Engineering and Information Technology**, v. 3, n. 6, p. 1376–1382, 2015b. Disponível em: <http://igmpublication.org/ijmeit%20issue/v3-i6/11%20ijmeit.pdf>.

KAZEROUNI, M. F.; SCHLEMPERZ, J.; KUHNERT, K.-D. Efficient Modern Description Methods by Using SURF Algorithm for Recognition of Plant Species. **Advances in Image and Video Processing**, v. 3, n. 2, abr. 2015. Disponível em: <http://scholarpublishing.org/index.php/AIVP/article/view/1151>. Acesso em: 22 nov. 2015.

KELLY, D.; VATSA, A.; MAYHAM, W.; KAZIC, T. Extracting complex lesion phenotypes in Zea mays. **Machine Vision and Applications**, p. 1–12, out. 2015. Disponível em: <http://link.springer.com/article/10.1007/s00138-015-0718-6>. Acesso em: 20 nov. 2015.

KEUCHEL, J.; NAUMANN, S.; HEILER, M.; SIEGMUND, A. Automatic land cover analysis for Tenerife by supervised classification using remotely sensed data. **Remote Sensing of Environment**, v. 86, n. 4, p. 530–541, ago. 2003, 00147. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0034425703001305>. Acesso em: 29 dez. 2015.

KURTULMUS, F.; LEE, W. S.; VARDAR, A. Green citrus detection using ‘eigenfruit’, color and circular Gabor texture features under natural outdoor conditions. **Computers and Electronics in Agriculture**, v. 78, n. 2, p. 140–149, set. 2011. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0168169911001475>. Acesso em: 26 jun. 2015.

KURTULMUS, F.; ÜNAL, H. Discriminating rapeseed varieties using computer vision and machine learning. **Expert Systems with Applications**, v. 42, n. 4, p. 1880–1891, mar. 2015. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0957417414006265>. Acesso em: 23 nov. 2015.

LAGAE, A.; LEFEBVRE, S.; DRETTAKIS, G.; DUTRÉ, P. Procedural noise using sparse Gabor convolution. In: ACM Transactions ON Graphics (TOG). 28., 2009. **Anais eletrônicos...**, ACM, 2009. p. 54. Disponível em: <http://dl.acm.org/citation.cfm?id=1531360>. Acesso em: 21 maio 2015.

LEWINSKI, S.; ALEKSANDROWICZ, S.; BANASZKIEWICZ, M. Testing Texture of VHR Panchromatic Data as a Feature of Land Cover Classification. **Acta Geophysica**, v. 63, n. 2, p. 547–567, 2015. Disponível em: <http://www.degruyter.com/view/j/acgeo.2015.63.issue-2/s11600-014-0250-5/s11600-014-0250-5.xml>. Acesso em: 22 nov. 2015.

LI, L.; DONG, J.; TENKU, S. N.; XIAO, X. Mapping Oil Palm Plantations in Cameroon Using PALSAR 50-m Orthorectified Mosaic Images. **Remote Sensing**, v. 7, n. 2, p. 1206–1224, jan. 2015. Disponível em: <http://www.mdpi.com/2072-4292/7/2/1206>. Acesso em: 23 nov. 2015.

LORENA, A. C.; CARVALHO, A. C. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43–67, 2007. Disponível em: http://www.seer.ufrgs.br/rita/article/viewArticle/rita_v14_n2_p43-67. Acesso em: 24 nov. 2015.

MACARTHUR, D. K.; SCHUELLER, J. K.; LEE, W. S.; CRANE, C. D.; MACARTHUR, E. Z.; PARSONS, L. R. Remotely-Piloted Helicopter Citrus Yield Map Estimation. In: . 2006. **Anais eletrônicos...**, American Society of Agricultural and Biological Engineers, 2006. Disponível em: <http://elibrary.asabe.org/abstract.asp?JID=5&AID=20892&CID=por2006&T=1>. Acesso em: 29 set. 2015.

MAHLEIN, A.-K. Plant Disease Detection by Imaging Sensors – Parallels and Specific Demands for Precision Agriculture and Plant Phenotyping. **Plant Disease**, set. 2015. Disponível em: <http://apsjournals.apsnet.org/doi/abs/10.1094/PDIS-03-15-0340-FE>. Acesso em: 19 nov. 2015.

MARR, D.; HILDRETH, E. Theory of edge detection. **Proceedings of the Royal Society of London B: Biological Sciences**, v. 207, n. 1167, p. 187–217, 1980. Disponível em: <http://rspb.royalsocietypublishing.org/content/207/1167/187.short>. Acesso em: 20 out. 2015.

MARTIN, A.; SATHISH, D.; BALACHANDER, C.; HARIPRASATH, T.; KRISHNAMORTHY, G. Identification and counting of pests using extended region grow algorithm. In: 2015 2ND International Conference ON Electronics AND Communication Systems (ICECS). 2015. **Anais...**, [S.l.: s.n.], 2015. p. 1229–1234.

MIZUSHIMA, A.; LU, R. An image segmentation method for apple sorting and grading using support vector machine and Otsu's method. **Computers and Electronics in Agriculture**, v. 94, p. 29–37, jun. 2013. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0168169913000483>. Acesso em: 29 set. 2015.

MUSTAFA, N.; FUAD, N. A.; AHMED, S.; ABIDIN, A.; ALI, Z.; YIT, W.; SHARRIF, Z. Image processing of an agriculture produce: Determination of size and ripeness of a banana. In: INTERNATIONAL Symposium ON Information Technology, 2008. ITSIm 2008. 1., 2008. **Anais...**, [S.l.: s.n.], 2008. p. 1–7.

MUSTAFIC, A.; LI, C. Classification of cotton foreign matter using color features extracted from fluorescent images. **Textile Research Journal**, v. 85, n. 12, p. 1209–1220, jul. 2015. Disponível em: <http://trj.sagepub.com/cgi/doi/10.1177/0040517514561923>. Acesso em: 19 nov. 2015.

NAGASAI, S.; RANI, S. J. Plant Disease Identification using Segmentation Techniques. **Plant Disease**, v. 4, n. 9, 2015. Disponível em: <http://ijarcce.com/upload/2015/september-15/IJARCCE%2088.pdf>. Acesso em: 23 nov. 2015.

NARENDRA, V. G.; HAREESHA, K. S. Study and Comparison of various Image edge Detection techniques used in Quality inspection and Evaluation of Agricultural and Food products by Computer vision. **International Journal of Agricultural & Biological Engineering**, v. 4, n. 2, p. 83–90, jun. 2011. Disponível em: <http://www.ijabe.org/index.php/ijabe/index>. Acesso em: 19 nov. 2015.

NAYAK, D.; DEY, A.; SHARMA, M. Measurement of length and width of betel leaf by image processing using MATLAB. In: 2015 International Conference ON Electrical, Electronics, Signals, Communication AND Optimization (EESCO). 2015. **Anais...**, [S.l.: s.n.], 2015. p. 1–5.

NGUYEN, T. T.; SLAUGHTER, D. C.; HANSON, B. D.; BARBER, A.; FREITAS, A.; ROBLES, D.; WHELAN, E. Automated Mobile System for Accurate Outdoor Tree Crop Enumeration Using an Uncalibrated Camera. **Sensors**, v. 15, n. 8, p. 18427–18442, jul. 2015. Disponível em: <http://www.mdpi.com/1424-8220/15/8/18427>. Acesso em: 19 nov. 2015.

NOGUCHI, Y.; SAKAI, K.; ASADA, S.; GARCIANO, L.; SASAO, A. Modeling of Alternate Bearing in Satsuma Mandarin. **Journal of the Japanese Society of Agricultural Machinery**, v. 65, n. 6, p. 55–61, 2003.

OKAMOTO, H.; LEE, W. S. Green citrus detection using hyperspectral imaging. **Computers and Electronics in Agriculture**, v. 66, n. 2, p. 201–208, maio 2009. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0168169909000258>. Acesso em: 26 jun. 2015.

OTSU, N. A threshold selection method from gray-level histograms. **Automatica**, v. 11, n. 285-296, p. 23–27, 1975. Disponível em: <http://web-ext.u-aizu.ac.jp/course/bmclass/documents/otsu1979.pdf>. Acesso em: 31 maio 2015.

OZCAN, A.; SAYAR, Y.; HISAR, D.; UNSALAN, C. Multiscale tree analysis from satellite images. In: 2015 7TH International Conference ON Recent Advances IN Space Technologies (RAST). 2015. **Anais...**, [S.l.: s.n.], 2015. p. 265–269.

PARIS, S.; DURAND, F. A fast approximation of the bilateral filter using a signal processing approach. In: **Computer Vision–ECCV 2006**. Springer, 2006. p. 568–580. Disponível em: http://link.springer.com/chapter/10.1007/11744085_44. Acesso em: 13 out. 2015.

PORTER, R.; CANAGARAJAH, N. Robust rotation-invariant texture classification: wavelet, Gabor filter and GMRF based schemes. **Vision, Image and Signal Processing, IEE Proceedings -**, v. 144, n. 3, p. 180–188, jun. 1997.

POTHULA, A. K.; IGATHINATHANE, C.; KRONBERG, S. Profile based image analysis for identification of chopped biomass stem nodes and internodes. **Industrial Crops and Products**, v. 70, p. 374–382, ago. 2015. Disponível em: <http://www.sciencedirect.com/science/article/pii/S092666901500237X>. Acesso em: 23 nov. 2015.

PRASAD, V. S. N.; DOMKE, J. Gabor filter visualization. **J. Atmos. Sci**, v. 13, 2005. Disponível em: <https://www.cs.umd.edu/class/spring2005/cmsc838s/assignment-projects/gabor-filter-visualization/report.pdf>. Acesso em: 21 maio 2015.

R CORE TEAM. R: A Language and Environment for Statistical Computing. Vienna, Austria, 2015. Disponível em: <https://www.R-project.org/>.

RAN, Q.; LI, W.; DU, Q.; YANG, C. Hyperspectral image classification for mapping agricultural tillage practices. **Journal of Applied Remote Sensing**, v. 9, n. 1, p. 097298–097298, 2015. Disponível em: <http://dx.doi.org/10.1117/1.JRS.9.097298>. Acesso em: 19 nov. 2015.

RANA, P.; CHOPRA, V. A Study on Image Enhancement Techniques. **IJARCCCE**, v. 4, n. 5, p. 609–611, maio 2015. Disponível em: <http://ijarcce.com/upload/2015/may-15/IJARCCCE%20130.pdf>. Acesso em: 19 nov. 2015.

REGUNATHAN, M.; LEE, W. S. Citrus Fruit Identification and Size Determination Using Machine Vision and Ultrasonic Sensors. In: . 2005. **Anais eletrônicos...**, American Society of Agricultural and Biological Engineers, 2005. 00025. Disponível em: <http://elibrary.asabe.org/abstract.asp?JID=5&AID=19821&CID=tf12005&T=1>. Acesso em: 02 jan. 2016.

SADEGAONKAR, V. D.; WAGH, K. H. Improving Quality of Apple Using Computer Vision & Image Processing Based Grading System. **International Journal of Science and Research (IJSR)**, v. 4, n. 4, p. 543–546, 2015. Disponível em: <http://www.ijsr.net/archive/v4i4/SUB152911.pdf>. Acesso em: 20 nov. 2015.

SAKAI, K.; NOGUCHI, Y.; ASADA, S.-I. Detecting chaos in a citrus orchard: Reconstruction of nonlinear dynamics from very short ecological time series. **Chaos, Solitons & Fractals**, v. 38, n. 5, p. 1274–1282, dez. 2008. Disponível em: <http://www.sciencedirect.com/science/article/pii/S096007790700272X>. Acesso em: 28 jun. 2015.

SAVVIDES, M.; KUMAR, B. V. Illumination normalization using logarithm transforms for face authentication. In: AUDIO-AND Video-Based Biometric Person Authentication. 2003. **Anais eletrônicos...**, Springer, 2003. p. 549–556. Disponível em: http://link.springer.com/chapter/10.1007/3-540-44887-X_65. Acesso em: 16 out. 2015.

SA'AD, F. S. A.; IBRAHIM, M. F.; SHAKAFF, A. Y. M.; ZAKARIA, A.; ABDULLAH, M. Z. Shape and weight grading of mangoes using visible imaging. **Computers and Electronics in Agriculture**, v. 115, p. 51–56, jul. 2015. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0168169915001283>. Acesso em: 23 nov. 2015.

SCHÖLKOPF, B.; SMOLA, A. J. **Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond**. [S.l.]: MIT Press, 2002. 10011. ISBN 978-0-262-19475-4.

TAGHADOMI-SABERI, S.; OMID, M.; EMAM-DJOMEH, Z.; FARAJI-MAHYARI, K. Determination of Cherry Color Parameters during Ripening by Artificial Neural Network Assisted Image Processing Technique. **Journal of Agricultural Science and Technology**, v. 17, n. 3, p. 589–600, maio 2015. Disponível em: http://jast.modares.ac.ir/article_12686_17.html. Acesso em: 19 nov. 2015.

THOMPSON, S. K. **Sampling**. New York: Wiley, 1992. (Wiley series in probability and mathematical statistics). 02567. ISBN 978-0-471-54045-8.

TRIBONI, H. d. R.; BARBOSA, J. C. Estimativa do número de frutos por amostragem de parte da copa em laranjeiras. **Revista Brasileira de Fruticultura**, v. 26, n. 3, p. 454–458, 2004. Disponível em: <http://www.scielo.br/pdf/%0D/rbf/v26n3/23144.pdf>. Acesso em: 27 jun. 2015.

VISHNU, S.; RAM, A. R. Plant Disease Detection Using Leaf Pattern: A Review. v. 2, n. 6, p. 774–780, 2015. Disponível em: http://ijiset.com/vol2/v2s6/IJISSET_V2.I6.110.pdf. Acesso em: 22 nov. 2015.

WANG, M. **3D digital relief generation**. 2011. Tese (Doutorado) — Bournemouth University, 2011. Disponível em: <http://core.kmi.open.ac.uk/download/pdf/4899220.pdf>. Acesso em: 21 maio 2015.

WARNE, P. P.; GANORKAR, S. R. Detection of Diseases on Cotton Leaves Using K-Mean Clustering Method. 2015. Disponível em: <http://www.ijret.net/archives/V2/i4/Irjet-v2i474.pdf>. Acesso em: 19 nov. 2015.

WEISS, B. Fast Median and Bilateral Filtering. In: ACM SIGGRAPH 2006 Papers. 2006, New York, NY, USA. **Anais eletrônicos...**, New York, NY, USA: ACM, 2006. p. 519–526. ISBN 1-59593-364-6. Disponível em: <http://doi.acm.org/10.1145/1179352.1141918>. Acesso em: 13 out. 2015.

XU, S.; XING, K.; TIAN, Y.; MA, G. Effect of light intensity on *Epinephelus malabaricus*'s image processing. 2015. Disponível em: http://www.atlantis-press.com/php/download_paper.php?id=24642. Acesso em: 19 nov. 2015.

YANG, W.; WANG, S.; ZHAO, X.; ZHANG, J.; FENG, J. Greenness identification based on HSV decision tree. **Information Processing in Agriculture**, 2015a. Disponível em: <http://www.sciencedirect.com/science/article/pii/S2214317315000347>. Acesso em: 19 nov. 2015.

YANG, W.; ZHAO, X.; WANG, S.; CHEN, L.; CHEN, X.; LU, S. A New Approach for Greenness Identification from Maize Images. In: HUANG, D.-S.; BEVILACQUA, V.; PREMARATNE, P. (Ed.). **Intelligent Computing Theories and Methodologies**. Springer International Publishing, 2015b, (Lecture Notes in Computer Science, 9225). p. 339–347. ISBN 978-3-319-22179-3 978-3-319-22180-9. DOI: 10.1007/978-3-319-22180-9_33. Disponível em: http://link.springer.com/chapter/10.1007/978-3-319-22180-9_33. Acesso em: 19 nov. 2015.

YE, X.; SAKAI, K.; ASADA, S.-i.; SASAO, A. Application of narrow-band TBVI in estimating fruit yield in citrus. **Biosystems Engineering**, v. 99, n. 2, p. 179–189, fev. 2008. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1537511007002565>. Acesso em: 27 jun. 2015.

YE, X.; SAKAI, K.; GARCIANO, L. O.; ASADA, S.-I.; SASAO, A. Estimation of citrus yield from airborne hyperspectral images using a neural network model. **Ecological Modelling**, v. 198, n. 3–4, p. 426–432, out. 2006. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0304380006002547>. Acesso em: 27 jun. 2015.

YE, X.; SAKAI, K.; MANAGO, M.; ASADA, S.-i.; SASAO, A. Prediction of citrus yield from airborne hyperspectral imagery. **Precision Agriculture**, v. 8, n. 3, p. 111–125, abr. 2007. Disponível em: <http://link.springer.com/article/10.1007/s11119-007-9032-2>. Acesso em: 27 jun. 2015.

YUEN, H. K.; PRINCEN, J.; DLINGWORTH, J.; KITTLER, J. A Comparative Study of Hough Transform Methods for Circle Finding. In: . 1989. **Anais eletrônicos...**, Alvey Vision Club, 1989. p. 29.1–29.6. 00000. Disponível em: <http://www.bmva.org/bmvc/1989/avc-89-029.html>. Acesso em: 15 dez. 2015.

ZHANG, J.; TAN, T.; MA, L. Invariant texture segmentation via circular Gabor filters. In: . 2., 2002. **Anais eletrônicos...**, IEEE Comput. Soc, 2002. p. 901–904. Disponível em: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1048450>. Acesso em: 29 set. 2015.

ZHAO, M.; QIN, J.; LI, S.; LIU, Z.; CAO, J.; YAO, X.; YE, S.; LI, L. An Automatic Counting Method of Maize Ear Grain Based on Image Processing. In: LI, D.; CHEN, Y. (Ed.). **Computer and Computing Technologies in Agriculture VIII**. Springer International Publishing, 2015, (IFIP Advances in Information and Communication Technology, 452). p. 521–533. ISBN 978-3-319-19619-0 978-3-319-19620-6. DOI: 10.1007/978-3-319-19620-6_59. Disponível em: http://link.springer.com/chapter/10.1007/978-3-319-19620-6_59. Acesso em: 22 nov. 2015.

ZHU, Z.; TANG, M.; LU, H. A new robust circular Gabor based object matching by using weighted Hausdorff distance. **Pattern Recognition Letters**, v. 25, n. 4, p. 515–523, mar. 2004. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0167865503002836>. Acesso em: 29 set. 2015.

APÊNDICES

**APÊNDICE A – EXEMPLOS DE GERAÇÃO DE IMAGENS DE BAIXO-RELEVO
SIMULADO A PARTIR DE IMAGENS DIGITAIS DE LARANJEIRAS**



Figura 1A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 6 e 10 anos



Figura 2A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 6 e 10 anos




Figura 3A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 6 e 10 anos



Figura 4A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 6 e 10 anos




Figura 5A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade maior que 10 anos




Figura 6A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade maior que 10 anos




Figura 7A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 6 e 10 anos



Figura 8A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 6 e 10 anos




Figura 9A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 3 e 5 anos



Figura 10A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Valência, com idade entre 3 e 5 anos




Figura 11A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 3 e 5 anos




Figura 12A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 3 e 5 anos




Figura 13A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 3 e 5 anos




Figura 14A. Imagem de baixo-relevo simulado de uma laranjeira da variedade Hamlin, com idade entre 3 e 5 anos

APÊNDICE B – RESULTADO DA DETECÇÃO AUTOMÁTICA DE FRUTOS VERDES EM IMAGENS OBTIDAS EM BOAS CONDIÇÕES



Figura 1B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 3 e 5 anos



Figura 2B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 3 e 5 anos



Figura 3B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 3 e 5 anos



Figura 4B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 3 e 5 anos



Figura 5B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com idade entre 6 e 10 anos



Figura 6B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com idade entre 6 e 10 anos



Figura 7B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Natal com mais de 11 anos de idade



Figura 8B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 6 e 10 anos



Figura 9B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com mais de 11 anos de idade



Figura 10B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com mais de 11 anos de idade



Figura 11B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Natal com mais de 11 anos de idade



Figura 12B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Hamlin com idade entre 6 e 10 anos



Figura 13B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Pêra com mais de 11 anos de idade



Figura 14B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com idade entre 3 e 5 anos



Figura 15B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com idade entre 3 e 5 anos



Figura 16B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Natal com idade entre 6 e 10 anos



Figura 17B. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em laranjeira Valência com idade entre 6 e 10 anos

APÊNDICE C – RESULTADO DA DETECÇÃO AUTOMÁTICA DE FRUTOS VERDES EM IMAGENS OBTIDAS EM MÁIS CONDIÇÕES



Figura 1C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada sem flash



Figura 2C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem desfocada



Figura 3C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada contra a luz do sol e desfocada



Figura 4C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada com a câmera muito próxima à copa da planta



Figura 5C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada sem flash



Figura 6C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada com a câmera muito próxima à copa da planta



Figura 7C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem com incidência de luz solar direta sobre a planta



Figura 8C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem desfocada



Figura 9C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada contra o Sol



Figura 10C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem tomada sem flash



Figura 11C. Resultado da aplicação do algoritmo de contagem automática de frutos verdes em imagem de laranjeira com idade menor que 3 anos

APÊNDICE D – CÓDIGOS-FONTE

```
1 //
2 // CircularGaborFilter.cpp
3 //
4 // Created by Walter Maldonado Jr on 07/10/15.
5 // Copyright 2015 Walter Maldonado Jr. All rights reserved.
6 //
7 #include "CircularGaborFilter.hpp"
8 #include <opencv2/core/core.hpp>
9 #include <opencv2/highgui/highgui.hpp>
10 #include <opencv2/imgproc/imgproc.hpp>
11
12 cv::Mat getCircularGaborKernel(cv::Size ksize, double sigma, double F,
13                               int ktype)
14 {
15     int xmin, xmax, ymin, ymax;
16
17     xmax = ksize.width / 2;
18     ymax = ksize.height / 2;
19
20     xmin = -xmax;
21     ymin = -ymax;
22
23     CV_Assert(ktype == CV_32F || ktype == CV_64F);
24
25     cv::Mat kernel(ymax - ymin + 1, xmax - xmin + 1, ktype);
26
27     for (int y = ymin; y <= ymax; y++)
28         for (int x = xmin; x <= xmax; x++)
29             {
30                 double xr = x;
31                 double yr = y;
32                 double v =
33                     (1 / (2 * CV_PI * sigma * sigma)) *
34                     std::exp(-1 * ((xr * xr + yr * yr) / 2 * sigma * sigma)) *
35                     cos(2 * CV_PI * F * sqrt(xr * xr + yr * yr));
36
37                 if (ktype == CV_32F)
38                     kernel.at<float>(ymax - y, xmax - x) = (float)v;
39                 else
40                     kernel.at<double>(ymax - y, xmax - x) = v;
41             }
42
43     return kernel;
44 }
```

Figura 1D. Implementação do filtro circular de Gabor em C++ para a geração de uma máscara espacial a ser utilizada nas funções de filtragem da biblioteca OpenCV (BRADSKI, 2015)

```

1 //
2 //  BatchFruitCounter.cpp
3 //
4 //  Created by Walter Maldonado Jr on 07/10/15.
5 //  Copyright 2015 Walter Maldonado Jr. All rights reserved.
6 //
7 #include "BatchFruitCounter.hpp"
8
9 #include <opencv2/core/core.hpp>
10 #include <opencv2/highgui/highgui.hpp>
11 #include <opencv2/imgproc/imgproc.hpp>
12 #include <boost/filesystem.hpp>
13 #include <iostream>
14 #include <fstream>
15
16 void batchFruitCount(std::string const &dirPath)
17 {
18     path imgDir(dirPath);
19     path upImgDir = imgDir.parent_path();
20     path runDirName = imgDir.stem();
21     path outDirName = upImgDir;
22     outDirName /= runDirName.string() + "_out";
23
24     cout << "Run Directory: " + imgDir.string() << endl;
25     cout << "Parent Run Directory: " + upImgDir.string() << endl;
26     cout << "Run Directory Name: " + runDirName.string() << endl;
27     cout << "Out Directory Name: " + outDirName.string() << endl;
28
29     cout << "Removing Directory " + outDirName.string() << endl;
30     remove_all(outDirName);
31     cout << "Creating Directory " + outDirName.string() << endl;
32     create_directory(outDirName);
33
34     uint64 startTime = GetTimeMs64();
35
36     // MARK: SVM Definition and Training
37     CvSVM svm0;
38     CvSVM svm1;
39     CvSVM svm2;
40     CvSVM svm3;
41     CvSVM svm4;
42     CvSVM svm5;
43     CvSVMParams params;
44     params.svm_type = CvSVM::C_SVC;
45     params.kernel_type = CvSVM::LINEAR;
46     params.term_crit = cvTermCriteria(CV_TERMCRIT_ITER, 100, 1e-6);
47
48     std::pair<Mat, Mat> train0 =
49         prepareTrainMat("/Users/walter/Work/Doutorado/SVM/ratio_pos0",
50                         "/Users/walter/Work/Doutorado/SVM/ratio_neg0",
51                         24, 20);
52     svm0.train(train0.first, train0.second, Mat(), Mat(), params);
53
54     std::pair<Mat, Mat> train1 =
55         prepareTrainMat("/Users/walter/Work/Doutorado/SVM/ratio_pos1",

```

```

56         "/Users/walter/Work/Doutorado/SVM/ratio_neg1",
57         28, 24);
58     svm1.train(train1.first, train1.second, Mat(), Mat(), params);
59
60     std::pair<Mat, Mat> train2 =
61         prepareTrainMat("/Users/walter/Work/Doutorado/SVM/ratio_pos2",
62                         "/Users/walter/Work/Doutorado/SVM/ratio_neg2",
63                         36, 28);
64     svm2.train(train2.first, train2.second, Mat(), Mat(), params);
65
66     std::pair<Mat, Mat> train3 =
67         prepareTrainMat("/Users/walter/Work/Doutorado/SVM/ratio_pos3",
68                         "/Users/walter/Work/Doutorado/SVM/ratio_neg3",
69                         40, 32);
70     svm3.train(train3.first, train3.second, Mat(), Mat(), params);
71
72     std::pair<Mat, Mat> train4 =
73         prepareTrainMat("/Users/walter/Work/Doutorado/SVM/ratio_pos4",
74                         "/Users/walter/Work/Doutorado/SVM/ratio_neg4",
75                         48, 40);
76     svm4.train(train4.first, train4.second, Mat(), Mat(), params);
77
78     std::pair<Mat, Mat> train5 =
79         prepareTrainMat("/Users/walter/Work/Doutorado/SVM/ratio_pos5",
80                         "/Users/walter/Work/Doutorado/SVM/ratio_neg5",
81                         56, 48);
82     svm5.train(train5.first, train5.second, Mat(), Mat(), params);
83
84     uint64 trainingTime = GetTimeMs64() - startTime;
85
86     cout << "Creating Results File " + outDirName.string() +
87           "/results.txt" << endl;
88     ofstream results;
89     results.open(outDirName.string() + "/results.txt");
90     results << "IMAGE\tFS1\tFS2\tFS3\tTOTAL\tFN\tFR\tTIME\n";
91     results << "Training Time: " << trainingTime << endl;
92     results.close();
93
94     // MARK: Processing of images found in directory
95     directory_iterator dirIteratorEnd;
96     for (directory_iterator itr(imgDir);
97          itr != dirIteratorEnd; ++itr)
98     {
99         path fe = itr->path().extension();
100         if (is_regular_file(itr->path()) &&
101             (fe == ".jpg" || fe == ".JPG"))
102         {
103             path newImgDir = outDirName;
104             newImgDir /= itr->path().stem();
105             cout << "Creating Directory " + newImgDir.string() << endl;
106             create_directory(newImgDir);
107             path newImgDirPos = newImgDir.string() + "/pos";
108             path newImgDirNeg = newImgDir.string() + "/neg";
109             create_directory(newImgDirPos);
110             create_directory(newImgDirNeg);
111

```

```

112     uint64 imgTime = GetTimeMs64();
113
114     Mat input = imread(itr->path().string());
115     saveImg(input, newImgDir.string() + "/01-InputImage.jpg");
116     Mat preMat = basRelief(input);
117     saveImg(preMat, newImgDir.string() + "/02-BasRelief.jpg");
118
119     // MARK: Detecting fruits in image
120     resize(preMat, preMat, cv::Size(1024, 768));
121     Mat ratio0 = ratioMat(preMat, 6, 5);
122     Mat ratio1 = ratioMat(preMat, 7, 6);
123     Mat ratio2 = ratioMat(preMat, 9, 7);
124     Mat ratio3 = ratioMat(preMat, 10, 8);
125     Mat ratio4 = ratioMat(preMat, 12, 10);
126     Mat ratio5 = ratioMat(preMat, 14, 12);
127
128     std::vector<cv::Point> points0 =
129         detectRatio(preMat, ratio0, 6, 5, svm0, newImgDir.string());
130     std::vector<cv::Point> points1 =
131         detectRatio(preMat, ratio1, 7, 6, svm1, newImgDir.string());
132     std::vector<cv::Point> points2 =
133         detectRatio(preMat, ratio2, 9, 7, svm2, newImgDir.string());
134     std::vector<cv::Point> points3 =
135         detectRatio(preMat, ratio3, 10, 8, svm3, newImgDir.string());
136     std::vector<cv::Point> points4 =
137         detectRatio(preMat, ratio4, 12, 10, svm4, newImgDir.string());
138     std::vector<cv::Point> points5 =
139         detectRatio(preMat, ratio5, 14, 12, svm5, newImgDir.string());
140
141     resize(input, input, cv::Size(1024, 768));
142     Mat rPeaks = input.clone();
143     rPeaks.convertTo(rPeaks, CV_8UC3);
144
145     Mat fArea = Mat::zeros(preMat.rows, preMat.cols, CV_8U);
146
147     if ((points5.size() <= 3) && (points4.size() <= 5) &&
148         (points3.size() <= 7))
149     {
150         for(std::vector<cv::Point>::size_type i = 0;
151             i != points0.size(); i++)
152         {
153             cv::Point pt = points0[i];
154             circle(rPeaks, pt, 7, Scalar(255, 0, 0), 1, 8, 0);
155             circle(fArea, pt, 7, 255, -1);
156         }
157         saveImg(rPeaks, newImgDir.string() +
158             "/03-7px-PatternRecognition.jpg");
159         saveImg(fArea, newImgDir.string() +
160             "/04-7px-AreaRecognition.jpg");
161     }
162
163     if ((points5.size() <= 6) &&
164         (points4.size() <= 4))
165     {
166         for(std::vector<cv::Point>::size_type i = 0;
167             i != points1.size(); i++)

```

```

168     {
169         cv::Point pt = points1[i];
170         if (std::find(points0.begin(),
171             points0.end(), pt) == points0.end())
172         {
173             circle(rPeaks, pt, 9, Scalar(0, 255, 255), 1, 8, 0);
174             circle(fArea, pt, 9, 255, -1);
175         }
176     }
177     saveImg(rPeaks, newImgDir.string() +
178         "/05-9px-PatternRecognition.jpg");
179     saveImg(fArea, newImgDir.string() +
180         "/06-9px-AreaRecognition.jpg");
181 }
182
183 for(std::vector<cv::Point>::size_type i = 0;
184     i != points2.size(); i++)
185 {
186     cv::Point pt = points2[i];
187     if ((std::find(points0.begin(),
188         points0.end(), pt) == points0.end()) &&
189         (std::find(points1.begin(),
190             points1.end(), pt) == points1.end()))
191     {
192         circle(rPeaks, pt, 11, Scalar(0, 0, 255), 1, 8, 0);
193         circle(fArea, pt, 11, 255, -1);
194     }
195 }
196 saveImg(rPeaks, newImgDir.string() +
197     "/07-11px-PatternRecognition.jpg");
198 saveImg(fArea, newImgDir.string() +
199     "/08-11px-AreaRecognition.jpg");
200
201 for(std::vector<cv::Point>::size_type i = 0;
202     i != points3.size(); i++)
203 {
204     cv::Point pt = points3[i];
205     if ((std::find(points0.begin(),
206         points0.end(), pt) == points0.end()) &&
207         (std::find(points1.begin(),
208             points1.end(), pt) == points1.end()) &&
209         (std::find(points2.begin(),
210             points2.end(), pt) == points2.end()))
211     {
212         circle(rPeaks, pt, 13, Scalar(0, 255, 0), 1, 8, 0);
213         circle(fArea, pt, 13, 255, -1);
214     }
215 }
216 saveImg(rPeaks, newImgDir.string() +
217     "/09-13px-PatternRecognition.jpg");
218 saveImg(fArea, newImgDir.string() +
219     "/10-13px-AreaRecognition.jpg");
220
221 for(std::vector<cv::Point>::size_type i = 0;
222     i != points4.size(); i++)
223 {

```



```

224     cv::Point pt = points4[i];
225     if ((std::find(points0.begin(),
226                   points0.end(), pt) == points0.end()) &&
227         (std::find(points1.begin(),
228                   points1.end(), pt) == points1.end()) &&
229         (std::find(points2.begin(),
230                   points2.end(), pt) == points2.end()) &&
231         (std::find(points3.begin(),
232                   points3.end(), pt) == points3.end()))
233     {
234         circle(rPeaks, pt, 15, Scalar(255, 255, 0), 1, 8, 0);
235         circle(fArea, pt, 15, 255, -1);
236     }
237 }
238 saveImg(rPeaks, newImgDir.string() +
239         "/11-15px-PatternRecognition.jpg");
240 saveImg(fArea, newImgDir.string() +
241         "/12-15px-AreaRecognition.jpg");
242
243 for(std::vector<cv::Point>::size_type i = 0;
244     i != points5.size(); i++)
245 {
246     cv::Point pt = points5[i];
247     if ((std::find(points0.begin(),
248                   points0.end(), pt) == points0.end()) &&
249         (std::find(points1.begin(),
250                   points1.end(), pt) == points1.end()) &&
251         (std::find(points2.begin(),
252                   points2.end(), pt) == points2.end()) &&
253         (std::find(points3.begin(),
254                   points3.end(), pt) == points3.end()) &&
255         (std::find(points4.begin(),
256                   points4.end(), pt) == points4.end()))
257     {
258         circle(rPeaks, pt, 17, Scalar(255, 0, 255), 1, 8, 0);
259         circle(fArea, pt, 17, 255, -1);
260     }
261 }
262 saveImg(rPeaks, newImgDir.string() +
263         "/13-17px-PatternRecognition.jpg");
264 saveImg(fArea, newImgDir.string() +
265         "/14-17px-AreaRecognition.jpg");
266
267 // MARK: Hough Circles
268 Mat houghC;
269 vector<Vec3f> circles;
270 houghC = fArea.clone();
271 GaussianBlur(houghC, houghC, Size(9, 9), 2, 2);
272 HoughCircles(houghC, circles,
273              CV_HOUGH_GRADIENT, 1, 20, 25, 10, 5, 20);
274 std::cout << "Circles: " << circles.size() << std::endl;
275 cvtColor(houghC, houghC, CV_GRAY2BGR);
276
277 int fs1 = 0;
278 int fs2 = 0;
279 int fs3 = 0;

```

```

280     for(size_t i = 0; i < circles.size(); i++)
281     {
282         Point center(cvRound(circles[i][0]), cvRound(circles[i][1]));
283         int radius = cvRound(circles[i][2]);
284         circle(houghC, center, radius, Scalar(0, 0, 255), 2, 8, 0);
285         circle(input, center, radius, Scalar(0, 0, 255), 2, 8, 0);
286         if (radius < 11) fs1++;
287         else if (radius < 17) fs2++;
288         else fs3++;
289     }
290     saveImg(houghC, newImgDir.string() +
291            "/15-HoughCirclesRecognition.jpg");
292     saveImg(input, newImgDir.string() +
293            "/16-HoughCirclesInput.jpg");
294
295     // MARK: Results file update
296     string flagNumber = "";
297     string flagRatio = "";
298     if ((fs1 > 40) && (fs2 > 25)) flagNumber = "*";
299     else flagNumber = "";
300     if (circles.size() > 25)
301     {
302         double sizeRatio = double(fs1) / double(circles.size());
303         if (sizeRatio > 0.7) flagRatio = "*";
304         else flagRatio = "";
305     }
306     results.open(outDirName.string() + "/results.txt", ios::app);
307
308     uint64 imgTimeEnd = GetTimeMs64();
309
310     string nResultLine = itr->path().stem().string() + "\t" +
311        to_string(fs1) + "\t" +
312        to_string(fs2) + "\t" +
313        to_string(fs3) + "\t" +
314        to_string(circles.size()) + "\t" +
315        flagNumber + "\t" +
316        flagRatio + "\t" +
317        to_string(imgTimeEnd - imgTime) + "\n";
318
319     results << nResultLine;
320     results.close();
321 }
322 }
323 }

```

Figura 2D. Implementação do algoritmo de reconhecimento e contagem de frutos verdes em imagens de laranjeiras. O algoritmo é aplicado a todos os arquivos .jpg do diretório informado como parâmetro no método e escreve os resultados em um arquivo de texto chamado *results.txt* nessa mesma pasta

