UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
Departamento de Engenharia elétrica

Patricia Pedroso Estevam Ribeiro

**Aplicação de técnicas de processamento de imagens
para diferenciação do *greening* de outras pragas**

São Carlos
2014

Patricia Pedroso Estevam Ribeiro

Aplicação de técnicas de processamento de imagens para diferenciação do *greening* de outras pragas

Dissertação apresentada à Escola de Engenharia de São Carlos, da Universidade de São Paulo, como parte dos requisitos para obtenção do Título de Mestre em Ciências, programa de Engenharia Elétrica.

Área de concentração:
Processamento de Sinais e Instrumentação.

Orientadora: Prof^ª. Dr^ª. Maria Stela Veludo de Paiva.

São Carlos
2014

Trata-se da versão corrigida da dissertação. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Elétrica.

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

R384a Ribeiro, Patricia Pedroso Estevam
 Aplicação de técnicas de processamento de imagens
 para diferenciação do greening de outras pragas /
 Patricia Pedroso Estevam Ribeiro; orientador Prof^a.
 Maria Stela Veludo de Paiva. São Carlos, 2014.

 Dissertação (Mestrado) - Programa de Pós-Graduação
 em Engenharia Elétrica e Área de Concentração em
 Processamento de Sinais e Instrumentação -- Escola de
 Engenharia de São Carlos da Universidade de São Paulo,
 2014.

 1. Greening. 2. Análise de textura. 3. LBP. 4. LFP.
 5. Segmentação por cor. I. Título.

FOLHA DE JULGAMENTO

Candidata: Engenheira **PATRICIA PEDROSO ESTEVAM RIBEIRO**.

Título da dissertação: "aplicação de técnicas de processamento de imagens para diferenciação do Greening de outras pragas".

Data da defesa: 07/05/2014

Comissão Julgadora:

Resultado:

Profa. Dra. **Maria Stela Veludo de Paiva (Orientadora)**
(Escola de Engenharia de São Carlos/EESC)

APROVADA

Dr. **Ednaldo José Ferreira**
(EMBRAPA)

Aprovada

Prof. Dr. **Celso Aparecido de França**
(Universidade Federal de São Carlos/UFSCar)

APROVADA

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica e
Presidente da Comissão de Pós-Graduação:
Prof. Titular **Denis Vinicius Coury**

*Dedico primeiramente a Deus, Jesus e á Nossa Senhora,
Ao meu filho Vinicius e ao meu marido Henrique e aos meus pais Susete e Antonio e as
minhas irmãs Priscila e Jessica e à minha avó Cacilda e tia Evani.*

Agradecimentos

Agradeço à minha orientadora Maria Stela Veludo de Paiva, pela confiança, orientação e amizade.

Ao Dr. Lúcio André de Castro Jorge, pela oportunidade de pesquisa na Embrapa Agropecuária, co-orientação, amizade.

À minha colega Raissa T. Vieira e Prof. Dr. Adilson Gonzaga, pelo apoio no desenvolvimento da classificação das doenças de citros.

À minha família e amigos que me auxiliaram no decorrer do trabalho.

À Embrapa Instrumentação Agropecuária e Universidade de São Paulo, pelo apoio operacional e ao CNPQ e CAPES pelo apoio financeiro.

Epígrafe

“Só fazemos melhor aquilo que repetidamente insistimos em melhorar. A busca da excelência não deve ser um objetivo, e sim um hábito”.

Aristóteles

RESUMO

RIBEIRO, P. P. E. **Aplicação de técnicas de processamento de imagens para diferenciação do greening de outras pragas.** 2014. 189f. Dissertação (Mestrado) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2014.

O *greening* ou *Huanglongbing* (HLB) é uma das mais graves doenças dos citros presentes nos pomares do Brasil. Causada pela bactéria *Candidatus Liberibacter spp.* é transmitida pelo inseto psíldeo *Diaphorina citri*, que ao se alimentar de uma planta doente transmite a doença às demais plantas. O *greening* apresenta como sintoma, manchas amareladas nas folhas, muitas vezes confundidas com deficiências nutricionais. A erradicação da planta e o controle do inseto transmissor são as únicas formas de prevenção para evitar a sua propagação. Este trabalho teve por objetivo avaliar uma metodologia baseada em segmentação por cor e outra baseada em análise de textura para avaliação de folhas de citros sintomáticas, identificando se estão contaminadas com o *greening* ou outras doenças e deficiências nutricionais. Foram fornecidas pelo grupo FISHER, 324 amostras de folhas cítricas, contendo folhas com doenças (*greening*, CVC e rubelose) e deficiências nutricionais (manganês, magnésio e zinco). As folhas foram digitalizadas por um *scanner* de mesa, com duas resoluções, utilizando somente a parte frontal da folha. Foram montados três bancos de imagens. Os resultados gerados com a metodologia baseada em segmentação por cor utilizando RNA PMC, mostraram que essa metodologia não é eficiente. Na metodologia baseada na análise por textura foram avaliados os descritores LBP, LFP e os de Haralick. Para estes descritores foram extraídas amostras por folha e por quadrantes das folhas nos canais de cores vermelho e verde e amostras em níveis de cinza. Os resultados gerados pelos descritores foram classificados pela distância χ^2 e pelos algoritmos IBK e RNA PMC do *toolbox* Weka. Os melhores resultados foram para os descritores LBP e LFP-s para distância χ^2 , com valores de sensibilidade acima de 97% e 93%, respectivamente, e para o LBP com o algoritmo IBK, com valores de sensibilidade acima de 98,5%. Os resultados obtidos evidenciam que o descritor LBP é o mais eficiente seguido pelo LFP-s na diferenciação do *greening* das outras pragas.

Palavras - Chaves: *Greening*, Análise de textura, LBP, LFP, Segmentação por cor.

ABSTRACT

RIBEIRO, P. P. E. **Application of image processing techniques to differentiate greening from other pests.** 2014. 189p. Dissertation – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2014.

The greening or Huanglongbing (HLB) is one of the most serious diseases of citrus orchards present in Brazil. HLB is caused by the bacterium *Candidatus Liberibacter* spp, it is transmitted by the psyllid insect (*Diaphorina citri*) that, when feeding on a diseased plant, it transmits the disease to other plants. One of the symptoms of the greening are yellowish spots on the leaves, often confused with nutritional deficiencies. The eradication of plants and control of insect are the only forms of prevention. This work aims to evaluate two methodologies: one based on color segmentation and the other based on texture analysis for assessment of symptomatic citrus leaves, identifying whether they are infected with greening and other diseases and nutritional deficiencies. A number of 324 samples of citrus leaves were provided by FISHER group, infected with diseases (greening, CVC, rubelose) and nutritional deficiencies (manganese, magnesium, zinc) . The leaves were acquired by a flatbed scanner with two different resolutions, using only the front side of the leaf. Three datasets of images were constructed. The results generated using the methodology based on color segmentation with ANN MLP, showed that this methodology is not efficient. In the methodology based on texture analysis it was evaluated the LBP, LFP and the Haralick descriptors. For these descriptors it was extracted samples from the leaves and quadrants of leaves, in red and green color channels and grayscale. The results generated by the descriptors were classified by χ^2 distance and the algorithms IBK and ANN MLP from the toolbox Weka. The best results were for LBP descriptor and LFP-s for χ^2 distance with values of sensitivity above 97% and 93%, respectively, and the LBP with IBK algorithm, with values of sensitivity above 98.5 %. The results showed that the LBP descriptor is the most efficient followed by LFP-s in the differentiation of the greening from other pests.

Key-Words: Greening, Texture analysis, LBP, LFP, Color Segmentation.

LISTA DE FIGURAS

FIGURA 1. 1 - INSPEÇÕES VISUAIS REALIZADAS EM POMARES DE CITROS, EM A) CAMINHANDO, B) EM PLATAFORMA MOVIDA POR TRATORES. FONTE: FUNDECITRUS (2009B).	38
FIGURA 2. 1 - INSETO PSILÍDEO <i>DIAPHORINA CITRI</i> . FONTE: FLOYD E KRASS (2008).	42
FIGURA 2. 2 - IMAGENS DE FOLHAS CONTAMINADAS COM O GREENING EM (A) RAMOS AMARELADOS CONTRASTANDO COM OS OUTROS RAMOS VERDES, E (B) FOLHAS MOSQUEADAS. FONTE: FUNDECITRUS (2009B).	43
FIGURA 2. 3 - AMOSTRAS FOLIARES ILUSTRANDO O <i>GREENING</i> E OUTRAS DOENÇAS E DEFICIÊNCIAS NUTRICIONAIS.	43
FIGURA 2. 4 - (A) IMAGENS DE FRUTOS DEFORMADOS E COM COLORAÇÃO ALTERADA; (B) FRUTO COM SEMENTES ABORTADAS. FONTE: FUNDECITRUS (2009B).	44
FIGURA 3. 1 - EXEMPLO DE UMA MATRIZ DE CONFUSÃO USANDO $L=8$ E DIREÇÃO 0° COM 1 PIXEL DE DISTÂNCIA.	65
FIGURA 3. 2 - (A) UMA SIMPLES ESTRUTURA COMO UMA ESCADA. (B) ESTRUTURA CODIFICADA. FONTE: GONZALEZ E WOODS (2010).	69
FIGURA 3. 3 - (A) UMA IMAGEM DE UMA TEXTURA PERIÓDICA; (B) ESPECTRO DE FOURIER CORRESPONDENTE; (C) O GRÁFICO DE $S(R)$; (D) O GRÁFICO DE $S(\theta)$. FONTE: BOAVENTURA (2010).	72
FIGURA 3. 4 - ILUSTRAÇÃO DO CÁLCULO DO <i>TEXTURE UNIT</i> . FONTE: VIEIRA (2013).	73
FIGURA 3. 5 - ILUSTRAÇÃO DO CÁLCULO DO <i>LOCAL BINARY PATTERN</i> . FONTE: VIEIRA (2013).	75
FIGURA 3. 6 - VIZINHANÇA CIRCULAR DE UM PIXEL EM MULTIRRESOLUÇÃO LBP.	75
FIGURA 3. 7 - GRÁFICO DA FUNÇÃO DE PERTINÊNCIA DE UM NÚMERO <i>FUZZY</i> TRIANGULAR. FONTE: VIEIRA (2013).	81
FIGURA 3. 8 - GRÁFICO DA FUNÇÃO DE PERTINÊNCIA DE UM NÚMERO <i>FUZZY</i> TRAPEZOIDAL. FONTE: VIEIRA (2013).	81
FIGURA 3. 9 - GRÁFICO DA FUNÇÃO DE PERTINÊNCIA DE UM NÚMERO <i>FUZZY</i> GAUSSIANO. FONTE: VIEIRA (2013).	82
FIGURA 3. 10 - GRÁFICO DA FUNÇÃO DE PERTINÊNCIA DE UM NÚMERO <i>FUZZY</i> SIGMOIDAL. FONTE: VIEIRA (2013).	82
FIGURA 3. 11 - CÁLCULO DE PERTINÊNCIA DO PIXEL CENTRAL. (A) MICROPADRÃO ($W \times W$), (B) FUNÇÃO DE PERTINÊNCIA, (C) MATRIZ DAS PERTINÊNCIAS EM RELAÇÃO AO PIXEL CENTRAL, (D) MATRIZ DE PESOS. FONTE: VIEIRA (2013).	85
FIGURA 3. 12 - ILUSTRAÇÃO DO CÁLCULO DO CÓDIGO LFP PARA UMA FUNÇÃO DE PERTINÊNCIA SIGMOIDAL. FONTE: VIEIRA (2013).	86

FIGURA 3. 13 - NEURÔNIO ARTIFICIAL.....	90
FIGURA 3. 14 - NEURAL ARTIFICIAL <i>PERCEPTRON</i> MULTICAMADA. FONTE: SILVA; SPATTI E FLAUZINO,(2010).....	91
FIGURA 3. 15 - NEURAL ARTIFICIAL <i>PERCEPTRON</i> MULTICAMADA COM O ALGORITMO <i>BACKPROPAGATION</i> . FONTE: SILVA; SPATTI E FLAUZINO (2010).	92
FIGURA 3. 16 - ESQUEMA DE CUBO DE CORES RGB. FONTE: MARQUES FILHO (1999).	94
FIGURA 4. 1 - DIAGRAMA DE DESENVOLVIMENTO DO TRABALHO PARA A PRIMEIRA METODOLOGIA.....	98
FIGURA 4. 2 - DIAGRAMA DE DESENVOLVIMENTO DO TRABALHO PARA A SEGUNDA METODOLOGIA.....	99
FIGURA 4. 3 - SEGMENTAÇÃO DO OBJETO DE INTERESSE.....	101
FIGURA 4. 4 - EXEMPLIFICAÇÃO DA SELEÇÃO DAS COMPONENTES RGB. EM (A) A SELEÇÃO DA COR VERDE ESCURO, EM (B) A SELEÇÃO DA COR VERDE CLARO, EM (C) A SELEÇÃO DA COR AMARELO, EM (D) A SELEÇÃO DA COR MARROM E EM (E) A SELEÇÃO DA COR DE FUNDO.	101
FIGURA 4. 5 - AMOSTRAS DAS IMAGENS SEGMENTADAS.	105
FIGURA 4. 6 - IMAGEM SEGMENTADA EM QUADRANTES.....	105
FIGURA 4. 7 - (A) IMAGEM DA FOLHA 05 COM CVC, (B) IMAGEM DA FOLHA SEGMENTADA EM QUADRANTES.	107
FIGURA 4. 8 – EXEMPLO DE AMOSTRAS EXTRAÍDAS POR UMA IMAGEM DE FOLHA DE CITROS, EM (A) EXTRAÇÃO DA AMOSTRA POR FOLHA E (B) EXTRAÇÃO DA AMOSTRA POR QUADRANTE.....	108
FIGURA 4. 9 – EXEMPLO DE AMOSTRAS EXTRAÍDAS POR UMA IMAGEM DE FOLHA DE CITROS, NOS CANAIS DE CORES VERMELHO, VERDE E NÍVEL DE CINZA.	108
FIGURA 4. 10 - ILUSTRAÇÃO DO PROCESSO DE CLASSIFICAÇÃO. FONTE: VIEIRA (2013).	110
FIGURA 4. 11 - HISTOGRAMA DO LBP PARA UMA AMOSTRA.	112

LISTA DE TABELAS

TABELA 4. 1 – TABELA COM UMA CAMADA ESCONDIDA.....	102
TABELA 4. 2 – TABELA COM DUAS CAMADAS ESCONDIDAS.....	102
TABELA 4. 3 – TABELA COM TRÊS CAMADAS ESCONDIDAS.....	102
TABELA 4. 4 - TABELA COM OS RESULTADOS DA CLASSIFICAÇÃO POR RNA (POR QUADRANTE) PARA O CVC.....	107
TABELA 4. 5 – TABELA COM A MATRIZ DE CONFUSÃO DO DESCRITOR LBP DO PRIMEIRO QUADRANTE.....	110
TABELA 4. 6 – TABELA COM A SENSIBILIDADE MÉDIA CALCULADA PARA CADA CLASSE DE DOENÇA PARA O PRIMEIRO QUADRANTE.	111
TABELA 5. 1 – TABELA DA SENSIBILIDADE OBTIDA COM VARIAÇÃO DO TAMANHO DA AMOSTRA WXW PIXELS.....	117
TABELA 5. 2 – TABELA DA SENSIBILIDADE COM VARIAÇÃO DO NÚMERO DAS FOLHAS DE CITROS, PARA 10 AMOSTRAS EXTRAÍDAS POR FOLHA.....	118
TABELA 5. 3 - TABELA DA SENSIBILIDADE COM VARIAÇÃO NO NÚMERO DAS FOLHAS DE CITROS, PARA 5 AMOSTRAS EXTRAÍDAS POR FOLHA.....	118
TABELA 5. 4 – TABELA DA SENSIBILIDADE OBTIDA PELO PRIMEIRO EXPERIMENTO.	119
TABELA 5. 5 – TABELA DA SENSIBILIDADE OBTIDA PELO SEGUNDO EXPERIMENTO.	119
TABELA 5. 6 – TABELA DE SENSIBILIDADE DO LBP, POR QUADRANTE, VARIANDO O NÚMERO DE AMOSTRAS.	120
TABELA 5. 7 - TABELA DE SENSIBILIDADE DO LBP, POR QUADRANTE, VARIANDO O TAMANHO DA AMOSTRA.....	121
TABELA 5. 8 - TABELA DE SENSIBILIDADE DAS DOENÇAS PARA O LBP VARIANDO O TAMANHO DAS AMOSTRAS.	121
TABELA 5. 9 - TABELA DE SENSIBILIDADE DO LFP COM AS FUNÇÕES DE PERTINÊNCIA. ..	122
TABELA 5. 10 – TABELA DE SENSIBILIDADE DO LFP-S, POR QUADRANTE, VARIANDO O NÚMERO DE AMOSTRAS.	123
TABELA 5. 11 - TABELA DE SENSIBILIDADE DO LFP-S, POR QUADRANTE, VARIANDO O TAMANHO DA AMOSTRA.....	124
TABELA 5. 12 – TABELA DE SENSIBILIDADE DAS DOENÇAS PARA O LFP-S VARIANDO O TAMANHO DAS AMOSTRAS.	124
TABELA 5. 13 – TABELA DE SENSIBILIDADE COM A VARIAÇÃO DO TAMANHO DAS AMOSTRAS.....	126
TABELA 5. 14 – TABELA DE SENSIBILIDADE PARA O PRIMEIRO EXPERIMENTO COM OS DESCRITORES DE HARALICK.....	126
TABELA 5. 15 – TABELA DE SENSIBILIDADE PARA O SEGUNDO EXPERIMENTO COM OS DESCRITORES DE HARALICK.....	127

TABELA 5. 16 - TABELA DE SENSIBILIDADE, VARIANDO O NÚMERO DE AMOSTRAS.	127
TABELA 5. 17 – TABELA COM OS VALORES MÉDIOS DE SENSIBILIDADE DOS QUADRANTES PARA CADA DOENÇA.	128
TABELA 5. 18 – TABELA DE COMPARAÇÃO DOS DESCRITORES.	128
TABELA 5. 19 – TABELA DE SENSIBILIDADE DAS DOENÇAS PELO CÁLCULO DA DISTÂNCIA χ^2	129
TABELA 5. 20 – TABELA DA SENSIBILIDADE OBTIDA COM A VARIAÇÃO DO NÚMERO DE BINS PARA OS QUADRANTES.	129
TABELA 5. 21 – TABELA DE SENSIBILIDADE DAS CLASSES DE DOENÇAS, COM A VARIAÇÃO NO NÚMERO DE CLASSES DE DOENÇAS PARA O DESCRITOR DE HARALICK.	130
TABELA 5. 22 - TABELA DE SENSIBILIDADE PARA AS CLASSES <i>GREENING</i> , MANGANÊS E ZINCO.	131
TABELA 5. 23 – TABELA DE SENSIBILIDADE DOS VALORES EXTRAÍDOS DOS HISTOGRAMAS PARA O LBP, POR QUADRANTES.	131
TABELA 5. 24 – TABELA DE SENSIBILIDADE DOS VALORES EXTRAÍDOS DOS HISTOGRAMAS PARA O LBP COM IBK.	132
TABELA 5. 25 – TABELA COM OS VALORES DE SENSIBILIDADE MÉDIOS DOS QUADRANTES, PARA O DESCRITOR LBP COM IBK.	132
TABELA 5. 26 - TABELA DE SENSIBILIDADE DOS VALORES EXTRAÍDOS DOS HISTOGRAMAS PARA O LBP, POR QUADRANTES, PARA RNA PMC.	132
TABELA 5. 27 - TABELA DE SENSIBILIDADE PARA OS VALORES EXTRAÍDOS DOS HISTOGRAMAS PARA O LBP COM RNA PMC.	133
TABELA 5. 28- TABELA COM OS VALORES MÉDIOS, DE SENSIBILIDADE, DOS QUADRANTES, PARA O DESCRITOR LBP COM IBK.	133
TABELA 5. 29 - TABELA DE SENSIBILIDADE PARA OS VALORES EXTRAÍDOS DOS HISTOGRAMAS PARA O LFP-S, POR QUADRANTES.	134
TABELA 5. 30 - TABELA DE SENSIBILIDADE DOS VALORES EXTRAÍDOS DOS HISTOGRAMAS PARA O LFP-S COM O IBK.	134
TABELA 5. 31 - TABELA COM OS VALORES MÉDIOS DE SENSIBILIDADE DOS QUADRANTES, PARA O DESCRITOR LFP-S COM O IBK.	134
TABELA 5. 32 - TABELA DE SENSIBILIDADE PARA OS VALORES EXTRAÍDOS DOS HISTOGRAMAS PARA O LFP-S, POR QUADRANTES.	135
TABELA 5. 33 - TABELA DE SENSIBILIDADE DOS VALORES EXTRAÍDOS DOS HISTOGRAMAS PARA O LFP-S COM RNA PMC.	135
TABELA 5. 34 - TABELA COM OS VALORES MÉDIOS DE SENSIBILIDADE DOS QUADRANTES, PARA O DESCRITOR LFP-S COM RNA PMC.	135
TABELA 5. 35 – TABELA DE SENSIBILIDADE DE 1 FOLHA DE <i>GREENING</i>	137
TABELA 5. 36 - TABELA DE SENSIBILIDADE DE 10 FOLHA DE <i>GREENING</i>	138

LISTA DE GRÁFICOS

GRÁFICO 5. 1 – GRÁFICO ILUSTRANDO A TABELA 5.8.	122
GRÁFICO 5. 2 – GRÁFICO DE COMPARAÇÃO DAS FUNÇÕES DE PERTINÊNCIA (SIGMÓIDE, TRIANGULAR E GAUSSIANA).	123
GRÁFICO 5. 3 – GRÁFICO ILUSTRANDO A TABELA 5.12.	125
GRÁFICO 5. 4 – GRÁFICO ILUSTRANDO A TABELA 5.16.	127
GRÁFICO 5. 5 – GRÁFICO COM RESUMO DA CLASSIFICAÇÃO DAS DOENÇAS.	136
GRÁFICO 5.6 - GRÁFICO DE COMPARAÇÃO GERAL DOS DESCRITORES.	137

LISTA DE SIGLAS

API	<i>Application Programming Interface</i> (Interface de Programação de Aplicativos)
CVC	Clorose Variegada dos Citros
CMY	<i>Cyan, Magenta, Yellow</i> (Ciano, Magenta e Amarelo)
CMYK	<i>Cyan, Magenta, Yellow, Black</i> (Ciano, Magenta, Amarelo e Preto)
DNA	<i>Deoxyribonucleic Acid</i> (Ácido Desoxirribonucléico)
EAM	Erro Absoluto Médio
EQM	Erro Quadrático Médio
FAO	<i>Food and Agriculture Organization of United Nation</i> (Organização de Alimentação e Agricultura dos Estados Unidos)
FLBP	<i>Fuzzy Local Binary Pattern</i>
FTIR	<i>Fourier transform infrared spectroscopy</i> (Espectroscopia de absorção no infravermelho médio)
FUNDECITRUS	Fundo de Defesa da Citricultura
FUNED	<i>Fuzzy Number Edge Detector</i>
GLCM	<i>Gray-Level Co-occurrence Matrices</i>
GLRLM	<i>Gray-Level Run-Length Matrices</i>
HLB	<i>Huanglongbing</i> (Greening)
HSI	<i>Hue, Saturation, Intensity</i> (Matiz, Saturação e Intensidade)
IFAS	<i>Institute Of Food And Agricultural Sciences</i> (Instituto de Alimentos e de Ciência Agrária)
ILBP	<i>Improved Local Binary Patterns</i>

LBP	<i>Local Binary Pattern</i>
LFP	<i>Local Fuzzy Pattern</i>
LFP-s	<i>Local Fuzzy Pattern (sigmoid)</i>
LFP-t	<i>Local Fuzzy Pattern (triangular)</i>
LFP-g	<i>Local Fuzzy Pattern (gaussian)</i>
LTPS	<i>Local Ternary Patterns</i>
LSU	<i>Linear Spectral Unmixing</i>
MLP	<i>Multilayer Perceptron (Perceptron Multicamadas)</i>
MTMF	<i>Mixture Tuned Match Filtering</i>
PCA Principais)	<i>Principal Component Analysis</i> (Análise de Componentes
PCR	<i>Polymerase Chain Reaction</i> (Reação em Cadeia da Polimerase)
PIB	Produto Interno Bruto
PIXEL	<i>Picture element</i>
PMC	<i>Perceptron Multicamadas</i>
QDA	Análise Discriminante Quadrática
TU	<i>Texture Unit</i>
RBF	<i>Radial basis function Networks</i> (Redes de base radial)
RBG	<i>Red, Green, Blue</i> (vermelho, verde, azul)
RNAs	Redes Neurais Artificiais
SAM	<i>Spectral Angle Mapper</i>
SDA	<i>Stepwise Discriminant Analysis</i>
SIMCA	<i>Soft Independent Modeling Of Classification Analogies</i>

FFFS	<i>Sequential Floating Forward Selection</i>
SLBP	<i>Soft Local Binary Pattern</i>
VLBP	<i>Volume Local Binary Patten</i>

LISTA DE SÍMBOLOS

$\%$	Porcentagem
$p(i,j)$	(i,j) -ésima entrada de uma matriz em tons de cinza, normalizada
$p_x(i)$	i -ésima entrada na matriz de probabilidade marginal obtida pela soma das linhas de $p(i,j)$
N_g	Número de níveis de cinza distintos na imagem quantizada
μ_x, μ_y, σ_x e σ_y	São as médias e o desvio padrão de p_x e p_y
H_x e H_y	São as entropias de p_x e p_y
R_0	Raio de círculo centrado na origem
$S(r, \theta)$	É uma função de espectro
r, θ	São variáveis nesse sistema de coordenadas
V_i	Pixel da vizinhança
E_i	Valor binário
V_0	Pixel central
N_{TU}	Código TU
N_{LBP}	Código LBP
P	Quantidade de pixels da vizinhança
R	Escala do perímetro circular
$\mu_A(x)$	Grau de pertinência do elemento x em reação ao conjunto A
$\mu_B(x)$	Grau de pertinência do elemento x em reação ao conjunto B
X	Universo de discurso
A	Conjunto <i>Fuzzy</i> A

$altura(A)$	Altura de um conjunto <i>fuzzy</i> A
max	Operador máximo
$suporte(A)$	Suporte de um conjunto <i>fuzzy</i> A
α	Corte em um conjunto <i>fuzzy</i> A
A_α	Conjunto de α -cortes do conjunto <i>fuzzy</i> A
$cardinalidade(A)$	Cardinalidade de um conjunto <i>fuzzy</i> A
$\cup$	União
min	Operador mínimo
$\cap$	Interseção
$a_1^{(\alpha)}$	α -corte 1 do conjunto A_α
$a_2^{(\alpha)}$	α -corte 2 do conjunto A_α
$b_1^{(\alpha)}$	α -corte 1 do conjunto B_α
$b_2^{(\alpha)}$	α -corte 2 do conjunto B_α
δ	Espalhamento de número <i>fuzzy</i>
σ	Desvio padrão
β	Inclinação da curva sigmóide
d_i	Diferença de nível de cinza
X_c	Pixel central
X_i	Pixel da vizinhança
N	Conjunto <i>fuzzy</i> que representa diferenças negativas
P	Conjunto <i>fuzzy</i> que representa diferenças positivas
e	Parâmetro que determina a imprecisão do modelo

n_i	Grau de pertinência no conjunto <i>fuzzy</i> N
M	Quantidade de pixels vizinhos
FP_K	k -ésimo padrão <i>fuzzy</i>
F_K	Grau de pertinência do k -ésimo padrão <i>fuzzy</i>
p_i	Pixel da vizinhança
p_c	Pixel central
$m_0()$	Função de pertinência
T	Parâmetro que controla o grau de incerteza
W	Tamanho da vizinhança
$g(i,j)$	Pixel central
$\hat{\mu}_g(i,j)$	Grau de pertinência do pixel central
$f_g(i,j)$	Função de pertinência
$P(k,l)$	Matriz de pesos
$A(k,l)$	Pixels da vizinhança
χ^2	Chi-quadrado
Q_i avaliada	Frequência do nível de cinza da amostra que está sendo avaliada
P_i	Frequência do nível de cinza da amostra do conjunto que está sendo comparada com a amostra avaliada
S	Sensibilidade
VP	Verdadeiros positivos
FN	Falsos negativos
X_n	Entradas RNA

W_n	Pesos Sinápticos de uma RNA
Σ	Combinador Linear de uma RNA
θ	Limiar de Ativação de uma RNA
u	Potencial de Ativação de uma RNA
$g(u)$	Função de Ativação de uma RNA
Y_n	Saídas da RNA
η	Taxa de aprendizagem de uma RNA.
δ	Gradiente local de uma RNA
α	Momentum de uma RNA
n	Neurônio de uma RNA
L	Camada de uma RNA
$W_{ji}^{(L)}$	Ajuste da matrizes de pesos sinápticos
$I_j^{(L)}$	Valor produzido pelo j -ésimo neurônio de saída
E_M	Erro quadrático médio
p	Amostras do erro quadrático médio
$E(K)$	Erro quadrático
$Y_j^{(3)}(K)$	Valor produzido pelo j -ésimo neurônio de saída da rede considerando-se a k -ésima amostra de treinamento
$d_j(K)$	É o seu respectivo valor desejado.
x_{CM}, y_{CM}	Centro de massa das coordenadas (x,y)
N_t	Número total de pixels dentro de uma região R
$\alpha_{min}, \alpha_{max}, \beta_{min}, \beta_{max}$	Pontos delimitadores do momento central.

$\mu_{p,q}$

Momento central

θ_{mc}

Teta do momento central

SUMÁRIO

RESUMO.....	15
ABSTRACT	17
LISTA DE FIGURAS	19
LISTA DE TABELAS	21
LISTA DE SIGLAS	25
LISTA DE SÍMBOLOS	29
SUMÁRIO.....	35
1. INTRODUÇÃO.....	35
1.1. Considerações iniciais.....	35
1.2. Objetivos	38
1.3. Estrutura do trabalho	39
2. REVISÃO BIBLIOGRÁFICA	41
2.1. Considerações iniciais.....	41
2.2. Proliferação do <i>Greening</i>	41
2.3. Detecção do <i>greening</i>	45
2.4. Trabalhos relacionados à análise de textura	49
2.5. Trabalhos relacionados com redes neurais artificiais.....	56
2.6. Considerações finais	60
3. TEORIA RELACIONADA	63

3.1.	Considerações iniciais	63
3.2.	Introdução sobre a textura.....	63
3.2.1	Abordagem estatística	64
3.2.2	Abordagem estrutural	69
3.2.3	Abordagem espectral.....	70
3.2.4	Abordagem por micropadrões.....	72
3.3.	Conjuntos <i>Fuzzy</i> e números <i>Fuzzy</i>	76
3.3.1.	Conjuntos <i>Fuzzy</i>	77
3.3.2.	Operadores <i>Fuzzy</i>	79
3.3.3.	Números <i>Fuzzy</i>	79
3.3.4.	Operações com números <i>fuzzy</i>	83
3.4.	<i>Local Fuzzy Pattern</i>	84
3.5.	Redes neurais artificiais	89
3.6.	Modelo de Cor RGB	93
3.7.	Considerações finais.....	95
4.	METODOLOGIA	97
4.1.	Considerações Iniciais	97
4.2.	Visão Geral do Trabalho	97
4.3.	Aquisição das Imagens Foliares	99
4.4.	Metodologia utilizando RNA PMC	100
4.4.1.	Pré-Processamento das Imagens.....	100
4.4.2.	Rede Neural Artificial	101
4.4.3.	Segmentação por Cor	103
4.4.4.	Divisão da Folha em Quadrantes	105
4.5.	Metodologia utilizando descritores de textura.....	107
4.5.1.	Extração das amostras	107
4.5.2.	Aplicação dos descritores de textura local LBP e LFP, e dos descritores de Haralick.....	109
4.5.3.	Cálculo da sensibilidade e classificação das classes de doenças pelo descritores LBP e LFP.....	109

4.5.4.	Extração dos histogramas dos descritores LBP e LFP	111
4.5.5.	Classificação das classes de doenças utilizando os algoritmos IBK e RNA PMC.	112
4.6.	Ferramentas utilizadas	112
4.7.	Considerações finais	113
5.	RESULTADOS E DISCUSSÕES.....	115
5.1.	Considerações Iniciais.....	115
5.2.	Resultado da metodologia utilizando RNA PMC	115
5.3.	Resultados da metodologia utilizando análise de textura.....	116
5.4.	Análise dos Resultados Obtidos com o Descritor LBP	120
5.5.	Análise dos Resultados Obtidos pelo Descritor LFP.....	122
5.6.	Análise dos Resultados Obtidos pelo Descritores de Haralick	125
5.7.	Análise Geral dos Descritores	128
5.8.	Classificação das Amostras Pelos Histogramas Dos Descritores LBP e LFP-s.....	131
5.8.1.	Classificação de 1 folha	137
5.8.2.	Classificação de 10 folhas	138
5.9.	Considerações Finais	138
6.	CONCLUSÕES	141
6.1.	Conclusões Finais.....	141
6.2.	Sugestões de Trabalhos Futuros	142
6.3.	Trabalhos Publicados.....	143
6.3.1.	Capítulos de livros.....	143
6.3.2.	Trabalhos publicados em anais de congresso.....	143
6.3.3.	Trabalho submetido.....	144
6.3.4.	Resumo de trabalhos publicados em anais de congresso	144
7.	REFERÊNCIAS	145

APÊNDICE A- RESULTADOS DA TABELAS DA DIVISÃO POR QUADRANTES	153
APÊNDICE B- IMAGENS DA FOLHAS DE CITROS	175
APÊNDICE C- ROTINA PARA EXTRAÇÃO DOS DESCRITORES DE HARALICK	179
APÊNDICE D- ROTINA PARA GERAR IMAGENS NOS CANAIS DE CORES	183
APÊNDICE E- GRÁFICO DE DISPERSÃO	184

Capítulo 1

Introdução

1.1. Considerações iniciais

As plantas do gênero *Citrus* da família *Rutaceae* fazem parte de um grande grupo de citros representados por laranjas (*Citrus sinensis*), tangerinas (*Citrus reticulata* e *Citrus deliciosa*), limões (*Citrus limon*), limão Tahiti (*Citrus latifolia*) e o limão Galego (*Citrus aurantiifolia*), laranjas doces como a lima da Pérsia (*Citrus limettioides*), pomelo (*Citrus paradisi*) e cidra (*Citrus medica*), laranja-azeda (*Citrus aurantium*) e toranjas (*Citrus grandis*) (INSTITUTO AGRONÔMICO DE CAMPINAS, 2010). De todas estas variedades, a que se destaca em todo mundo é a laranja. Originária do leste Asiático, por volta do ano de 2200 a.C., suas mudas foram levadas da Ásia para o norte da África e de lá para o sul da Europa, onde foram trazidas para as Américas por volta de 1500 (HASSE, 1987). Atualmente, os pomares de laranjas mais produtivos e estruturados são das regiões de clima tropical e subtropical, como o Brasil, Estados Unidos, México, China e África do sul (TODA FRUTA, 2010).

No Brasil, a produção de laranjas tanto para suco como para o consumo *in natura* vem crescendo em todo o país, sendo um dos maiores exportadores de suco de laranja, respondendo por 23,5% do Produto Interno Bruto (PIB), 36% das exportações totais, movimentando R\$ 9 bilhões por ano e gerando 37% dos empregos brasileiros, ou seja, 400 mil empregos diretos (ANDRIGUETO et al, 2008).

Segundo os dados da FAO (*Food and Agriculture Organization of United Nation*), em 2007 o Brasil possuía 30% da produção mundial, destacando o estado de São Paulo como sendo o responsável por 80% da produção de laranjas em 565 mil hectares de área cultivada (AGRIANUAL, 2008). Para os anos 2009 a 2010, a produção estimada foi de 318,6 milhões de caixas de 40,8 kg, sendo que deste montante 83,4% foi destinada à indústria e 16,6% para o consumo (INSTITUTO DE ECONOMIA AGRÍCOLA, 2010).

Apesar de sua eficiência e capacidade de produção, a citricultura paulista apresenta uma distribuição não uniforme da produtividade da laranja, havendo variações de regiões com alta produtividade e regiões com baixa produtividade, concentrando em regiões sem variação

de relevos ou barreiras físicas e próximas às malhas rodoviárias, possibilitando o trânsito de sementes, borbulhas e frutos cítricos.

Com o abandono dos pomares devido a quedas nas exportações para a Europa no período da II Guerra mundial, observou-se o aumento das incidências e propagações de doenças conhecidas e não conhecidas, como por exemplo, o vírus “tristeza”, que causou o definhamento progressivo das árvores, chegando a destruir cerca de 80% das árvores cítricas existentes no Brasil na época (TODA FRUTA, 2010).

Atualmente, a grande quantidade de plantas cítricas expostas durante todo ano a vários ataques de pragas e doenças, somados à variabilidade genética muito baixa, conduzem à ocorrência de epidemias de doenças conhecidas e novas doenças, abalando a sustentabilidade do agronegócio.

No início do século 21, até o ano de 2005, observou-se o crescimento de custos na produção da laranja, redução de área plantada, queda na produção de mudas, ocorrendo maior incidência de pragas e doenças como cancro cítricos, a clorose variegada dos citros (CVC), a morte súbita e o *greening*, sendo este último responsável pela redução de 10% da produção média nos últimos anos (PORTAL REDE DE INOVAÇÃO E PROSPECÇÃO TECNOLÓGICA PARA O AGRONEGÓCIO, 2011).

Dentre as doenças citadas anteriormente o *greening* é a que tem causado maior preocupação, pois afeta todas as variedades cítricas, sendo considerada a mais grave doença dos citros no mundo (BOVÉ, 2006).

O *greening* é causado pela bactéria *Candidatus Liberibacter spp.*, transmitida pelo inseto psílídeo *Diaphorina citri*, que adquire e transmite a bactéria às demais plantas ao se alimentar de plantas já doentes.

No Brasil, em 2004, foram diagnosticadas as primeiras plantas com sintomas do *greening* em pomares das regiões Centro e Sul do Estado de São Paulo, e posteriormente nos Estados de Minas Gerais e no Paraná. (FUNDECITRUS, 2009a).

Entre os anos de 2008 a 2009 observou-se um aumento de 56% dos talhões contaminados com a doença em todo estado de São Paulo (FUNDECITRUS, 2010). Segundo o levantamento amostral realizado pelo Fundo de Defesa da Citricultura (Fundecitrus), 38,8% dos talhões dos pomares paulistas foram atingidos no ano de 2010.

O sintoma característico do *greening* aparece inicialmente, em alguns ramos com folhas mosqueadas (manchas de formas irregulares, mescladas com o verde amarelado no fundo verde), provocando desfolha, seca e morte de ponteiros, e os frutos amadurecem parcialmente, com formato irregular, inviabilizando o consumo (FUNDECITRUS, 2010).

A única forma de controle efetivo do *greening* consiste na erradicação pela raiz das plantas com sintomas da doença, sendo de suma importância a obtenção de um diagnóstico precoce para evitar a propagação.

Dentre os métodos existentes para diagnosticar a doença, pode-se citar o método de inspeção visual e a análise de *Polymerase Chain Reaction* (PCR) (INNIS et al., 1990). O PCR é um dos métodos que apresenta maior precisão no diagnóstico do patógeno. No entanto, torna-se proibitivo de ser aplicado em casos onde há necessidade de testes em larga escala, devido ao custo elevado por análise e ao longo tempo de resposta.

A inspeção visual é efetuada por técnicos treinados, devendo ser realizada periodicamente segundo o manual técnico da Fundecitrus (FUNDECITRUS, 2010), em intervalos de dois meses, com a detecção e eliminação imediata de todas as plantas identificadas com o sintoma.

As inspeções visuais podem ser realizadas de duas formas: i) por inspetores caminhando ao lado das plantas cítricas (Figura 1.1 a) e ii) por dois ou quatro inspetores em plataformas acopladas a um trator, como apresentado na Figura 1.1(b). Observou-se que este tipo de inspeção detecta em média 47,61 % de plantas sintomáticas num pomar (FUNDECITRUS, 2009b), ou seja, a eficácia deste método depende de vários fatores como: acuidade visual dos inspetores, conhecimento e prática na detecção de plantas sintomáticas, genótipo e altura das plantas, severidade e distribuição dos sintomas na planta, presença de outros sintomas nas folhas e nos frutos, época do ano, incidência de raios solares nas plantas e no rosto do inspetor.

Comparando o resultado da detecção de plantas sintomáticas entre equipes, observou-se que há variação dos resultados, não somente entre as equipes, mas também entre as inspeções realizadas pela mesma equipe (BELASQUE Jr. et al, 2010).

Figura 1.1 - Inspeções visuais realizadas em pomares de citros, em a) caminhando, b) em plataforma movida por tratores. Fonte: Fundecitrus (2009b).

Como a publicação da Instrução Normativa N° 53 (IN 53) (BRASIL, 2008) determina a eliminação de todas as plantas de pomares com incidência de *greening* superior a 28% (BELASQUE Jr. et al., 2009), os inspetores avaliam a porcentagem ou proporção de área foliar manchada em plantas sintomáticas, gerando estimativas de incidência da doença no pomar. Nos experimentos apresentados por Martins et. al. (2004), Kowata et. al. (2008) e Nutter e Schultz (1995) são destacados que a diferença de mensuração entre os inspetores depende da habilidade e condições físicas de cada um para discriminar a doença nas folhas.

Os problemas mencionados anteriormente para a identificação do *greening* evidenciam a necessidade de técnicas complementares que contribuam com a avaliação dos inspetores para melhorar a taxa de acerto. Este fato levou à proposta de uma metodologia baseada em processamento de imagens para diferenciar o *greening* de outras pragas, contribuindo como um recurso adicional para a estimativa desta doença.

1.2. Objetivos

Este trabalho teve por objetivo avaliar uma metodologia baseada em segmentação por cor e outra baseada em análise de textura para avaliação de folhas de citros sintomáticas,

identificando se estão contaminadas com o *greening* ou outras doenças e deficiências nutricionais.

Os objetivos específicos são os seguintes:

- Construção de um banco de dados constituído por imagens de folhas de citros digitalizadas;
- Avaliar as imagens de folhas utilizando segmentação por cor;
- Aplicação dos descritores de textura LBP, LFP e Haralick nas amostras extraídas das imagens digitalizadas;
- Utilização dos algoritmos IBK e RNA PMC para avaliar os resultados.

1.3. Estrutura do trabalho

O presente trabalho está organizado conforme a estrutura apresentada a seguir.

No capítulo 1 foi realizada uma apresentação do contexto no qual se insere o trabalho, e o objetivo.

O Capítulo 2 trata dos trabalhos relacionados, sendo inicialmente apresentada uma descrição da doença *greening* e sua situação no Brasil. Em seguida são apresentados os principais artigos relacionados à análise de textura, e aplicação de Redes Neurais Artificiais (RNA) para a segmentação por cor e classificação de imagens.

No Capítulo 3 é apresentada a teoria relacionada à textura.

No Capítulo 4 são descritas as metodologias utilizadas neste trabalho.

No Capítulo 5 são apresentados os resultados obtidos e as discussões.

No Capítulo 6 são apresentadas as conclusões, os trabalhos publicados e as sugestões para trabalhos futuros.

Capítulo 2

Revisão bibliográfica

2.1. Considerações iniciais

Neste capítulo inicialmente é feita uma introdução à doença *greening*, sendo descritos os principais trabalhos encontrados na literatura relacionados à sua detecção. Posteriormente são descritos artigos relacionados à análise de textura de imagens e aplicação de RNA para a segmentação por cor e classificação de imagens.

2.2. Proliferação do *Greening*

O *greening* é também conhecido como *Huanglongbing* (HLB), traduzido do chinês como “doença do dragão amarelo”, e teve seus primeiros sintomas relatados em 1919 na China. A partir desta data essa doença foi se proliferando por diversos países: em 1921 foram identificados pela primeira vez os sintomas do *greening* nas Filipinas; em 1928 foram observados também os sintomas da doença na África do Sul, onde foi apelidada de “*greening*” ou “doença do ramo amarelo” (GRAÇA, 1991); na Tailândia em 1960; nos Estados Unidos da América em 2005 e foi se proliferando por outros 40 países dos continentes Asiático, Africano, Oceania e Americano (BÓVE, 2006).

No Brasil foi detectado em 2004, primeiramente nos pomares da região de Araraquara, estado de São Paulo (COLETTA FILHO et al., 2004). Atualmente a doença é encontrada em pomares das regiões Centro, Sul e Sudeste do Estado de São Paulo e nos Estados de Minas Gerais e no Paraná.

Somente em 1978 é que foi identificado que o agente causal do *greening* é a bactéria *Candidatus Liberibacter spp.*, a qual é encontrada em três espécies: *Candidatus Liberibacter africanus*, *Candidatus Liberibacter americanus* e *Candidatus Liberibacter asiaticus*. No Brasil a proliferação desta doença foi favorecida pelo clima quente e seco, tendo sido constatadas as bactérias *Candidatus Liberibacter asiaticus* e a *Candidatus Liberibacter americanus* (COLETTA-FILHO et al., 2004). Estas duas bactérias são transmitidas por um inseto da ordem

dos hemípteros, da família *Psyllidae*, o psílídeo *Diaphorina citri*, que mede de 2 a 3 mm de comprimento e que tem preferência por climas secos e quentes (Figura 2.1).

Figura 2. 1 - Inseto psílídeo *Diaphorina citri*. Fonte: Floyd e Krass (2008).

O inseto adquire a bactéria ao se alimentar de uma planta já doente, mesmo estando o inseto no estágio de ninfa, e a bactéria permanece nele a vida toda. Geralmente esses insetos alimentam-se de brotos novos, onde seus ovos também são colocados, formando as ninfas.

A bactéria espalha-se por toda a planta, alojando-se em outros ramos, troncos e raízes. Ao se alimentar obstrui os vasos condutores de seiva, como o líber ou floema, inibindo o transporte da seiva para a planta, impedindo a distribuição de açúcares para as demais partes da planta, tornando-a improdutiva de 2 a 5 anos (ZAGHI, 2008). Os sintomas são os mesmos, indiferente da região ou país onde foi diagnosticada, destacando-se geralmente em ramos, com as folhas de cor amarelada em contraste com o verde das folhas dos ramos não afetados. O melhor período para a identificação da doença é no final do verão até o início da primavera.

As folhas do ramo com a doença apresentam coloração mosqueada (manchas amareladas de forma irregular) ou clorose assimétrica típica no limbo foliar, normalmente delimitada entre as nervuras secundárias do limbo foliar, como pode ser observado na Figura 2.2(a) e 2.2(b). Muitas vezes as manchas do *greening* são confundidas com outras doenças e deficiências nutricionais que se assemelham às características visuais do *greening* (Figura 2.3).

(a)

(b)

Figura 2. 2 - Imagens de folhas contaminadas com o Greening em (a) ramos amarelados contrastando com os outros ramos verdes, e (b) folhas mosqueadas. Fonte: Fundecitrus (2009b).

(a) *Greening*

(b) Clorose Variegada dos Citros (CVC)

(c) Deficiência de Magnésio

(d) Deficiência de Manganês

(e) Deficiência de zinco

(f) Rubelose

Figura 2. 3 - Amostras foliares ilustrando o *greening* e outras doenças e deficiências nutricionais.

As características de cada amostra foliar ilustrada na Figura 2.3 são as seguintes:

- (a) *Greening*: apresenta folha mosqueada ou clorose assimétrica.
- (b) CVC: apresenta pequenas manchas amareladas e irregulares, espalhadas na frente, e lesões de cor palha nas costas da folha.
- (c) Deficiência de Magnésio: amarelecimento em forma de “V” invertido.
- (d) Deficiência de Manganês: surge clorose entre as nervuras, porém mais pálidas e menos acentuadas que as de deficiência de zinco.
- (e) Deficiência de Zinco: apresenta clorose acentuada do limbo entre as nervuras.
- (f) Rubelose: apresenta lesão nas forquilha dos ramos principais; as folhas da copa tornam-se amareladas.

Os novos brotos das plantas contaminadas com o *greening* apresentam apenas a coloração amarelada e o fruto apresenta maturação, formato e coloração irregular, contendo partes verdes mesmo após a sua maturação, de onde se origina o nome da doença, e ocasiona a queda prematura do fruto (Figura 2.4a). As sementes ficam pequenas, escuras e com má formação como pode ser observado na Figura 2.4b. Internamente, o fruto apresenta filetes alaranjados próximos ao pedúnculo¹, e o tecido branco da casca e a polpa possuem uma espessura maior em relação aos de um fruto sadio, tornando o fruto impróprio para comercialização (Figura 2.4b) (FUNDECITRUS, 2010).

(a)

(b)

Figura 2. 4 - (a) Imagens de frutos deformados e com coloração alterada; (b) fruto com sementes abortadas.

Fonte: Fundecitrus (2009b).

Sendo uma das doenças mais temidas entre os agricultores de citros, por não possuir cura ou tratamento e por não existir variedade comercial de copa ou porta-enxerto resistente à

¹ Haste que prende o fruto.

doença, o controle do *greening* só pode ser feito com inspeção constante e eliminação imediata de plantas com sintomas. O controle do inseto transmissor deve ser realizado com uso de produtos químicos e com a montagem de armadilhas nas plantas.

2.3. Detecção do *greening*

As grandes perdas que a doença *greening* vem causando aos pomares de citros e a dificuldade dos agricultores em administrar as manifestações da doença e combate à mesma os têm levado a buscar auxílio em universidades e centros de pesquisas especializados em citros, estimulando a produção de vários trabalhos científicos.

Os primeiros sintomas da doença foram observados em 1938 por Chen (CHEN, 1943), mas os primeiros testes para diagnosticar o *greening* foram realizados por McClean e Oberholzer (1965) com o uso de indicadores biológicos, por meio de enxerto de plantas suspeitas em plantas indicadoras como a laranja doce, tangerina Pokan (*Citrus reticulata*) e tangelo Orlando (COLETTA FILHO; CARLOS, 2010).

A primeira tentativa de uso de indicador por composto químico para tentar detectar o *greening* foi relatada por Schwarz (1965), que aplicou o composto fluorescente azul-violeta como indicador de ácido gentísico², indicando em papel cromatográfico o composto com amostras de plantas sintomáticas. Foram obtidos bons resultados para laranjas doces, pois as plantas doentes apresentam altas concentrações deste fenólico. Entretanto Schwarz percebeu que este composto era influenciado pelas variações climáticas.

Embora a técnica PCR tenha sido desenvolvida em 1983 por M. Smith e Kerry B. Bullis, ela começou a ser utilizada para diagnosticar o *greening* a partir de 1996, tornando-se uma poderosa técnica na detecção e identificação de patógenos de plantas suspeitas. Basicamente, a técnica efetua a leitura do DNA da bactéria, comparando-a com dois bancos de dados: um com plantas sabidamente saudáveis e outro com plantas infectadas com o patógeno (CUBERO; GRAHAM e GOTTWALD, 2001). Atualmente, existem duas técnicas de detecção do DNA da bactéria: i) PCR convencional aplicável apenas em folhas sintomáticas e ii) PCR em tempo real ou quantitativo, cuja sensibilidade é 2000 vezes maior em relação à técnica convencional. O tempo de resposta destas técnicas é demorado (aproximadamente 20 dias), seu custo é normalmente alto e depende da qualidade do reagente

² É um composto fenólico presente nas plantas normais em baixas concentrações.

utilizado, inviabilizando as análises de rotina em áreas produtivas de plantas cítricas (AGRISOFT, 2009).

Devido ao alto custo e ao longo tempo de resposta do PCR, outras técnicas foram pesquisadas, buscando obter resultados mais rápidos na detecção da doença, com potencial de uso em larga escala.

Taba et al. (2006) desenvolveram um método de baixo custo e com resultados rápidos, realizando testes por meio de composto químico com solução à base de iodo, para detectar as alterações fisiológicas ocasionados pelo *greening* em folhas de citros, visto que as folhas doentes apresentam uma alta concentração de amido quando contaminados com *greening*. Com as folhas trituradas e amolecidas em água quente, estas foram aplicadas à solução de iodo, e como resposta apresentou uma coloração roxa para as folhas doentes, azul para as amostras com deficiência nutricional e amarelo ou marrom para as saudáveis. Foi utilizado um conjunto de 100 amostras de folhas doentes, e os resultados obtidos com o composto à base de iodo foram comparados com os resultados do PCR, obtendo-se 75% de acurácia.

Dando continuidade à pesquisa anterior Etxeberria et al. (2007) realizaram experimentos com tintura de iodo diluída em água, para identificar supostas folhas contaminadas com o *greening*, e concluíram ser esta uma técnica útil para selecionar as amostras, ajudando a distinguir entre os sintomas de deficiência nutricional, dos sintomas do *greening*. Como esta técnica determina amostras que tem certa probabilidade de contaminação, as amostras selecionadas devem ser posteriormente submetidas à análise por PCR, para confirmar a presença do *greening*. O IFAS (*Institute of Food and Agricultural Sciences*) da Universidade da Flórida não recomenda o uso da técnica para determinar com exatidão a presença do *greening* na planta.

Zaghi (2008) desenvolveu uma metodologia para diagnosticar folhas doentes, utilizando espectroscopia de fluorescência e fluorescência induzida por laser, avaliando a técnica para cinco tipos de variedades de porta-enxerto e quatros tipos de variedades de copa de laranjas. Os espectros foram analisados por métodos estatísticos de PCA, permitindo distinguir a variação das concentrações de clorofilas a e b, entre as plantas doentes e saudáveis. Os resultados obtidos mostraram que a taxa de acerto na distinção entres as folhas doentes e saudáveis foi superior a 93%.

Hawkins et al. (2010) aplicaram a técnica de espectroscopia de absorção no infravermelho médio, utilizando a transformada de Fourier para análise dos espectros, com o objetivo de identificar os sintomas do *greening* em folhas de citros. Foi observado que a

região dos espectros que diferencia as amostras doentes das saudáveis corresponde à faixa 900 cm^{-1} à 1180 cm^{-1} . As folhas doentes possuem uma alta concentração do composto de carboidrato, que responde ao estímulo de vibração nesta região, sendo este composto que torna os frutos pequenos e ácidos. Foram analisadas 179 amostras de folhas e comparados os resultados desta técnica com os resultados obtidos pela técnica de PCR, e a avaliação final mostrou uma acurácia superior a 95%.

Silva et al. (2010) utilizaram os sinais capturados por espectroscopia de absorção no infravermelho médio (FTIR), aplicando a transformada de Fourier aos espectros obtidos das folhas doentes (sintomáticas e assintomáticas) e das saudáveis. Durante o período de oitos meses de testes, utilizando a técnica FTIR, foram realizadas medidas semanais com noventa amostras de folhas doentes e folhas saudáveis, analisando-se os resultados com PCA. Com a interpretação dos espectros de infravermelho, verificou-se que as plantas passaram por transformações químicas que podem ter sido ocasionadas pela presença da bactéria. Os autores concluíram que a aplicação da espectroscopia de infravermelho no estudo do *greening* em plantações de citros mostrou ser uma ferramenta útil, que continua sendo estudada com a tentativa de desenvolver uma metodologia para a detecção precoce da doença.

Gonzalez-Mora et al. (2010) analisaram os sinais *hiperespectrais* das folhas de citros, para detectar o *greening*, e incluíram as amostras de folhas saudáveis, folhas com diferentes deficiências nutricionais e folhas com o *greening*. A avaliação foi realizada nas faixas do visível e do infravermelho, tendo sido utilizado o algoritmo de classificação por regressão logística e o método *Sequential Floating Forward Selection* (SFFS). A metodologia utilizada para a classificação do *greening* apresentou resultados preliminares promissores em comparação aos resultados da técnica PCR, apesar de não terem confirmado conclusivamente a detecção da doença pela técnica proposta.

Kumar et al. (2010) fizeram um estudo aplicando métodos para detectar áreas contaminadas com o *greening* por meio de imagens *hiperespectrais* e *multiespectrais*. As imagens *hiperespectrais* foram obtidas na faixa de 457 nm à 921 nm, abrangendo 128 bandas espectrais, com a resolução espacial de 1m e 3,6 nm de resolução espectral, a 1524 m de altitude. Já as imagens *multiespectrais* foram obtidas na faixa de 480 nm à 830 nm, com quatro bandas espectrais (vermelho, verde, azul e próximo do infravermelho) e altitude de 3048 m. As imagens foram obtidas com 640 pixels de resolução e 12 bits de resolução radiométrica, e também foram georreferenciadas (cada pixel de resolução correspondendo a 1m). Foram aplicados os métodos *Mixture Tuned Match Filtering* (MTMF), *Spectral Angle Mapper* (SAM) e *Linear Spectral Unmixing* (LSU). A técnica PCR foi também realizada para

a comparação dos resultados da análise das imagens espectrais obtidas pela técnica proposta. Com o método MTMF obteve-se acurácia de 80% e com o método SAM obteve-se 87%.

Em Sankaran et al. (2010) foi realizado um estudo de técnicas com espectroscopia no infravermelho médio em tempo-real, em folhas de citros, com o objetivo de auxiliar na detecção das folhas doentes, folhas com deficiência nutricional e folhas saudáveis. A análise foi dividida em duas etapas e as amostras foram analisadas por um espectrômetro de infravermelho-médio portátil. Foram calculadas a primeira e segunda derivada dos espectros obtidos das amostras foliares e em seguida aplicada a análise por PCA. A seguir, com o conjunto de dados reduzidos por meio de PCA, este foi classificado por dois algoritmos: análise discriminante quadrática e pela análise de *k*-vizinho próximo. A primeira etapa, baseada no algoritmo de análise do *k*-vizinho próximo, resultou numa classificação superior à da segunda etapa, com desempenho superior a 95% em relação à análise discriminante quadrática. Foi observado que o pico do espectro que corresponde à faixa de valores entre 9 μm à 10,5 μm permite diferenciar as amostras foliares doentes com *greening*, das amostras foliares com deficiência nutricional e saudáveis, devido ao fato das folhas doentes possuírem um acúmulo de amido.

Sankaran et al. (2011), aplicaram a técnica de espectroscopia no infravermelho próximo do visível, para detectar o *greening* em pomares de citros. Foram coletados os dados espectrais das amostras foliares correspondentes às faixas de 350 nm à 2500 nm, com 989 características espectrais entre 100 amostras de folhas saudáveis e 93 amostras de folhas doentes. No pré-processamento os dados foram normalizados e foi feita a média a cada 25nm, para reduzir as características espectrais, criando três conjuntos de dados, sendo o primeiro formado pela primeira derivada, o segundo conjunto pela segunda derivada e o terceiro conjunto de dados obtido pela combinação dos dois anteriores. Aos conjuntos de dados foram aplicados PCA para reduzir o número de características usadas como entrada no algoritmo de classificação. Os conjuntos de dados formados por PCA foram misturados aleatoriamente e separados, sendo 75% dos dados para treinamento e 25% para testes. Os algoritmos avaliados foram: análise discriminante linear, análise discriminante quadrática (QDA), *k*-vizinho próximo e *Soft Independent Modelling of Classification Analogies* (SIMCA). O conjunto de dados da segunda derivada avaliado com o algoritmo QDA, apresentou precisão de 95%. Para as amostras com *greening* a classificação apresentou precisão de 98%, e o algoritmo SIMCA apresentou precisão de 92%, com 3% de falsos negativos.

2.4. Trabalhos relacionados à análise de textura

A textura é definida por um conjunto de medidas locais que apresentam variações espaciais de intensidade de níveis de cinza ou cor. A análise de textura possibilita obter informações para resolver problemas que envolvem diferentes aplicações, permitindo diferenciar os objetos de interesse, baseando-se em técnicas de processamento de imagens para a extração das características, segmentação, reconhecimento de padrões e classificação dos atributos.

A classificação automática de imagens vegetais é um processo difícil, que depende diretamente dos atributos visuais levantados na coleta, como a geometria, atributos da cor, forma, textura e contorno foliar, podendo apresentar grandes variações com a idade da planta, tamanho, impurezas, pragas ou/e doenças e fatores do meio como solo, iluminação e clima.

Os avanços em técnicas de processamento de imagens, como análise de textura vêm permitindo auxiliar na inspeção e monitoramento de pragas e doenças, identificação de plantas invasoras, mapeamento de áreas infestadas, estado de crescimento de área cultivada, permitindo também a inspeção e classificação da qualidade de produtos na produção agrícola, proporcionando maior precisão e rapidez na avaliação.

A seguir serão apresentados artigos que utilizam análise de textura em aplicações que envolvem plantas e também aplicações médicas.

Alves et al. (2002) aplicaram técnicas de processamento de imagens na classificação de dois tipos de folhas daninhas, *Bidens pilosa* (folha larga) e *Brachiaria decumbens* (folha estreita), onde foram coletadas imagens monocromáticas a 10 cm de altura das plantas em 4 etapas de desenvolvimento. Destas imagens foram recortados e processados blocos de 5x5 e 20x20 pixels, utilizando-se as características texturais da matriz de co-ocorrência da imagem. Em seguida foram aplicadas a técnica de PCA e a análise discriminante para a classificação das folhas de plantas daninhas. Aplicando a função discriminante para cada etapa de desenvolvimento obteve-se o valor médio de precisão de 92% para blocos de 5x5, e 88,3% de precisão para blocos de 20x20 pixels.

Andrade e Pinto (2003) verificaram que os descritores de forma são úteis para a identificação de diversas plantas por meio de suas folhas. Com o objetivo de classificar folhas de plantas diferentes, foram realizados dois experimentos. No primeiro experimento foram coletadas nove amostras de folhas de três tipos diferentes de forma e tamanho e no segundo experimento foram coletadas dez amostras de folhas, com tamanho e forma diferentes. Em ambos os experimentos foram calculados descritores tais como área, perímetro e fator de

forma. Foram marcados 16 pontos sobre o contorno da folha, numerando no sentido horário a partir da junção do caule com a folha, e calculada a distância absoluta de cada ponto do contorno da folha até o centro de massa do conjunto de pontos. Este conjunto de pontos foi usado como entrada para compor o vetor de características, que foi analisado por PCA. Com este método foi possível agrupar corretamente as folhas em três diferentes classes: folha de castanheira, goiabeira e manga.

Martins et al. (2005) analisaram imagens radiográficas frontais do tórax e extraíram atributos de textura. O banco de imagem incluía 482 imagens contendo lesões e 324 imagens normais. Foram analisadas as lesões intersticiais, separado os pulmões pelo contorno do fundo da imagem. Posteriormente cada pulmão foi dividido em regiões menores, e de cada uma das regiões da lesão foram extraídos atributos de forma automática. Foi realizada uma seleção das melhores combinações de atributos extraídos de quatro matrizes de co-ocorrência (energia, contraste, correlação, momento da diferença inversa, média da soma, média da diferença, entropia, entropia da soma, entropia da diferença, variância da soma, variância da diferença e medida de informação da correlação I) nas direções 0° , 45° , 90° 135° utilizando a distância Jeffries-Matusita. As regiões normais e suspeitas foram classificadas utilizando a comparação com os k -vizinhos mais próximos, tendo sido treinado o classificador pelo teste "half-half" e utilizada a correlação cruzada. Os resultados foram analisados utilizando a curva ROC (*Receiver Operating Characteristic*), onde os valores variam de 0 a 1; obteve-se o valor de 0,887 da curva ROC, 0,804 para o valor de sensibilidade e 0,793 para a especificidade.

Caponetti et al. (2006) propuseram a segmentação por textura utilizando o descritor *Local Fuzzy Pattern* (LFP) baseado em uma estratégia de decisão neuro-fuzzy, sendo uma extensão do descritor *Local Binary Pattern* (LBP) onde a diferença de níveis de cinza entre o pixel central e o pixel da vizinhança deve ser caracterizada por conjuntos fuzzy [N (Negativo) e P (Positivo)], com funções de pertinência dos conjuntos fuzzy simétricas e trapezoidais, possibilitando quatro possíveis padrões fuzzy (NN, NP, PN e PP). O grau de pertinência foi calculado e acumulado no *bin* do histograma. Todo o processo foi repetido em toda a vizinhança e todos os graus de pertinência foram multiplicados e seu valor final armazenado no k -ésimo *bin* do histograma. Para os testes foram utilizadas imagens do banco de imagens VisTex e de diferentes imagens de mosaico construídas a partir de combinações de texturas primitivas de Brodatz, com tamanho de 512×512 pixels. Os resultados mostraram que o descritor LFP foi capaz de segmentar as imagens para regiões de textura uniforme, preservando as bordas finas de textura, e com desempenho melhor que o LBP para imagens distorcidas com ruído.

Santos, Nunes e Delamaro (2007) implementaram um sistema para recuperação de imagens de mamografias baseadas no conteúdo (CBIR - *Content-Based Image Retrieval*), com objetivo de auxiliar os testes de sistemas CAD. Os sistemas CBIR permitem extrair atributos relacionados a cor, textura ou forma, de acordo com a classe de imagem e o interesse do usuário, armazenando essas informações num vetor de características. A partir desses vetores de características de espaço n-dimensional, a recuperação das imagens é realizada considerando a menor distância euclidiana entre os vetores: quanto menor o valor mais parecidas são as imagens. Na extração das características foram utilizados seis descritores: área, densidade, forma da mama, entropia, segundo momento angular e contraste. Os últimos 3 descritores foram extraídos da matriz de co-ocorrência e são características de textura. Foram calculados os valores de cada característica selecionada de todas as imagens e estes foram armazenados em um banco de imagens. Para a fase de recuperação foi criado um vetor de característica para cada imagem. Nesta etapa foi utilizada uma função de similaridade que compara os resultados do vetor de referência com as demais imagens do banco. Os valores retornados são armazenados em um vetor numérico, onde cada uma das posições representa a similaridade de uma das imagens com a imagem referência. Após ordenar este vetor foi possível obter uma classificação das imagens mais similares de acordo com as características selecionadas. As características individuais que apresentaram melhor desempenho foram “área e forma”, com 97,5% de precisão. Considerando a análise de características agrupadas as que apresentaram melhor desempenho foram a “densidade e forma” com 97,5% de precisão e “área e forma” com 97,5% de precisão. Por outro lado, os piores desempenhos entre as características individuais foram apresentados pelo contraste seguido pelo segundo momento angular (SMA). Para as características agrupadas os piores desempenhos foram para “entropia e SMA” no segundo conjunto seguido de “SMA e contraste” no terceiro conjunto.

Quinta (2008) aplicou técnicas de visão computacional baseadas em análise de textura para extração de atributos e classificação de peças de couro nos estágios couro cru e *wet-blue*, com fundo branco e madeirado, e estimou a área do couro bovino. A autora utilizou para extração de atributos o descritor LBP, mapas de interação, matrizes de co-ocorrência e filtro de Gabor. Os atributos extraídos foram fundidos e selecionados por diferentes algoritmos de seleção de atributos pelo *toolbox* Weka (WEKA, 2011) como o método *best-first*, algoritmos genéticos e busca gulosa. Em seguida o couro e o fundo foram segmentados em duas classes. Os resultados obtidos mostraram 99,98% de acerto para seleção de atributos no estágio couro cru, 100% de acertos para a seleção de atributos no estágio *wet-blue* com

fundo amadeirado e 99,97% de acertos para a seleção de atributos no estágio *wet-blue* com fundo branco.

Iakovidis, Keramidas e Maroulis (2008) introduziram o novo descritor denominado de *Fuzzy Local Binary Pattern* (FLBP), sendo uma extensão *fuzzificada* do LBP, para caracterização de textura em imagens de ultrassonografia. Com dois conjuntos de regras *fuzzy*, foi descrita a relação entre os valores de intensidade dos pixels da vizinhança e o pixel central, numa vizinhança 3x3. Dessa forma foram determinadas duas funções de pertinências, possibilitando caracterizar uma vizinhança 3x3 por mais de um código LBP, resultando em mais de um *bin* do histograma FLBP. Foram analisados 65 imagens de ultrassonografia para identificar nódulos de parênquima da tireóide, onde foram extraídos amostras de 32x32 pixels, totalizando 240 amostras. As amostras foram classificadas com diferentes classificadores (SVM, matriz de co-ocorrência e FLBP) e comparados os resultados. O melhor resultado apresentado foi o do classificador FLBP com 84% de acurácia. Para os outros classificadores os resultados foram de 70% de acurácia para o SVM e de 62% de acurácia para a matriz de co-ocorrência.

Suruliandi e Ramar (2008) propuseram o *Local Texture Pattern* (LTP), que seria o aprimoramento do *Texture Unit* (TU) aliado à medida de uniformidade do LBP para a redução do número de *bins*, possibilitando detectar o número de transição ou descontinuidades na disposição circular dos padrões. Para a classificação foram extraídas amostras da imagens do álbum de Brodatz, com o tamanho de 512x512 pixels, em 5 classes, totalizando 262144 amostras. Os resultados mostraram que o método LTP apresentou um desempenho de 99% de precisão, o TU apresentou 89% de precisão e o LBP 87% de precisão.

Santos (2009) aplicou técnicas de processamento imagens para auxiliar na identificação de plantas invasoras como a folha larga e folha estreita, fazendo uso de análise de textura e descritores baseados em forma para o reconhecimento do padrão das plantas. O valor de textura foi encontrado utilizando-se de medidas estatísticas extraídas da matriz de co-ocorrência. O processo de validação consistiu na montagem do mapa para aplicação de herbicidas e cálculo do percentual de ocupação das folhas. A validação do método de reconhecimento de plantas invasoras, foi realizada na cultura de milho na unidade da Embrapa Milho e Sorgo, obtendo um coeficiente linear de 0,84, com uma taxa de acerto de 84,24 % para folhas largas e um coeficiente linear de 0,801 com uma taxa de acerto de 80,17% para folhas estreitas.

Kim et al. (2009) realizaram a análise de imagens microscópicas em folhas de citros em diferentes condições: folhas com manchas mosqueadas, folhas com ilhas verdes, folhas

com deficiência de ferro, manganês, zinco, folhas novas brilhantes e folhas maduras normais. As imagens foram digitalizadas no sistema de cores RGB e foram convertidas para o sistema de cores HSI, e para cada imagem de folha digitalizada, foram extraídas 39 características estatísticas usando o método de análise da matriz de co-ocorrência para cor. Para reduzir as características texturais redundantes e melhorar o desempenho na classificação foi utilizado o algoritmo *Stepwise Discriminant Analysis* (SDA), em três tipos de combinações: a primeira inclui todos os tipos de amostras, a segunda todas menos as amostras de folhas novas brilhantes e a terceira com todas as amostras de folhas brilhantes e as folhas mosqueadas. A terceira combinação apresentou uma acurácia de 97,33%, a segunda 95,60% e a primeira 86,67%. Concluiu-se que as amostras foliares novas brilhantes confundiram-se com as amostras foliares adultas. Em média este método apresentou uma classificação robusta com acurácia de 94,06%, embora o trabalho não avalie a combinação das folhas novas brilhantes e adultas.

Sorensen, Shaker e Bruijne (2010), fizeram uma análise quantitativa de imagens tomográficas computadorizadas de enfisema pulmonar. O sistema proposto baseou-se na classificação de textura pela região de interesse, considerando as seguintes características de textura: *Local Binary Pattern* (LBP), *Gaussian Filter Bank* (GFB), e um conjunto de características baseadas no *Gray-Level Cooccurrence Matrices* (GLCM), *Gray-Level Run-Length Matrices* (GLRLM) e na atenuação do histograma. As imagens foram classificadas em três classes: tecido normal, enfisema e enfisema paraseptal, e centrolobulares. Os experimentos mostraram 95,2 % de precisão na classificação usando LBP na região de interesse.

Boaventura (2010) abordou o conceito de números *fuzzy* para a detecção de bordas em imagens com variação gradual dos níveis de cinza, denominado *Fuzzy Number Edge Detector* (FUNED), possibilitando também nesse trabalho analisar regiões por um descritor de textura local, usando uma função de pertinência triangular e simétrica. Os resultados obtidos pela técnica proposta foram comparados com outros detectores clássicos para detecção de bordas como o Sobel e Canny, os detectores que empregam sistemas de regras *fuzzy*, o detector de Miosso e o detector de Russo. Numa análise qualitativa os resultados comparados com Canny e de Miosso, apresentaram desempenho superior, mas em uma análise quantitativa, o FUNED é mais eficaz computacionalmente, comparados aos detectores de Canny, Sobel, e de Russo.

Sette e Maillard (2011) analisaram imagens de textura do bioma³ brasileiro por sensoriamento remoto. A partir de imagens nas bandas espectrais no visível (vermelho, verde e azul) foram extraídas as medidas de textura utilizando-se uma matriz de co-ocorrência das seguintes medidas: contraste, entropia, correlação, momento de diferença inversa e segundo momento angular. Os resultados obtidos com a classificação supervisionada com o algoritmo Máxima Verossimilhança, apresentaram 46,4% de precisão para as imagens que foram classificadas usando apenas as imagens no visível; as imagens classificadas usando as características de textura obtiveram 55,6% de precisão; e as imagens classificadas usando adição das características de textura e espectrais obtiveram 83,9% de precisão.

Huang et al. (2011) realizaram uma pesquisa para avaliar diferentes metodologias envolvendo LBP e a aplicação das mesmas em imagens de faces. O $LBP_{(p,r)}$ onde os valores de p representa a vizinhança e r o rádio, foi utilizado para imagens em grande escala. O ILBP foi usado para reforçar a capacidade discriminativa. O LTPs utilizado para melhorar a robustez. O SLBP emprega duas funções de pertinência ao invés de uma. Para avaliar uma imagem de vídeo, foi proposta a metodologia VLBP, combinada com a aparência de movimento e informações de volume. Outra combinação também proposta foi a LBP com *Wavelets* de Gabor, onde o LBP possibilita a captura do detalhe da aparência local da imagem e as *Wavelets* de Gabor permitem extrair informações numa grande gama de escalas. Análise de imagens faciais inclui a detecção de rosto, reconhecimento de faces, análise de expressão facial e classificação demográfica. Para análise de imagens faciais, considerou-se a imagem como sendo uma composição de regiões locais, onde são extraídos histogramas em LBP, concatenando-os em um único histograma. Para a detecção de rosto foram aplicadas as metodologias $LBP_{(4,1)}$ sobreposto em pequenas regiões e utilizando um SVM (*Support vector machine*) como classificador, obtendo-se taxa de acerto de 93,4 % de precisão. Outra forma proposta para a detecção de rosto foi a extração de histogramas espaciais sobre as medições de cores (Y, R, G, B e θ) nos espaços de cores RGB e YUV, usando o LBP para transformar as medidas obtidas em histogramas, e posteriormente utilizou-se um classificador SVM para discriminar as faces das não faces, obtendo 91,7% de precisão.

Liu et al. (2012) apresentaram uma nova abordagem na classificação de texturas baseada numa generalização do descritor LBP. Nessa nova abordagem dois tipos diferentes e complementares de características são extraídos de uma região local, sendo eles a intensidade do pixel e a diferença do pixel. A intensidade do pixel foi dividida em dois componentes: a

³ Um conjunto de ecossistemas.

intensidade do pixel central e a intensidade do pixel vizinho. Para a diferença do pixel foi estudado o raio e a diferença angular. Todos os descritores foram combinados para formar conjuntos de histogramas que possibilitem representar uma textura. Foram realizados experimentos em três de bases de dados: Outex, CURET e KTHTIPS2b. O LBP apresentou melhor resultado com o Outex. Já a metodologia proposta apresentou melhores resultados na classificação utilizando-se do KTHTIPS2b e resultados comparáveis ao estado da arte para o CURET.

Vieira et al. (2012a) propuseram o descritor *Local Fuzzy Pattern* (LFP) e apesar do nome do método ser igual ao proposto por Caponetti et al. (2006), ele é um descritor de textura local baseado em conjuntos de números *fuzzy*. Para avaliação deste descritor foi realizada uma comparação com o descritor LBP, a partir de 40 imagens de textura do álbum de Brodatz, sendo retirado das imagens amostras que variam do tamanho: 50x50 pixels, 55x55 pixels, 60x60 pixels, 65x65 pixels e 70x70 pixels. Os resultados obtidos mostraram que o descritor LFP possui maior poder discriminativo, com uma taxa de erro de 2,5% para uma amostra de 65x65 pixels. Foram também realizados testes utilizando o banco de dados Outex, com imagens rotacionadas não sobrepostas, com 3840 amostras extraídas, a partir de 20 imagens em oito ângulos. As amostras foram avaliadas com o descritor LFP com função de pertinência sigmoideal e os resultados comparados com o LBP, $LBP_{8,1}^{ri}$ e $LBP_{8,1}^{ri2}$. Os resultados mostraram um melhor desempenho para o descritor LFP com sensibilidade de 92,94%, enquanto o LBP obteve 50,21% de sensibilidade, $LBP_{8,1}^{ri}$ obteve 78,80% de sensibilidade e $LBP_{8,1}^{ri2}$ obteve 84,82% de sensibilidade.

Em outro teste de comparação realizado por Vieira et al. (2012b) foram utilizadas 111 imagens de textura do álbum de Brodatz, das quais foram retiradas 10 amostras de tamanho 50x50 pixels por imagem, totalizando 1110 amostras. Os resultados obtidos mostraram que o descritor LFP superou o LBP com a sensibilidade de 85,05% em relação a 80,18% de sensibilidade para o LBP.

Vieira e Gonzaga (2013) em seu trabalho avaliaram as técnicas LBP e LFP para classificar imagens de minério vermiculita. Foi criado um banco de imagens a partir de 10 imagens de 2592x1944 pixels, aplicando-se três tipos de iluminação diferentes: lâmpada fluorescente, iluminação natural e lâmpada de LED. As vermiculitas foram separadas por um especialista em 8 classes e extraídas 20 amostras aleatórias de cada imagem com diversos tamanhos: 100x100 pixels, 160x160 pixels, 180x180 pixels, 190x190 pixels, 220x220 pixels, 250x250 pixels e 300x300 pixels, totalizando 4800 amostras de imagens. A partir destas

amostras foram extraídas as características texturais pelos descritores LBP e LFP com a função sigmóide (LFP-s), utilizando a validação cruzada *leave-one-out*. Os histogramas de cada amostra foram comparados com o restante das amostras pela distância χ^2 . Os resultados da classificação foram armazenados em uma matriz de confusão, e foi realizado o cálculo da sensibilidade para cada descritor, sendo o descritor LFP de 300x300 pixels com iluminação natural no final que apresentou o melhor desempenho, com 98,7% de sensibilidade.

Considerando a variação do número de códigos binários *bins* do histograma na classificação das imagens, Chierici et al. (2013) propuseram uma nova metodologia para analisar imagens de texturas rotacionadas. A nova metodologia utiliza o descritor de textura LFP e compara os seus resultados com o LBP. O LFP considera os níveis de cinza extraídos de uma vizinhança como valores *fuzzy* com certo grau de incerteza, modulados por funções de pertinência *fuzzy*. Na metodologia proposta foi utilizada a função sigmóide como função de pertinência (LFP-s) e foi variado o número de *bins* do histograma gerado, com o objetivo de otimização do número de bins. Para avaliação da metodologia proposta foi utilizada a base de dados Outex, que contém um banco de texturas, criadas para facilitar a avaliação de algoritmos para classificação e segmentação de texturas. Os resultados foram avaliados pelo cálculo da sensibilidade e os histogramas foram comparados usando a distância X^2 . O descritor LFP-s mostrou ser uma excelente escolha para imagens rotacionadas, possibilitando capturar mais informações sobre o nível de cinza do que o descritor LBP, e nos resultados apresentados os melhores valores de sensibilidade foram obtidos com número inferior de 50 *bins*.

2.5. Trabalhos relacionados com redes neurais artificiais

As redes neurais artificiais (RNAs) são técnicas computacionais inspiradas na estrutura neural de seres vivos, que apresentam particularidades tais como: adaptação por experiência, capacidade de aprendizado, habilidade de generalização, agrupar ou organizar dados, tolerância a falhas, que auxiliam na análise e resolução de problemas (SILVA; SPATTI e FLAUZINO, 2010).

As RNA vêm sendo utilizadas no processamento de imagens digitais e visão computacional para auxiliar na classificação, segmentação e reconhecimento de padrões de imagens, com vários trabalhos publicados.

A seguir, serão apresentados alguns artigos que utilizam RNA em aplicações de visão computacional para a área agrícola.

Simões e Costa (2003) analisaram atributos de cor e forma das frutas, propondo um método automático baseado no padrão brasileiro de cor das laranjas. Foram capturadas as imagens de 25 amostras para cada exemplo de cor, no sistema de cores RBG, com resolução de 200x200 pixels, totalizando 125 amostras. Para a classificação das cores dos pixels da imagem foi utilizada uma RNA do tipo PMC (*Perceptron Multicamadas*), e em seguida foi aplicado o algoritmo de crescimento de região para a segmentação da imagem. Posteriormente foram extraídos descritores de forma (largura, comprimento, raio mínimo e raio máximo) e os descritores de cor (“Verde Escuro” (VE), “Verde Claro” (VC), “Amarelo” (A), “Laranja Claro” (LC), Laranja Escuro “LE” e “Marrom” (M)), construindo os vetores de características com estes dados, os quais foram submetidos ao algoritmo *fuzzy C-means*, de forma a determinar o vetor típico de cada uma das cinco classes. Depois de segmentada e extraídas as características de cor de cada fruta, foram utilizadas 120 laranjas para testes, comparando as características de cor com padrões previamente conhecidos. Os testes foram divididos em dois grupos, visando avaliar a robustez da classificação quanto às condições de iluminação e o poder de rejeição do sistema. Os autores mencionam que embora a aplicabilidade do método proposto tenha sido comprovada, verificou-se que a classificação de padrões utilizando como ferramenta a quantização vetorial, não é capaz de implementar qualquer função de classificação. Devido a isto, os autores sugerem a análise do problema por um classificador *fuzzy* que talvez possa tratar melhor o problema de rejeição (frutas fora do padrão) no sistema.

Dias e Neto (2004) analisaram imagens aéreas de plantações de cana-de-açúcar, com o objetivo de auxiliar os inspetores em campo, na identificação do agente causal da ferrugem. Foram utilizados os sistemas de cores RGB e L1L2L3, e selecionadas 150 regiões de interesse de 16x16 pixels, sendo 50 para cada nível de infecção das 36 imagens adquiridas. Em seguida foram extraídas das amostras as características de cores (média, variância e inclinação), o histograma de cor, o vetor de coerência de cor. A classificação foi realizada por uma rede neural PMC (*Perceptron MultiCamadas*), e também por árvore de decisão e SVM (*Support Vector Machines* e clusterização). Os autores dividiram a análise em dois experimentos, onde no primeiro experimento os dados foram extraídos, as fotos reveladas e digitalizadas. No segundo experimento foram extraídos os negativos das fotos reveladas, sofrendo um processo de normalização das cores durante a revelação. O sistema de cor L1L2L3 mostrou resultados superiores no experimento 1, e equivalentes ao histograma de cor

no experimento 2, promovendo uma boa taxa de classificação usando a rede neural, com 83,3% de acurácia.

Pereira Neto, Jorge e Guimarães (2005) avaliaram imagens aéreas digitalizadas de plantações de soja, por meio de um classificador baseado em técnicas de RNA implementado no *software* AGGeoImagem (AGX Tecnologia Ltda.) (AGX, 2011). O objetivo foi quantificar o nível de infestação de ervas daninhas em plantações de soja. As imagens foram capturadas por uma câmera embarcada em avião a 100 metros de altura da plantação, com resolução de 1030x1423 pixels, onde cada pixel da imagem representava 1 cm. Foi escolhida uma imagem representativa da plantação e importada para o *software* SPRING do INPE (Instituto Nacional de Pesquisas Espaciais), e posteriormente analisada visualmente pela composição colorida RGB, para definir qual representava a planta invasora. As imagens foram segmentadas e classificadas digitalmente em três classes: cultura, invasora e entrelinha pelo RNA da AGGeoImagem. A seleção das amostras para classificação foi baseada em semelhança de tonalidade, cor, textura e forma. Os resultados apresentados evidenciaram que a RNA adotada pelos *softwares* citados mostrou-se eficiente na quantificação do nível de infestação de ervas daninhas na lavoura de soja.

Cavani et al. (2006) utilizaram o algoritmo de segmentação JSEG e a RNA do tipo PMC para classificar as 658 imagens agrícolas de pomares de laranjas adquiridas em dias e horários diferentes. As imagens foram capturadas com 2048x1536 pixels de resolução e divididas em três grupos: grupo que mostra as árvores desde o solo até o topo; grupo que mostra apenas folhas e frutos; e grupo que mostra as fileiras de árvores, o solo e o céu. O algoritmo JSEG segmentou as imagens em três etapas: quantização do espaço de cores, crescimento de região e fusão das regiões com cores semelhantes. Após a segmentação, foram extraídas as características dos segmentos pelo histograma de cores para cada canal de cores RGB e HSV. Os vetores de característica testados foram formados pelos histogramas: H, H e S; H, S e V; R, G e B; RGB normalizados. Para a classificação dos segmentos, foram utilizadas duas abordagens. Foi usado o algoritmo iRPROP que é um algoritmo derivado do *backpropagation*. Na primeira abordagem foi utilizada uma RNA com as entradas associadas aos histogramas do sistema de cores HSV com 256 categorias, 60, 70 e 90 neurônios na camada escondida e cinco neurônios para a camada de saída, que corresponde às classes: folhas, frutas, céu, solo e demais plantas. Na segunda abordagem utilizou-se de cinco RNA, sendo uma para cada tipo de segmento, com 20 vetores de características formados com os histogramas dos canais de cores. Após o treinamento foi selecionada dentre os diferentes topologias, aquela que apresentou o menor EQM (erro quadrático médio). Os autores

concluíram que o classificador que mostrou ser mais adequado para o problema proposto foi a RNA, permitindo determinar quais os algoritmos mais adequados para classificar os segmentos com a RNA adotada, e foi observado que os vetores de características extraídos do espaço de cores HSV apresentaram menor EQM.

Sartori (2006) aplicou RNA PMC com o algoritmo *backpropagation*, em imagens *multiespectrais*, nas bandas espectrais do comprimento de onda da luz vermelha, verde e do infravermelho próximo, com objetivo de discriminar graus de infestação de plantas daninhas em culturas de café. As imagens foram obtidas utilizando o sistema de sensoriamento remoto aerotransportado. Para o mapeamento das plantas daninhas, foram utilizados dois diferentes métodos: classificação de imagens *multiespectrais* (RNA) e análise geoestatística (Krigagem). Foi utilizado uma câmara de vídeo digital MS3100-CIR possui um chip CCD de 6,4x4,8mm com 1392x1040 detectores, arranjados matricialmente, com tamanho de 0,0046mm. A distância focal e altitude do voo do avião foram de, aproximadamente, 600 metros, com resolução espacial de 16 cm. Foi utilizado o *software* SPRING para análise geoestatística, o *software* IDRISI para gerar os dados para classificação e o *software* SNNS para classificar usando RNA. Os mapas temáticos gerados foram analisados, e foi feita a matriz de confusão entre os resultados obtidos e os dados adquiridos em campo. Os resultados da classificação e da geoestatística foram comparados entre si. A krigagem apresentou resultados suavizados e confusos, ao contrário da classificação por RNA. A classificação por RNA mostrou ser eficiente com o uso de duas camadas escondidas, obtendo acurácia de 89,16%.

Huang (2007) aplicou RNA com algoritmo *backpropagation* para classificar imagens de folhas de orquídeas com três tipos de doenças: a podridão mole (BSR), mancha marrom (BBS) e podridão negra (PBR). As imagens foram adquiridas no formato RGB com 640x480 pixels e equalizadas. As características de cor e de texturas da área da lesão ocasionada pelas doenças foram extraídas por meio de uma matriz de co-ocorrência (HARALICK, SHANMUGAN E DINSTEIN, 1973). Foram extraídas três características de cor, considerando os valores médios de cada cor R, G e B, e 18 características de textura (área, perímetro e diâmetro médio, contraste, uniformidade, probabilidade máxima, homogeneidade, diferença da inversa, diferença da variância, diferença da variância diagonal, entropia e a diferença da entropia das bandas G e B da área lesionada para avaliar a textura da área da lesão da folha). Foi utilizada a distância de 1 pixel e os ângulos de 0°, 45°, 90° e 135° na montagem da matriz. Foram definidas quatro classes de saída, sendo uma para as plantas saudáveis (OK) e as outras três restantes para as plantas doentes (BSR, BBS e PBR). Com

145 imagens para as plantas doentes e 40 para as plantas saudáveis, a RNA conseguiu classificar as doenças mencionadas com uma acurácia de 97, 2%.

Venâncio (2010) fez um estudo aplicando RNA para distinguir plantas doentes com *greening* de plantas saudáveis, baseado na obtenção de espectros de fluorescência induzida por laser (LIFS) das folhas de citros. Foram realizados dois experimentos. O primeiro experimento realizado no campo com pés de laranjeira Pêra-rio enxertada em limoeiro Cravo demonstrou que plantas sintomáticas podem ser diagnosticadas com eficiência de 87%. No segundo experimento usou mudas de laranjeira Valência em citrumeleiro Swingle, comprovando que a técnica proposta também é capaz de diagnosticar plantas assintomáticas, obtendo taxas de acerto de até 63%. Da comparação dos resultados com os obtidos por RT-PCR constatou-se que a técnica proposta apresentou taxa de acerto até duas vezes maior nos estágios iniciais do desenvolvimento da doença, até dois meses antes do aparecimento dos sintomas. Foram feitos também estudos preliminares da viabilidade do uso das técnicas de imagens de fluorescência induzida por laser (LIFI) e espectroscopia de emissão óptica com plasma induzido por laser (LIBS) para o diagnóstico precoce do *greening*. Os resultados mostraram que na fase assintomática da doença, LIFI obteve sempre mais de 68% de acerto, e LIBS obteve mais de 62% em todos os casos. Todas as técnicas forneceram resultados superiores aos da inspeção visual, e todas mostraram-se mais viáveis que o RT-PCR, tanto pela rapidez quanto pelo custo envolvido.

2.6. Considerações finais

A revisão bibliográfica apresentada abordou a evolução do *greening*, com técnicas de identificação e combate desta doença ao longo dos anos. Foram também incluídos na revisão, trabalhos encontrados principalmente na literatura, na área de agricultura, que utilizam técnicas de processamento de imagens e visão computacional, que evidenciam técnicas possíveis de serem aplicadas na detecção do *greening*.

Na identificação do *greening*, a técnica de espectroscopia apresenta resultados promissores (SANKARAN et al. (2011); SANKARAN et al.(2010); SILVA et al. (2010); HAWKINS et al. (2010); ZAGHI (2008)), mas requer equipamentos de custo elevado.

Dentre os trabalhos apresentados na área de processamento de imagens destacam-se os resultados daqueles que usam métodos de análise de textura local com o *Local Binary Pattern* (LBP) (SORENSEN, SHAKER e BRUIJNE (2010); LIU et al. (2012); QUINTA

(2008); HUANG et al. (2011)), assim como com o *Local Fuzzy Pattern* (LFP), descritor de textura local baseado em conjuntos de números *fuzzy* (SIMÕES e COSTA, 2003; VIEIRA et al. (2012a); VIEIRA et al. (2012c); VIEIRA et al. (2012b); VIEIRA (2013)) , sendo que o LFP merece destaque pelo desempenho superior ao LBP em algumas aplicações.

O uso de redes neurais artificiais tem mostrado ser capaz de segmentar regiões de interesse nas imagens e classificar as texturas de modo eficaz (PEREIRA NETO; JORGE; GUIMARÃES, 2005; CAVANI et al., 2006; SARTORI, 2006; HUANG, 2007; VENÂNCIO, 2010), sendo outra ferramenta a ser considerada para a classificação das imagens.

Capítulo 3

Teoria Relacionada

3.1. Considerações iniciais

Este capítulo tem como objetivo apresentar uma introdução sobre textura e as principais abordagens para descrição de textura incluindo abordagem por micropadrões e LFP, sendo esta última de interesse para o presente trabalho. Além disso, é apresentada uma introdução sobre conjuntos *fuzzy* e números *fuzzy*, redes neurais artificiais e o modelo de cor RGB.

3.2. Introdução sobre a textura

Análises de textura vêm se tornando muito útil em várias aplicações, por se aproximar de uma avaliação feita pelo sistema visual humano, permitindo identificar regiões por meio do padrão de cores. Apesar da textura não possuir uma definição formal, ou seja, na forma quantitativa, apenas na forma qualitativa, a sua definição tende a ser mais em relação à sua aplicação (Vieira, 2013).

Gool, Dewaele e Oosterlinck, (1985) definiram a textura com sendo uma estrutura composta por uma área contendo vários elementos ordenados ou em padrões, não possuindo relevância ao serem observados individualmente, mas quando observados de forma global estes elementos podem identificar uma determinada área.

Haralick, Shanmugan e Dinstein (1973) definiram a textura a partir de medidas como a de uniformidade, densidade, aspereza, regularidade e intensidades, entre outras características da imagem, permitindo caracterizar as propriedades de tonalidades dos pixels e o relacionamento espacial entre esses pixels.

A textura é um componente importante para análise de imagem, permitindo extrair informações de rugosidade ou suavidade de determinada superfície, e a regularidade. Ela fornece informações sobre a distribuição espacial das variações de tonalidades, possibilitando envolver várias aplicações, como a segmentação, reconhecimento de padrões e síntese de textura.

Gonzalez e Woods (2010) descrevem a textura por meio de três principais abordagens, a abordagem estatística, a estrutural e a espectral. Mas como o presente trabalho trata de técnicas que analisam a vizinhança local da imagem para extrair características que possibilitem a descrição de textura, foi incluída nesta teoria mais uma abordagem: a de micropadrões locais. Nas subseções seguintes serão descritas as quatro abordagens.

3.2.1 Abordagem estatística

A abordagem estatística considera a distribuição e o inter-relacionamento dos tons de cinza. Nela a textura é descrita por um conjunto de medidas locais usadas.

O método proposto por Haralick, Shanmugan e Dinstein (1973), conhecido também como método das matrizes de co-ocorrência – GLCM (*Grey Level Co-Occurrence Matrix*) é um método de abordagem estatística, que vem sendo amplamente utilizado (FERREIRO et al, 2006; QUEIROZ, ARAUJO E ARAUJO, 2008). Esse método, baseia-se na classificação de textura a partir de cálculos estatísticos de segunda ordem, permitindo extrair características de textura em uma imagem a partir de um conjunto de estatísticas para as ocorrências de cada nível de cinza em pixels diferentes, ao longo de diferentes direções (VIEIRA, 2013).

A matriz de co-ocorrência considera o operador $p(i, j; d, \theta)$, em uma imagem f , com L níveis de intensidades, onde p é uma matriz cujo elemento $p_{i,j}$ é o numero de vezes que os pares de pixels com intensidades z_i e z_j ocorrem em f na posição definida por p e $1 \leq i, j \leq L$. Ou seja a matriz de co-ocorrência considera a relação de dois elementos (pixels) de textura por vez, um chamado de pixel de referência e outro de pixel vizinho com propriedades i e j , separados por uma distância d em uma direção θ . O pixel vizinho pode estar em qualquer distância do pixel de referência como por exemplo 1 pixel, ou 2, ou 3, ou L , e em qualquer direção, como por exemplo, a 0° , a 45° , a 135° , a 180° , a 225° e 270° . A Figura 3.1 mostra um exemplo de como construir uma matriz de co-ocorrência usando $L=8$ e direção 0° com 1 pixel de distância. O elemento (1,1) de p é 1, pois existe apenas uma ocorrência em f de um pixel com o valor de 1 com outro pixel vizinho de valor 1 à sua direita. Passando para outro exemplo, o elemento (6,2) de p é 3, porque há apenas três ocorrências em f de um pixel com o valor de 6 e com outro pixel vizinho de valor 2, à sua direita (GONZALEZ; WOODS, 2010).

Figura 3.1 - Exemplo de uma matriz de confusão usando $L=8$ e direção 0° com 1 pixel de distância.

Fonte: Gonzalez e Woods (2010).

Haralick, Shanmugan e Dinstein (1973) propuseram um conjunto de 14 descritores para descrever a textura, em que são definidas diversas características advindas do cálculo de matriz de co-ocorrência: segundo momento angular, contraste, correlação, variância, momento de diferença inverso, média da soma, variância da soma, entropia da soma, entropia, variância da diferença, entropia da diferença, medidas de informações da correlação (com 2 propriedades) e coeficiente de correlação máximo.

As equações de 3.1 a 3.17 definem esses descritores. A seguinte notação é utilizada nas equações:

- $p(i,j)$ representa a (i,j) -ésima entrada de uma matriz em tons de cinza, normalizada;
- $p_x(i)$ é a i -ésima entrada na matriz de probabilidade marginal obtida pela soma das linhas de $p(i,j)$;
- N_g é o número de níveis de cinza distintos na imagem quantizada;
- μ_x, μ_y, σ_x e σ_y são as médias e o desvio padrão de p_x e p_y ;
- H_x e H_y são as entropias de p_x e p_y ;
- $\sum_i$ e $\sum_j$ representam $\sum_{i=1}^{N_g}$ e $\sum_{j=1}^{N_g}$, respectivamente.

Outras notações utilizadas:

$$p_y(j) = \sum_{i=1}^{N_g} p(i,j)$$

$$p_{x+y}(k) = \sum_{\substack{i=1 \\ i+j=k}}^{N_g} \sum_{j=1}^{N_g} p(i,j), \quad k = 2, 3, \dots, 2N_g$$

$$p_{x-y}(k) = \sum_{\substack{i=1 \\ |i-j|=k}}^{N_g} \sum_{j=1}^{N_g} p(i,j), \quad k = 0, 1, \dots, N_g - 1$$

1) Segundo momento angular:

$$f_1 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \{p(i,j)\}^2 \quad (3.1)$$

2) Contraste:

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{\substack{i=1 \\ |i-j|=n}}^{N_g} \sum_{j=1}^{N_g} p(i,j) \right\} \quad (3.2)$$

3) Correlação:

$$f_3 = \frac{\sum_i \sum_j (ij) p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3.3)$$

4) Variância:

$$f_4 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i - \mu)^2 p(i,j) \quad (3.4)$$

5) Momento de diferença inversa:

$$f_5 = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{1}{1 + (i-j)^2} p(i, j) \quad (3.5)$$

6) Média da soma:

$$f_6 = \sum_{i=2}^{2Ng} i p_{x+y}(i) \quad (3.6)$$

7) Variância da soma:

$$f_7 = \sum_{i=2}^{2Ng} (i - f_6)^2 p_{x+y}(i) \quad (3.7)$$

8) Entropia da soma:

$$f_8 = - \sum_{i=2}^{2Ng} p_{x+y}(i) \log\{p_{x+y}(i)\} \quad (3.8)$$

9) Entropia:

$$f_9 = - \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} p(i, j) \log(p(i, j)) \quad (3.9)$$

10) Variância da diferença:

$$f_{10} = p_{x-y} \quad (3.10)$$

11) Entropia da diferença:

$$f_{11} = - \sum_{i=0}^{N_{g-1}} p_{x-y}(i) \log\{p_{x-y}(i)\} \quad (3.11)$$

12) Medidas de informações da correlação (Primeira propriedade)

$$f_{12} = \frac{HXY - HXY1}{MAX\{HX, HY\}} \quad (3.12)$$

$$HXY = - \sum_i \sum_j p(i, j) \log p(i, j) \quad (3.13)$$

$$HXY1 = - \sum_i \sum_j p(i, j) \log\{p_x(i)p_y(j)\} \quad (3.14)$$

$$HXY2 = - \sum_i \sum_j p_x(i)p_y(j) \log\{p_x(i)p_y(j)\} \quad (3.15)$$

13) Medidas de informações da correlação (Segunda propriedade):

$$f_{13} = (1 - \exp[-2.0(HXY2 - HXY)])^{1/2} \quad (3.16)$$

14) Coeficiente de correlação máximo:

$$f_{14} = \left(\sum_k \frac{p(i, k)p(j, k)}{p_x(i)p_y(k)} \right)^{1/2} \quad (3.17)$$

De acordo com Haralick, Shanmugan e Dinstein (1973) os descritores anteriormente apresentados permitem a análise de características que não são invariantes sobre as transformações monotônicas de níveis de cinza, possibilitando classificar, por exemplo, duas imagens com a mesma textura, em níveis de cinza claro e escuros, onde os olhos humanos não seria capazes.

Outra abordagem para quantificar a textura de uma imagem é o uso da função de autocorrelação, que relaciona texturas de natureza repetitiva, permitindo extrair um vetor de deslocamento entre a própria imagem e a imagem traduzida (HARALICK, SHANMUGAN e DINSTEIN, 1973).

3.2.2 Abordagem estrutural

Algumas texturas podem ser vista como padrões bidimensionais constituídos por um conjunto de primitivas ou subpadrões, organizados a partir de algumas regras de localização para sua geração (STEIN, 2005).

A abordagem estrutural lida com arranjos de primitivas de textura dispostas de forma aproximadamente regular e repetitiva, com regras bem definidas de posicionamento espacial. Essa textura pode ser simples, como pixels individuais, ou uma região com níveis de cinza uniforme.

Para compreender melhor essa abordagem, será considerada a Figura 3.2 (a) que mostra a estrutura de escada simples. Considerando que essa estrutura tenha sido segmentada a partir de uma imagem, que se deseja descrevê-la de alguma maneira formal. Ao definir os dois elementos primitivos a e b como mostrados na Figura 3.2 (a) pode-se codificar a Figura 3.2(a) na forma mostrada na Figura 3.2 (b) (GONZALEZ; WOODS, 2010).

Figura 3. 2 - (a) Uma simples estrutura como uma escada. (b) Estrutura codificada. Fonte: Gonzalez e Woods (2010).

Uma abordagem simples de descrição dessa estrutura é usar o método de regras de rescrita:

- 1) $S \rightarrow aA$,
- 2) $A \rightarrow bS$, e
- 3) $A \rightarrow b$

onde S e A são variáveis, e os elementos a e b das regras são constantes primitivas. A regra 1 informa que S (símbolo inicial), pode ser substituído pela primitiva a e a variável A . A variável A por sua vez pode ser substituída por bS ou somente b . Substituir A por bS leva de volta à primeira regra e o procedimento pode ser repetido.

Por exemplo, observando-se a Figura 3.2 (b) a regra *ababab* que representa a ordem de regras (1,2,1,2,1,3), foi obtida pelos seguintes passos:

S (regra inicial)
 aA (regra 1)
 abS (regra 2)
 $abaA$ (regra 1)
 $ababS$ (regra 2)
 $ababaA$ (regra 1)
 $ababab$ (regra 3)

Pode-se observar que essas três regras simples podem ser usadas para gerar ou descrever um número infinito de estruturas semelhantes.

Essa abordagem é considerada apropriada quando a primitiva de textura é grande o suficiente para ser individualmente segmentada e descrita. A vantagem da abordagem estrutural é que fornece uma boa descrição simbólica da imagem em uma análise de textura.

3.2.3 Abordagem espectral

A abordagem espectral, baseia-se na propriedade do espectro de uma imagem, proposta por Fourier (GONZALEZ; WOODS, 2010). Permite detectar a periodicidade global (periódicos ou semi-periódicos) em uma imagem pela identificação de picos de alta energia no espectro. Possui três características importantes para a descrição de textura: (1) picos

existentes no espectro fornecem a direção principal dos padrões de textura; (2) A localização dos picos no plano de frequência fornece o período espacial fundamental dos padrões; (3) A eliminação de quaisquer componentes periódicos através de filtragem deixa os elementos não periódicos na imagem, que podem ser descritos por técnicas estatísticas (GONZALEZ; WOODS, 2010).

A detecção e interpretação das características do espectro mencionado anteriormente são usualmente simplificadas, expressando-se o espectro em coordenadas polares, sendo a função $S(r, \theta)$, onde S é uma função de espectro, e r e θ são variáveis nesse sistema de coordenadas. Para cada direção θ , $S(r, \theta)$ pode ser considerado uma função 1-D, $S_\theta(r)$. Da mesma forma, para cada frequência r , $S_r(\theta)$ é uma função 1-D. A análise de $S_\theta(r)$ para um valor fixo de θ provê o comportamento do espectro (como a presença de picos) ao longo de uma direção radial a partir da origem, enquanto a análise de $S_r(\theta)$ para um valor fixo de r fornece o comportamento ao longo de uma circunferência centrada na origem (GONZALEZ; WOODS, 2010).

Uma descrição global é obtida através das funções:

$$S(r) = \sum_{\theta=0}^{\pi} S_\theta(r) \quad (3.18)$$

$$S(\theta) = \sum_{r=1}^{R_0} S_r(\theta) \quad (3.19)$$

onde R_0 é o raio de circunferência centrada na origem. Os resultados das equações 3.18 e 3.19 constituem um par de valores $[S(r), S(\theta)]$ para cada par de coordenadas (r, θ) . Variando-se essas coordenadas, pode-se gerar funções unidimensionais $S(r)$ e $S(\theta)$ que compõem a descrições de energia espectral da textura para uma imagem ou região. Além disso, os descritores das próprias funções podem ser calculados para uma caracterização quantitativa. Os descritores usualmente utilizados para esse propósito são a posição do valor mais alto, a média e a variância da amplitude e as variações de eixo, e a distância entre a média e o maior valor da função (GONZALEZ; WOODS, 2010).

Figura 3.3 - (a) Uma imagem de uma textura periódica; (b) Espectro de Fourier correspondente; (c) O gráfico de $S(r)$; (d) O gráfico de $S(\theta)$. Fonte: Boaventura (2010).

A Figura 3.3 ilustra o uso das equações 3.18 e 3.19 para a descrição global de textura. A Figura 3.3(a) mostra uma imagem com uma textura periódica, enquanto a Figura 3.3(b) apresenta o espectro dessa imagem. A Figura 3.3(c) mostra o gráfico de $S(r)$ e a Figura 3.3(d) mostra o gráfico de $S(\theta)$. O gráfico de $S(r)$ possui uma estrutura típica com um conteúdo de alta energia perto da origem e progressivamente menor para as altas frequências. O gráfico de $S(\theta)$ mostra picos proeminentes em intervalos de 45° , correspondendo à periodicidade no conteúdo de textura da imagem.

3.2.4 Abordagem por micropadrões

De acordo com Vieira (2013) a abordagem por micropadrões locais permite analisar descritores de textura locais que modelam a imagem em relação às intensidades relativas entre os pixels em uma pequena vizinhança e não sobre os seus valores de intensidades absolutos. A primeira abordagem realizada em análise de textura local foi proposta por He e Wang (1990), introduzindo o método de *Texture Unit* (TU), onde as informações de textura são

extraídas de uma vizinhança de 3x3 de uma imagem original, convertida em nível de cinza, como pode ser observado na Figura 3.4 (a). A vizinhança 3x3 representa a menor unidade da imagem, possuindo oitos direções ao redor do pixel central. Os valores deste micro-padrão são divididos em três níveis a partir do pixel central, possibilitando gerar 3^8 (6561) códigos. Cada pixel de Vizinhança (V_i) adquire o valor (E_i), onde seu valor será '0' se estiver abaixo do valor do pixel central (V_0), senão adquire o valor '1' se for igual, ou '2' se estiver acima do valor do pixel central, como pode ser observado na Figura 3.4 (b). Uma unidade de textura para uma vizinhança é produzida multiplicando os valores limiarizados, como mostrado na Figura 3.4 (c) pelos dados dos pixels correspondentes, como se pode observar na Figura 3.4 (d), e posteriormente, somando-se o resultado (Figura 3.4 e), obtendo- o código TU pela Equação 3.20 que caracteriza um determinado micropadrão de imagem (VIEIRA, 2013).

Figura 3.4 - Ilustração do cálculo do *Texture Unit*. Fonte: Vieira (2013).

$$N_{tu} = \sum_{i=1}^8 E_i \cdot 3^{i-1} \quad (3.20)$$

A partir do histograma desta unidade chamada espectro de textura obtém-se uma descrição global da imagem, permitindo o espectro de textura ser usado diretamente para análise.

Posteriormente, Ojala, Pietikäinen, e Harwood (1996) propuseram o descritor *Local Binary Pattern* (LBP), baseado no algoritmo do *Texture Unit* (TU). Com este descritor uma imagem em tons de cinza é analisada, considerando uma vizinhança 3x3 ao redor do pixel central (Figura 3.5 a). Essa vizinhança é limiarizada pelo valor do pixel central gerando uma matriz com valores binários, podendo ser observado na Figura 3.5 (b), possibilitando gerar 2^8 (256) códigos. Cada pixel de vizinhança (V_i) adquire o valor (E_i), sendo o seu valor '0', se estiver abaixo do valor do pixel central (V_0), senão adquire o valor '1' se for igual ou maior do que o valor do pixel central, como pode ser observado na Figura 3.4 (c). Os valores dos pixels na vizinhança limiarizada são multiplicados por uma matriz de pesos (Figura 3.5 d). Realizando a soma desses valores, resulta no código LBP através da Equação 3.21, como pode ser observado na Figura 3.5(e) (VIEIRA, 2013).

$$N_{LBP} = \sum_{i=1}^8 E_i \cdot 2^{i-1} \quad (3.21)$$

Um histograma é gerado para determinar as ocorrências dos diferentes códigos LBP, formando o vetor de característica LBP, caracterizando uma imagem de textura.

Figura 3. 5 - Ilustração do cálculo do *Local Binary Pattern*. Fonte: Vieira (2013).

Em Ojala, Pietikäinen e Mäenpää (2002), os autores ampliaram a definição LBP para vizinhanças circulares do pixel, com o objetivo de torná-lo invariante à rotação, e a possibilidade de análise multi-escalar. É possível estipular a quantidade de vizinhos P a partir de um perímetro circular em qualquer escala R . A vizinhança é interpolada com espaçamento igual no círculo (VIEIRA, 2013).

Figura 3. 6 - Vizinhança circular de um pixel em multirresolução LBP.
Fonte: Ojala, Pietikäinen, Mäenpää (2002).

O número possível de padrões locais cresce se o número de vizinhos cresce, e dependendo da quantidade adotada, torna-se inviável para aplicações reais. Mäenpää et al.

(2000) sugeriram considerar apenas os padrões locais “uniformes” para os quais o número máximo de transições de *bits* do valor um para zero ou de zero para um é limitado. Considerando que alguns padrões locais representam na grande maioria, ao redor de 90% de todos os padrões locais da imagem, pode-se reduzir o número de códigos binários mantendo um bom desempenho. Por exemplo, o número de *bins* do histograma com LBP 8-*bits* é reduzido para 59 *bins*, em que os 58 *bins* são os padrões uniformes e o último *bin* contém a frequência de ocorrência de todos os outros.

O descritor LBP, por ser computacionalmente mais rápido que o método TU, tem sido aplicado nas mais diversas áreas, como por exemplo: reconhecimento facial (AMARAL; THOMAZ, 2012; NANNI; LUMINI; BRAHNAM, 2010; SHAN; GONG; McOWAN, 2009), classificação de textura (CHEN; TANG; FANGY, 2011), sensoriamento remoto (MUSCI, M.; FEITOSA, R. Q.; NOVACK. T., 2011), detecção e rastreamento de objetos, biometria, localização do olho e rastreamento do foco de atenção, inspeção visual, aplicações biomédicas, síntese de textura por vídeo, análise de vídeo entre outras aplicações citadas em Pietikäinen et al. (2011).

3.3. Conjuntos *Fuzzy* e números *Fuzzy*

A teoria de conjuntos *fuzzy*, foi proposta por Zadeh (1965), com o objetivo principal de dar um tratamento matemático a conceitos vagos e subjetivos existentes na comunicação humana, tais como “aproximadamente”, “em torno de”, que não podem ser tratados adequadamente pelos conjuntos convencionais (BOAVENTURA, 2010).

A lógica *fuzzy* permite a definição de valores intermediários tais como verdadeiro/falso, sim/não, alto/baixo, etc, sendo que estes valores podem ser matematicamente formulados e processados por computadores. A modelagem *fuzzy* considera o modo como a falta de exatidão e a incerteza são descritas e, dessa forma, torna-se suficientemente adequada para manipular de maneira conveniente o conhecimento (VIEIRA, 2013).

Nesta seção é apresentado um resumo da teoria básica de conjuntos e lógica *fuzzy*, destacando os tópicos de interesse para compreensão dos descritores de texturas utilizados no presente trabalho.

3.3.1. Conjuntos *Fuzzy*

Um conjunto *fuzzy*, é um conjunto que contém elementos que têm diferentes graus de pertinência ao conjunto (VIEIRA, 2013).

De acordo com Boaventura (2010) as definições dadas a seguir formalizam os conceitos da teoria dos conjuntos *fuzzy*.

Definição 1: Um conjunto *fuzzy* A é um subconjunto do conjunto universo X , sendo definido como um conjunto de pares ordenados, tal que:

$$A = \left\{ \left((x, \mu_A(x)) \mid x \in X \right) \right\} \quad (3.22)$$

onde $\mu_A(x)$ é a função de pertinência ou função característica do conjunto A . Determina o grau de pertinência (que varia entre 0 e 1) do elemento x , que pertence ao universo de discurso X , em relação ao conjunto *fuzzy* A , sendo definida por:

$$\mu_A(x): X \rightarrow [0, 1]; x \in X \quad (3.23)$$

A terminologia utilizada para denotar um conjunto *fuzzy* pode ser realizada de duas formas. Para o conjunto universo X , discreto e finito:

$$A = \left\{ \frac{\mu_A(x_1)}{x_1} + \frac{\mu_A(x_2)}{x_2} + \dots + \frac{\mu_A(x_n)}{x_n} \right\} = \left\{ \sum_{i=1}^N \frac{\mu_A(x_i)}{x_i} \right\} \quad (3.24)$$

onde, o símbolo de “+” não denota uma soma algébrica, mas uma concatenação.

E para o conjunto universo X , contínuo e infinito.

$$A = \left\{ \int_x \frac{\mu_A(x)}{x} \right\} \quad (3.25)$$

onde, o símbolo da integral representa a composição total do elemento de A .

Definição 2: O conjunto *fuzzy* A é normalizado se existe algum elemento $x \in X$ que possui o grau de pertinência igual a 1, ou seja $\mu_A(x) = 1$.

Definição 3: A altura de um conjunto *fuzzy* A , corresponde ao maior grau de pertinência assumido por um de seus elementos.

$$altura(A) = \max_{x_i \in X} \mu_A(x_i) \quad (3.26)$$

Definição 4: Seja A um subconjunto *fuzzy* do conjunto universo X . O suporte de A é o conjunto de X onde os elementos têm grau de pertinência não-nulos em relação a A :

$$suporte(A) = \{x \in X : \mu_A(x) > 0\} \quad (3.27)$$

Definição 5: Um conjunto *fuzzy* A é convexo se e somente se, for observada a seguinte desigualdade:

$$\mu_A(\lambda * x_1 + (1 - \lambda) * x_2) \geq \min(\mu_A(x_1); \mu_B(x_2)) \quad (3.28)$$

onde, $x_1, x_2 \in X$; $\lambda \in [0; 1]$.

Definição 6: Cardinalidade de um conjunto *fuzzy* A é a soma dos graus de pertinência de todos os elementos de A , os quais pertencem a um conjunto universo X .

$$cardinalidade(A) = \sum_{x \in X} \mu_A(x) \quad (3.29)$$

Definição 7: O α -corte em um conjunto *fuzzy* A é especificado por um conjunto *crisp*, que contém todos os elementos de A , pertencentes ao universo de discurso X , que possuem grau de pertinência maior ou igual a α .

$$A_\alpha = \{x \in X | \mu_A(x) \geq \alpha\} \quad (3.30)$$

3.3.2. Operadores *Fuzzy*

As operações básicas que são utilizadas em sistemas de lógica *fuzzy* são normalmente realizadas sobre suas respectivas funções de pertinências. As operações de união, interseção e complemento são definidas em função dos operadores *máximo* (*max*) e *mínimo* (*min*), os quais são análogos aos operadores produto e soma da álgebra elementar. Utilizando as funções *max* e *min* em dois conjuntos *fuzzy* A e B , definidos em um mesmo universo de discurso X , tem-se as seguintes definições (VIEIRA, 2013):

Definição 8: O conjunto união é formado por todos os valores máximos entre μ_A e μ_B , para todo $x \in X$, conforme a Equação 3.31.

$$\mu_A(x) \cup \mu_B(x) = \max(\mu_A(x), \mu_B(x)) \quad (3.31)$$

Definição 9: O conjunto interseção é formado por todos os valores mínimos entre μ_A e μ_B , para todo $x \in X$, ou seja:

$$\mu_A(x) \cap \mu_B(x) = \min(\mu_A(x), \mu_B(x)) \quad (3.32)$$

Definição 10: O conjunto complemento de conjunto *fuzzy* A normalizado, pertence ao conjunto universo X , e é formado pela subtração de $\mu_A(x)$ do valor unitário.

$$\overline{\mu_A(x)} = 1 - \mu_A(x) \quad (3.33)$$

3.3.3. Números *Fuzzy*

Os conjuntos *fuzzy* são formados por números *fuzzy*, determinados em um universo discreto ou contínuo, permitindo a quantificação da incerteza associada a uma informação (BARROS; BASSANEZI, 2006).

Definição 11: Um subconjunto *fuzzy* A é chamado de número *fuzzy* quando o conjunto universo no qual μ_A está definida, é conjunto dos números reais $\mathbb{R}$ e que satisfaz as seguintes condições (BARROS; BASSANEZI, 2006):

- i) Todos os α -cortes de A são não vazios, com $0 \leq \alpha \leq 1$;

- ii) Todos os α -cortes de A são intervalos fechados de $\mathbb{R}$.
- iii) $\text{suporte}(A) = \{x \in X : \mu_A(x) > 0\}$ é limitado .

A descrição de números *fuzzy* pode ser efetuada por meio do teorema da representação, onde qualquer conjunto *fuzzy* pode ser especificado por uma coleção de α -cortes. Dessa forma, para um número *fuzzy* A tem-se:

$$A = \bigcup_{0 \leq \alpha \leq 1} (\alpha A_\alpha) \quad (3.34)$$

onde A_α é o intervalo do universo de discurso em $\mu_A(x) \geq \alpha$. Logo, para um número *fuzzy* A , um α -corte em A pode ser representado por um par de valores $a_1^{(\alpha)}$ e $a_2^{(\alpha)}$ que representam o domínio de um α -corte em A . Assim, um α -corte em A produz o conjunto $A_\alpha = [a_1^{(\alpha)}, a_2^{(\alpha)}]$.

Os números *fuzzy* podem ser representados por funções parametrizadas, como triangular, trapezoidal, gaussiana e sigmoideal, cujas definições são dadas a seguir (SUMATHI; SUREKHA, 2010):

Definição 12: A função de pertinência triangular de um número *fuzzy* A é dada pela Equação 3.35:

$$\mu_A(x) = \begin{cases} 0, & \text{se } x \leq a \\ \frac{x-a}{m-a}, & \text{se } x \in [a, m] \\ \frac{b-x}{b-m}, & \text{se } x \in [m, b] \\ 0, & \text{se } x \geq b \end{cases} \quad (3.35)$$

O gráfico da função de pertinência de um número *fuzzy* triangular (Figura 3.7), possui a forma de um triângulo, com base $[a,b]$, e como único vértice fora da base o ponto $(m,1)$.

Figura 3. 7 - Gráfico da função de pertinência de um número *fuzzy* triangular. Fonte: Vieira (2013).

Definição 13: A função de pertinência trapezoidal de um número *fuzzy* A é dada pela Equação 3.36:

$$\mu_A(x) = \begin{cases} 0, & \text{se } x \leq a \\ \frac{x-a}{m-a}, & \text{se } x \in [a, m] \\ 1, & \text{se } x \in [m, n] \\ \frac{b-x}{b-n}, & \text{se } x \in [n, b] \\ 0, & \text{se } x \geq b \end{cases} \quad (3.36)$$

O gráfico da função de pertinência de um número *fuzzy* trapezoidal (Figura 3.8), possui a forma de um trapézio, com base menor no intervalo $[m,n]$, e com a base maior no intervalo $[a,b]$.

Figura 3. 8 - Gráfico da função de pertinência de um número *fuzzy* trapezoidal. Fonte: Vieira (2013).

Definição 14: A função de pertinência gaussiana de um número *fuzzy* A é dada pela Equação 3.37:

$$\mu_A(x) = e^{-\frac{(x-m)^2}{\sigma^2}} \quad (3.37)$$

Sendo σ o desvio padrão, o gráfico da função de pertinência de um número *fuzzy* gaussiano possui a forma de um sino, como pode ser observado na (Figura 3.9).

Figura 3. 9 - Gráfico da função de pertinência de um número *fuzzy* gaussiano. Fonte: Vieira (2013).

Definição 15: A função de pertinência sigmoidal de um número *fuzzy* é dada pela Equação 3.38:

$$\mu_A(x) = \frac{1}{1 - e^{-\frac{(x-m)}{\beta}}} \quad (3.38)$$

onde, β é a inclinação da curva sigmóide, que pode ser representada pela Figura 3.10.

Figura 3. 10 - Gráfico da função de pertinência de um número *fuzzy* sigmoidal. Fonte: Vieira (2013).

3.3.4. Operações com números *fuzzy*

Dado dois números *fuzzy* A e B , definidos num universo de discurso X , representados respectivamente pelas funções de pertinência $\mu_A(x)$ e $\mu_B(x)$. As operações de adição, subtração, multiplicação e subtração entre os números *fuzzy* são aplicadas sobre suas representações por α -cortes (BOAVENTURA, 2010).

b) Adição entre números *fuzzy*

$$A + B = \left[a_1^{(\alpha)}, a_2^{(\alpha)} \right] + \left[b_1^{(\alpha)}, b_2^{(\alpha)} \right] = \left[a_1^{(\alpha)} + b_1^{(\alpha)}, a_2^{(\alpha)} + b_2^{(\alpha)} \right] \quad (3.39)$$

c) Subtração entre números *fuzzy*

$$A - B = \left[a_1^{(\alpha)}, a_2^{(\alpha)} \right] - \left[b_1^{(\alpha)}, b_2^{(\alpha)} \right] = \left[a_1^{(\alpha)} - b_2^{(\alpha)}, a_2^{(\alpha)} - b_1^{(\alpha)} \right] \quad (3.40)$$

d) Multiplicação entre números *fuzzy*

$$A * B = \left[a_1^{(\alpha)}, a_2^{(\alpha)} \right] * \left[b_1^{(\alpha)}, b_2^{(\alpha)} \right] = \left[a_1^{(\alpha)} * b_1^{(\alpha)}, a_2^{(\alpha)} * b_2^{(\alpha)} \right] \quad (3.41)$$

e) Divisão entre números *fuzzy*

$$A \div B = \left[a_1^{(\alpha)}, a_2^{(\alpha)} \right] \div \left[b_1^{(\alpha)}, b_2^{(\alpha)} \right] = \left[a_1^{(\alpha)} \div b_2^{(\alpha)}, a_2^{(\alpha)} \div b_1^{(\alpha)} \right] \quad (3.42)$$

f) Mínimo entre números *fuzzy*

Sejam dois números *fuzzy* A e B , definidos num mesmo universo de discurso X . O mínimo entre estes dois valores é dado por:

$$\min(A, B) = \min \left([a_1^{(\alpha)}, a_2^{(\alpha)}], [b_1^{(\alpha)}, b_2^{(\alpha)}] \right) = (\min [a_1^{(\alpha)}, b_1^{(\alpha)}], \min [a_2^{(\alpha)}, b_2^{(\alpha)}])$$

(3.43)

g) Máximo entre números *fuzzy*

Sejam dois números *fuzzy* A e B , definidos num mesmo universo de discurso X . O máximo entre estes dois valores é dado por:

$$\max(A, B) = \max \left([a_1^{(\alpha)}, a_2^{(\alpha)}], [b_1^{(\alpha)}, b_2^{(\alpha)}] \right) = (\max [a_1^{(\alpha)}, b_1^{(\alpha)}], \max [a_2^{(\alpha)}, b_2^{(\alpha)}]) \quad (3.$$

44)

3.4. *Local Fuzzy Pattern*

Como mencionado na seção 3.2.4 o descritor LBP avalia uma vizinhança 3x3 ao redor do pixel central e utiliza valores *crisp* na comparação entre os pixels, o que implica numa perda do poder discriminatório e no aumento da sensibilidade a ruído, perdendo assim, a informação relacionada com a quantidade real da diferença entre os valores dos pixels. Uma possível solução para esses problemas é a utilização da lógica *fuzzy* na comparação entre os pixels, que possibilita representar as incertezas dos níveis de cinza dos pixels (VIEIRA, 2013). Dessa forma, posteriormente ao LBP, surgiram alguns trabalhos utilizando a lógica *fuzzy* aplicada na análise de textura, podendo citar como exemplo os trabalhos de Caponetti et al. (2006), Iakovidis, Keramidas e Maroulis (2008), Boaventura (2010), Vieira e Gonzaga (2013), Chierici et al. (2013).

O descritor *Local Fuzzy Pattern* (LFP), foi proposto por Vieira et al. (2012b) como um novo descritor para análise de micropadrões de imagens digitais baseado na lógica *fuzzy*. O diferencial desse descritor é que ao invés de utilizar regras *fuzzy* para se obter um código final que descreva um determinado padrão da imagem, como apresentado em artigos anteriores, são utilizados conjuntos *fuzzy* para tratar a vizinhança de pixels e um número *fuzzy* para tratar o nível de cinza de cada pixel. Como neste método não são utilizadas regras *fuzzy*, o seu custo computacional diminui.

A representação por números *fuzzy* é paramétrica e a definição de uma função de pertinência apropriada é heurística e não única. Assim, a definição de diferentes funções de

pertinência é baseada nas propriedades da vizinhança do micropadrão $W \times W$ do pixel central $g(i,j)$ em uma imagem digital. No LFP cada distribuição de níveis de cinza dentro desta vizinhança é um conjunto *fuzzy*, e uma função de pertinência é responsável diretamente pelo código LFP.

O grau de pertinência é determinado pela Equação (3.45), e pode ser visualizado na Figura 3.11 (a):

$$\hat{\mu}_{g(i,j)} = \frac{\sum_{k=1}^W \sum_{l=1}^W [f_{g(i,j)} P(k,l)]}{\sum_{k=1}^W \sum_{l=1}^W P(k,l)} \quad (3.45)$$

onde, $f_{g(i,j)}$ é a função de pertinência (Figura 3.11b), gerando os valores das pertinências em relação ao pixel central (Figura 3.11c) e $P(k,l)$ é uma matriz de pesos (Figura 3.11d) para a vizinhança $A(k,l)$ com a mesma dimensão $W \times W$.

Figura 3. 11 - Cálculo de pertinência do pixel central. (a) micropadrão ($W \times W$), (b) função de pertinência, (c) matriz das pertinências em relação ao pixel central, (d) matriz de pesos. Fonte: Vieira (2013).

O grau de pertinência $\hat{\mu}_{g(i,j)}$ do pixel central à região definida pela janela $W \times W$ é dado pela média ponderada dos valores de pertinência individuais de cada pixel, gerando o código LFP. A Figura 3.12 demonstra o cálculo do código LFP para uma função de pertinência sigmoidal.

Figura 3. 12 - Ilustração do cálculo do código LFP para uma função de pertinência sigmoidal. Fonte: Vieira (2013).

Vieira (2013) observou que usando a Equação 3.45 podem-se derivar algumas abordagens tradicionais publicadas para análise de micropadrões ao aplicar diferentes funções de pertinência e matriz de pesos.

Aplicando a função de pertinência dada pela Equação 3.46, o método *Texture Unit* (TU) proposto por He e Wang, (1990), pode ser derivado pela Equação 3.45.

$$f_{g(i,j)} = 1 + \text{sgn} [A(k,l) - g(i,j)] \quad (3.46)$$

em que,

$$\text{sgn}[A(k,l) - g(i,j)] = \begin{cases} -1, & \text{se } [A(k,l) - g(i,j)] < 0 \\ 0, & \text{se } [A(k,l) - g(i,j)] = 0 \\ 1, & \text{se } [A(k,l) - g(i,j)] > 0 \end{cases}$$

e a matriz de peso $P(k,l)$ é dado por:

$$P(k, l) = \begin{bmatrix} 1 & 3 & 9 \\ 2187 & 0 & 27 \\ 729 & 243 & 81 \end{bmatrix}$$

O descritor *Local Binary Pattern* (LBP) proposto por Ojala, Pietikäinen, Harwood (1996) pode ser derivado pela Equação (3.45) usando a função *crisp* como função degrau dada pela Equação (3.47).

$$f_{g(i,j)} = H[A(k, l) - g(i, j)] \quad (3.47)$$

onde,

$$H[A(k, l) - g(i, j)] = \begin{cases} 0, & \text{se } [A(k, l) - g(i, l)] < 0 \\ 1, & \text{se } [A(k, l) - g(i, l)] \geq 0 \end{cases}$$

Considerando o LBP com uma vizinhança de pixels de 3 x 3, sendo a matriz de peso:

$$P(k, l) = \begin{bmatrix} 1 & 2 & 4 \\ 128 & 0 & 8 \\ 64 & 32 & 16 \end{bmatrix}$$

O N_{LBP} pode ser obtido pela Equação (3.48):

$$N_{LBP} = \hat{\mu}_{g(i,j)} \sum_{K=1}^W \sum_{l=1}^W P(k, l) \quad (3.48)$$

O método LBP é um caso particular da abordagem do LFP.

No presente trabalho será utilizado o método LFP, avaliando-se as funções de pertinências sigmoidal, triangular e gaussiana

O descritor LFP de textura local com a função de pertinência sigmoidal, descrita pela Equação (3.49) é denominado de *Local Fuzzy Pattern-sigmoid* (LFP-s), e possibilita captar nuances que o descritor LBP não é capaz.

$$f_{g(i,j)} = \frac{1}{1 + e^{\frac{-[A(k,l)-g(i,j)]}{\beta}}}$$
(3.49)

Para o descritor LFP-s é adotado a matriz de pesos $P(k, l)$:

$$P(k, l) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Usando uma função de pertinência triangular e simétrica, descrita pela Equação (3.50), obtém-se o descritor LFP de textura local denominado *Local Fuzzy Pattern-triangular* (LFP-t):

$$f_{g(i,j)} = \max \left(0, 1 - \frac{|g(i,j) - A(k,l)|}{\delta} \right)$$
(3.50)

onde, $A(k,l)$ são os pixels na vizinhança $W \times W$ e δ é o espalhamento de número fuzzy e a matriz de pesos $P(k, l)$ é da forma:

$$P(k, l) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

O descritor de textura local LFP com a função de pertinência gaussiana, descrita pela Equação (3.51) é denominado *Local Fuzzy Pattern - gaussian* (LFP-g):

$$f_{g(i,j)} = e^{\frac{-[A(k,l)-g(i,j)]^2}{\sigma}}$$
(3.51)

onde, σ é o desvio padrão, e a matriz de pesos $P(k, l)$ é da forma:

$$P(k, l) = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Como os descritores LFP-s, o LFP-t e o LFP-g geram valores no intervalo $[0,1]$, é necessário convertê-los para um esquema de nível de cinza de 8-bit, sendo que cada valor do grau de pertinência é multiplicado por 255 e arredondado no resultado final. Assim os histogramas LFP-s, LFP-t e LFP-g tem 256 *bins*, ou seja, valores inteiros entre 0 e 255.

3.5. Redes neurais artificiais

As redes neurais artificiais (RNA), são modelos computacionais inspirados no sistema nervoso de seres vivos. As RNA são compostas por unidades de processamento, caracterizados por neurônios artificiais, que tem a capacidade natural de aquisição e indução do conhecimento por meio da experiência, tornando-o similar ao mecanismo básico do cérebro humano (SILVA; SPATTI e FLAUZINO, 2010).

Os neurônios artificiais, proposto por Warren McCulloch e Water Pitts em 1943, são modelos simplificados dos neurônios biológicos e são interligados por interconexões (sinapses artificiais), sendo representados por vetores ou matrizes de pesos sinápticos.

No modelo de um neurônio artificial, ilustrado pela Figura 3.13, os sinais de entrada são representados pelo conjunto $\{X_1, X_2, \dots, X_n\}$, os pesos sinápticos $\{W_1, W_2, \dots, W_n\}$ irão ponderar cada uma das variáveis de entrada da rede. O limiar de ativação $\{\theta\}$ é uma variável que irá gerar um valor de disparo em direção à saída do neurônio. O combinador linear $\{\Sigma\}$ representa a função de agregador de todos os sinais que foram ponderados. O potencial de ativação $\{u\}$ representa o resultado da diferença entre o combinador linear e o limiar de ativação. A função de ativação $\{g(u)\}$ permite restringir a saída do neurônio dentro de um intervalo de valores. O sinal de saída $\{y\}$ representa o valor de saída produzido pelo neurônio em relação a um determinado conjunto de entrada.

Figura 3. 13 - Neurônio artificial.

A arquitetura de uma RNA define a forma como os seus neurônios são dispostos uns em relação aos outros. A topologia de RNA é definida pelo número de camadas, quantidade de neurônios nas camadas e pelo tipo de conexão entre neurônios (SILVA; SPATTI e FLAUZINO, 2010).

O algoritmo de aprendizagem consiste no treinamento de uma arquitetura específica, aplicando um conjunto de passos ordenados, com o intuito de ajustar os pesos e os limiares de seus neurônios. Após a rede ter aprendido, ela será capaz de produzir uma saída próxima daquela desejada.

O processo de treinamento pode ser dividido em duas estratégias: o treinamento supervisionado e o não supervisionado.

O treinamento supervisionado consiste em cada amostra de treinamento ser composta por sinais de entrada e suas correspondentes saídas, ensinando para a rede qual a resposta correta para cada amostra apresentada em suas entradas.

No treinamento não supervisionado não existem saídas desejadas, sendo que a rede se auto-organiza, identificando os subconjuntos similares.

A forma como os neurônios estão organizados está ligada ao tipo de problema que será solucionado. As principais arquiteturas de RNA podem ser: *feedforward* de única camada, *feedforward* de múltiplas camadas, redes recorrentes, e redes reticuladas.

A aplicabilidade das diferentes teorias e arquiteturas existentes em RNA depende do problema proposto. Dentre os vários tipos de RNA, a rede PMC é uma das soluções mais clássicas para problemas de classificação, permitindo resolver problemas não linearmente separáveis.

As RNA PMC são caracterizadas pela presença de pelo menos de uma camada intermediária (escondida) de neurônios, situada entre a camada de entrada e a respectiva

camada neural de saída. Cada uma das entradas da rede é propagada para cada neurônio um a um em direção à camada neural de saída (SILVA; SPATTI e FLAUZINO, 2010).

A camada de entrada é composta por n sinais, e recebe o dado do meio externo; as camadas intermediárias ou escondidas são constituídas de n_1 e n_2 neurônios, e são responsáveis por extrair as características associadas ao processo. A camada de saída é composta de m neurônios que apresentam o valor de saída, como pode ser observado na Figura 3.14.

Figura 3. 14 - Neural Artificial *Perceptron* Multicamada. Fonte: Silva; Spatti e Flauzino,(2010).

A RNA PMC (Figura 3.14) pertence à arquitetura *feedforward* de múltiplas camadas cujo treinamento é realizado de forma supervisionada. O fluxo de informações inicia-se na camada de entrada e percorre as camadas intermediárias e finaliza na camada neural de saída. Não existe alimentação de valores produzidos pela camada neural de saída ou pelas camadas neurais intermediárias.

As redes PMC com o algoritmo de aprendizagem *backpropagation*, (Figura 3.15) permite utilizar os dados de treinamento para ajustar os pesos sinápticos da RNA por um mecanismo de correção de erros. O treinamento desta rede é realizado de forma supervisionada, mediante uma sequência de dois passos. No primeiro passo, denominado de *forward*, uma amostra do sinal é aplicada à camada de entrada da rede e as informações são propagadas camada a camada até que uma resposta seja produzida pela camada de saída. Em seguida, no segundo passo *backward*, as respostas produzidas pela camada de saída são comparadas com as respostas desejadas, o erro é calculado, e propagado de volta, permitindo

ajuste dos pesos e limiares de todos os neurônios em cada iteração (SILVA; SPATTI e FLAUZINO, 2010).

Figura 3. 15 - Neural artificial *perceptron* multicamada com o algoritmo *backpropagation*. Fonte: Silva; Spatti e Flauzino (2010).

O objetivo do processo de treinamento consiste em ajustar a matriz de pesos a fim de minimizar o erro quadrático médio. Este ajuste é realizado no passo *backward*, que altera os pesos utilizando a saída fornecida pelo passo *forward*.

Outra forma de aumentar a velocidade de convergência da RNA treinada pelo algoritmo *backpropagation* é a inclusão de um termo denominado *momentum*, visando ponderar o quão as matrizes sinápticas foram alteradas entre duas iterações anteriores e sucessivas e é definido pela Equação 3.54 (MUELEER, 1996).

$$\Delta W_{ji}^{(L)} = \eta \cdot \delta_j^{(L)} \cdot y_i^{(L-1)} + \alpha \cdot (W_{ji}^{(L)}(t) - W_{ji}^{(L)}(t-1)) \quad (3.52)$$

onde, $W_{ji}^{(L)}$: matriz de pesos do j -ésimo neurônio da camada L , $y_j^{(L)}$ é o valor produzido pelo j -ésimo neurônio de saída. O parâmetro η representa a taxa de aprendizagem. O parâmetro $\delta_j^{(L)}$ representa o gradiente local em relação ao j -ésimo neurônio da camada de saída. O parâmetro α representa o termo *momentum*, $0 < \alpha < 1$.

O treinamento desta rede é finalizado quando o erro quadrático médio entre duas épocas sucessivas for menor que o erro estipulado ou quando um determinado número de ciclos for realizado.

Assumindo um conjunto de treinamento composto por p amostras, a medição da evolução do desempenho global do algoritmo *backpropagation* pode ser efetuada por meio da avaliação do erro quadrático médio, que é dado pela Equação (3.53) (SILVA; SPATTI e FLAUZINO, 2010).

$$E_M = \frac{1}{p} \sum_{K=1}^p E(K) \quad (3.53)$$

sendo, $E(K)$ o erro quadrático obtido pela Equação 3.54

$$E(K) = \frac{1}{2} \sum_{j=1}^{n3} (d_j(K) - Y_j^{(3)}(K))^2 \quad (3.54)$$

onde, $Y_j^{(3)}(K)$ é o valor produzido pelo j -ésimo neurônio de saída da rede considerando-se a k -ésima amostra de treinamento, enquanto que $d_j(K)$ é o seu respectivo valor desejado.

3.6. Modelo de Cor RGB

A visão humana possui sensores na retina do olho para recepção da luz, chamados cones e bastonetes. Os cones são responsáveis pela sensibilidade da cor e os bastonetes em sua maioria, são sensíveis a baixos níveis de iluminação e servem para gerar uma imagem geral do campo de visão. A cor é captada por estes sensores através de estímulos do cérebro, que são transmitidos na forma de impulsos elétricos gerados pela retina humana. As cores percebidas pelo ser humano encontram-se na faixa do espectro eletromagnético compreendida entre 380 nm a 770 nm (JORGE, 2001).

A cor possibilita ao ser humano diferenciar, identificar e extrair característica de objetos ou estruturas com a variação de medidas perceptíveis como a luminância, saturação e

tonalidade, permitindo que cada indivíduo agrupe e separe as cores através das noções psicológicas e exemplos prévios.

Em processamento de imagens a cor é um poderoso descritor que muitas vezes simplifica a identificação do objeto e sua extração de uma cena. (GONZALEZ, WOODS, 2010).

Para a representação computacional da cor é necessário um modelo de cor, que facilite a representação das cores em alguma forma padronizada. São vários os modelos de cores encontrados na literatura, podendo-se citar o RGB, HSI, CMY, CMYK, entre outros.

O modelo de cor RGB baseia-se nas cores primárias vermelho (R, *red*), verde (G, *green*) e azul (B, *blue*), absorvida da luz pelos cones do olho humano. Este sistema é representado por coordenadas cartesianas, de forma que os valores RGB primários estão em três vértices, as cores secundárias (ciano, magenta e amarelo) estão em outros três vértices, a cor preta está localizada na origem, e o branco está no vértice mais distante do preto, como pode ser observado na Figura 3.16 (MARQUES FILHO, 1999). Nesse modelo o subespaço de cores de interesse é o cubo e a escala de cinza (pontos de valores RGB iguais) estende -se do preto até o branco ao longo do segmento de reta que une esses dois pontos (GONZALEZ, WOODS, 2010).

Figura 3. 16 - Esquema de cubo de cores RBG. Fonte: Marques Filho (1999).

Imagens representadas no modelo de cores RGB consiste de três componentes de imagens, uma para cada cor primária.

3.7. Considerações finais

Neste capítulo foram apresentados os fundamentos teóricos necessários para o desenvolvimento do presente trabalho. Foi apresentado um resumo dos descritores de análise de textura local, *Texture Unit* (TU), *Local Binary Pattern* (LBP) e o novo descritor proposto por Vieira et al. (2013) *Local Fuzzy Pattern* (LFP) que utiliza a teoria dos conjuntos *fuzzy* e números *fuzzy* em sua análise. Os descritores LBP e LFP são utilizados no presente trabalho.

Capítulo 4

Metodologia

4.1. Considerações Iniciais

Este capítulo apresenta uma visão geral do trabalho, seguida pela descrição da aquisição e construção do banco de imagens de folhas de citros. Nas seções seguintes são descritas duas metodologias para analisar as imagens digitalizadas de folhas cítricas, uma utilizando RNA PMC e outra por descritores de textura.

4.2. Visão Geral do Trabalho

Este trabalho tem por objetivo propor um método que auxilie na diferenciação do *greening* de outras doenças similares, contribuindo como um recurso adicional para a estimativa desta doença. Para isso foram avaliadas duas metodologias para a análise das imagens digitalizadas de citros, ilustradas nas Figura 4.1 e Figura 4.2.

Conforme mostrado na Figura 4.1 a primeira metodologia realiza a análise por cor utilizando uma RNA PMC, e está dividida nas seguintes etapas de desenvolvimento:

1. Pré-processamento das imagens
2. Treinamento da RNA PMC com base nas amostras adquiridas de doenças
3. Segmentação por cor
4. Divisão da folha em quadrantes

Figura 4. 1 - Diagrama de desenvolvimento do trabalho para a primeira metodologia.

A segunda metodologia realiza a análise por descritores de textura, e suas etapas, ilustradas na Figura 4.2, são as seguintes:

1. Extração das amostras.
2. Aplicação dos descritores de textura local LBP e LFP, e dos descritores de Haralick.
3. Cálculo da sensibilidade e classificação das classes de doenças pelos descritores LBP e LFP.
4. Extração dos histogramas do descritor LBP e LFP
5. Classificação das classes de doenças utilizando os algoritmos IBK e RNA PMC.

Nas seções seguintes todas as etapas das duas metodologias serão detalhadas.

Figura 4. 2 - Diagrama de desenvolvimento do trabalho para a segunda metodologia.

4.3. Aquisição das Imagens Foliares

A empresa do grupo Fischer (FISCHER, 2010), forneceu 324 amostras, divididas em seis tipos de folhas de citros com sintomas de doenças e deficiência nutricional, contendo 54 amostras para cada tipo de doença (*greening*, CVC e rubelose) e deficiência nutricional (manganês, magnésio e zinco) conforme foi apresentado na seção 2.2, Figura 2.3.

Estas amostras foram selecionadas por um técnico agrônomo, que identificou os sintomas, apenas por meio da inspeção visual, segundo instruções do manual técnico do *greening*, fornecido pela Fundecitrus (FUNDECITRUS, 2009a).

As folhas de citros foram digitalizadas por um *scanner* de mesa, modelo SCANNER HP SCANJET G4050, com diferentes resoluções, e diferentes dimensões, no modelo de cores RGB, utilizando a parte frontal da folha. Para evitar o cálculo de porcentagem de área foliar incorreta foi retirado o caule das folhas e estas foram rotacionadas, com o caule direcionado para o lado esquerdo e a ponta da folha no lado direito, para manter o mesmo padrão de análise.

Foram construídos três bancos de imagens de folhas de citros que serão descritos a seguir.

- **Banco 1:** foram digitalizadas 324 folhas de citros com resolução de 100 DPI, e com dimensão de 400 x 200 pixels das imagens originais em RGB, contendo 54 amostras para cada tipo de doença (*greening*, CVC e rubelose) e deficiência nutricional (manganês, magnésio e zinco).
- **Banco 2:** foram selecionadas e digitalizadas as 150 melhores folhas de citros, sem deformidades geométricas, com resolução de 100 DPI, e dimensão de 400 x 200 pixels das imagens originais em níveis de cinza, contendo 25 amostras para cada tipo de doença (*greening*, CVC e rubelose) e deficiência nutricional (manganês, magnésio e zinco).
- **Banco 3:** foram selecionadas e digitalizadas as 120 melhores folhas de citros (apêndice B), sem deformidades geométricas, com resolução de 300 DPI, e dimensão de 3000 x 1800 pixels das imagens originais em RGB, contendo 20 amostras para cada tipo de doença (*greening*, CVC e rubelose) e deficiência nutricional (manganês, magnésio e zinco).

4.4. Metodologia utilizando RNA PMC

Esta metodologia realiza a análise por cor utilizando uma RNA PMC, nas imagens digitalizadas do banco 1, e está dividida nas etapas de desenvolvimento descritas nas seções abaixo.

4.4.1. Pré-Processamento das Imagens

Inicialmente foi utilizado o método de Otsu, (OTSU, 1979) para a binarização das imagens de forma automática permitindo encontrar o contorno da folha, usando um algoritmo que varre toda a imagem, verificando o limiar da cor preta para branca, e armazenando em um vetor os pontos do contorno da folha. Em seguida o contorno é desenhado sobre a imagem original, sendo utilizado na etapa seguinte como um delimitador, para especificar que somente

os pixels da folha (sem o fundo) são usados como entrada para a RNA. A Figura 4.3 apresenta a imagem original na qual foi sobreposto o contorno.

Figura 4. 3 - Segmentação do objeto de interesse.

4.4.2. Rede Neural Artificial

Neste trabalho foi utilizada uma RNA do tipo *Perceptron* multicamada (PMC) com o algoritmo *backpropagation*, da API do *toolbox* Weka, com o objetivo de realizar a segmentação da imagem por cor. Essa metodologia baseou-se nos trabalhos de Simões e Costa (2003), Pereira Neto, Jorge e Guimarães (2005), Cavani et al. (2006), Sartori (2006), Huang (2007) e Venâncio (2010).

Para a RNA PMC foram utilizadas três entradas, nas quais foram aplicadas as componentes de cor RGB de cada pixel das cores selecionadas para a saída.

Foram utilizados cinco neurônios na saída, classificados em quatro classes de cores (verde escuro, verde claro, amarelo e marrom) e mais o fundo, representando a clorose para a cor amarela, a folha em si para a cor verde escuro e verde claro, e as necroses ou lesões para a cor marrom. A cor de fundo é utilizada caso a folha apresente algum buraco. As classes de cores foram definidas, selecionando manualmente os pixels da região da imagem pertencente à classe em questão, indicando o valor da saída a ser treinada, ilustrado pela Figura (4.4).

Figura 4. 4 - Exemplificação da seleção das componentes RGB. Em (a) a seleção da cor verde escuro, em (b) a seleção da cor verde claro, em (c) a seleção da cor amarelo, em (d) a seleção da cor marrom e em (e) a seleção da cor de fundo.

Para definir o número de camadas intermediárias, foram realizados testes iniciais variando a taxa de aprendizado $\{\eta\}$, o momentum $\{\alpha\}$ e o número de camadas escondidas, com o objetivo de verificar os valores do erro quadrático médio (EQM) e a porcentagem de classificação. Foram mantidos o mesmo valor de época (500), validação cruzada com 10 *folds* e função de ativação sigmóide em todos os testes.

As Tabelas 4.1, 4.2 e 4.3 apresentam os resultados dos treinamentos para cada tipo de configuração topológica.

Tabela 4. 1 – Tabela com uma camada escondida.

1 camada escondida			
η	α	EQM (%)	Precisão (%)
0,3	0,2	27,63	74,38
0,7	0,3	27,61	74,58
0,9	0,1	27,62	75,26

Tabela 4. 2 – Tabela com duas camadas escondidas.

2 camadas escondidas			
η	α	EQM (%)	Precisão (%)
0,3	0,2	16,86	90,36
0,7	0,3	17,61	90,38
0,9	0,1	17,09	90,28

Tabela 4. 3 – Tabela com três camadas escondidas.

3 camadas escondidas			
η	α	EQM (%)	Precisão (%)
0,3	0,2	16	89,85
0,7	0,3	16,41	90,42
0,9	0,1	16,42	90,4

Ao analisar os resultados das Tabelas 4.1, 4.2 e 4.3, observa-se que as configurações de rede neural com duas e com três camadas apresentaram melhor classificação em relação à configuração com uma camada. A Tabela 4.2 com duas camadas apresentou 90,38 % de precisão, e a Tabela 4.3 com 3 camadas apresentou 90,42% de precisão, havendo apenas uma pequena diferença nos resultados da precisão. Estes resultados levam à conclusão que se pode utilizar a configuração de duas ou três camadas escondidas.

Com base nos resultados apresentados na Tabela 4.3 foi escolhida a configuração de três camadas escondidas, por apresentar o menor EQM de 16%, ficando a topologia da rede da seguinte forma: uma camada de entrada (três entradas), três camadas escondidas e uma camada de saída com cinco neurônios (verde escuro, verde claro, amarelo, marrom e fundo). Os parâmetros adotados foram: 0,3 para a taxa de aprendizado, 0,2 para o momento e 500 para a quantidade de épocas. Foi utilizado o esquema de validação cruzada com 10 *folds* e função de ativação sigmóide.

Para o treinamento da rede foram aplicadas em suas entradas as informações RGB dos pixels de toda a imagem, incluindo o fundo. Foram utilizadas 80% das instâncias (4259) e os 20% restantes (1065) foram usadas para testes. A rede foi treinada para cada classe de cor.

Para os testes, foram aplicadas nas entradas da RNA somente as informações referentes à folha, delimitada pelo contorno. Para que a segmentação fosse visualizada, foram atribuídas pseudocores para representar cada padrão, sendo amarelo para clorose, verde escuro e verde claro para folha sadia e marrom para as necroses ou lesões.

4.4.3. Segmentação por Cor

A segmentação por cor foi utilizada para separar as manchas amarelas do fundo verde e verde escuro das folhas e de áreas com alguma necrose, caracterizada pela cor marrom, utilizando-se para isto, a RNA PMC da seção 4.4.2. A Figura 4.5 ilustra o resultado obtido com a segmentação.

(a) Imagem original de folha com *greening*

(b) Imagem segmentada da folha com *greening*

(c) Imagem original de folha com Clorose Variegada dos Citros (CVC)

(d) Imagem segmentada da folha com Clorose Variegada dos Citros (CVC)

(e) Imagem original de folha com deficiência de magnésio

(f) Imagem segmentada da folha com deficiência de magnésio

(g) Imagem original de folha com Deficiência de Manganês

(h) Imagem segmentada da folha com Deficiência de Manganês

(i) Imagem original de folha com deficiência de zinco

(j) Imagem segmentada da folha com deficiência de zinco

Figura 4.5 - Amostras das imagens segmentadas.

4.4.4. Divisão da Folha em Quadrantes

Devido às manchas de *greening* apresentarem a cor amarela distribuída assimetricamente, conforme mencionado na seção 2.2, foi realizada a divisão da folha em quadrantes para se determinar a porcentagem de cada cor utilizada em cada quadrante.

Para a divisão da folha em quadrantes, foi determinado o centro de massa na coordenadas (xCM, yCM) e os pontos delimitadores do momento central (α_{min} , α_{max} , β_{min} e β_{max}), conforme apresentado na Figura 4.6.

Figura 4.6 - Imagem segmentada em quadrantes.

O cálculo do centro de massa em relação a uma região R é dado pela Equação 4.1 e 4.2 (JAIN, 1989).

$$x_{CM} = \frac{1}{N_t} \sum_{i=0}^{x-1} X_i \quad (4.1)$$

$$y_{CM} = \frac{1}{N_t} \sum_{i=0}^{Y-1} Y_i \quad (4.2)$$

O parâmetro N_t é o número total de pixels dentro da região de interesse da coordenada (x,y).

Para o cálculo dos pontos delimitadores do momento central (α_{min} , α_{max} , β_{min} e β_{max}), inicialmente calcula-se os valores de $\mu_{p,q}$ (momentos centrais) pela Equação 4.3, variando-se (p,q) entre [0, 2], e o valor de θ_{CM} (ângulo do momento central) dado pela Equação 4.4 (JAIN, 1989).

$$\mu_{p,q} = \sum_{i=0}^{X-1} \sum_{j=0}^{Y-1} (X_i - x_{CM})^p (Y_j - y_{CM})^q \quad (4.3)$$

$$\theta_{CM} = \frac{1}{2} \tan^{-1} \left[\frac{2\mu_{1,1}}{\mu_{2,0} - \mu_{0,2}} \right] \quad (4.4)$$

$$\alpha_b = X \cos \theta_{CM} + Y \sin \theta_{CM} \quad (4.5)$$

$$\beta_b = -X \sin \theta_{CM} + Y \cos \theta_{CM} \quad (4.6)$$

Determinado o θ_{CM} , usam-se as Equações 4.5 e 4.6 para encontrar os dois pontos de mínimos e de máximos das coordenadas (X, Y) da imagem, ficando assim definidos os quatro pontos delimitadores do momento central (α_{min} , α_{max} , β_{min} e β_{max}), permitindo assim dividir a imagem em quadrantes.

A Figura 4.7 apresenta um exemplo de imagem segmentada com CVC, dividida em quadrantes, e a Tabela 4.4 mostra os valores de porcentagem de cor para cada quadrante.

Figura 4. 7 - (a) Imagem da folha 05 com CVC, (b) Imagem da folha segmentada em quadrantes.

Tabela 4. 4 - Tabela com os resultados da classificação por RNA (por quadrante) para o CVC.

Tabela com resultado da segmentação por cor				
Quadrante-Folha	Verde escuro (%)	Verde claro (%)	Amarelo (%)	Marrom (%)
1Q-Folha05	0,518	93,895	2,931	2,656
2Q-Folha05	2,801	94,013	1,675	1,511
3Q-Folha05	7,453	90,278	1,189	1,080
4Q-Folha05	6,023	75,251	11,603	7,123

O apêndice A contém todas as tabelas com os valores da classificação RNA PMC para cada quadrante, para cada folha do banco1.

4.5. Metodologia utilizando descritores de textura

Esta metodologia realiza a análise por descritores de textura, utilizando os bancos 2 e 3 de imagens de digitalizadas e suas etapas são descritas nas seções seguintes.

4.5.1. Extração das amostras

A aplicação dos descritores de textura é realizada em amostras extraídas de cada folha. Com objetivo de verificar a influência do número de amostras por classe de doença, foram extraídas 2 amostras, 5 amostras, 10 amostras, 20 amostras por folha nos tamanhos: 30 x 30 pixels, 100 x 100 pixels, 200 x 200 pixels e 300 x 300 pixels.

Foram avaliados grupos de 5 folhas, 10 folhas, 20 folhas e 25 folhas para cada classe de doenças, considerando as melhores folhas sem deformidades geométricas (folhas que não apresentem buracos e imperfeições).

As amostras extraídas foram analisadas por duas abordagens. A primeira em relação à extração por número de amostras por folha (Figura 4.8 a) e segunda por número de amostras extraídas por quadrante por folha (Figura 4.8 b).

Figura 4. 8 – Exemplo de amostras extraídas por uma imagem de folha de citros, em (a) extração da amostra por folha e (b) extração da amostra por quadrante.

Com a primeira metodologia (apêndice A) e em Ribeiro, Paiva e Jorge (2011), mostrou que as cores segmentadas influenciam na diferenciação das doenças, para a segunda metodologia as amostras foram extraídas nos canais de cores vermelho e verde e em níveis de cinza, conforme ilustrado na Figura 4.9.

Usando o Matlab (MATLAB, 2014) as amostras foram recortadas manualmente, selecionando as áreas com manchas que caracterizam as doenças, gerando novas imagens recortadas nos canais de cores vermelho e verde (apêndice D), e em níveis de cinza usando a função *rgb2gray*.

Figura 4. 9 – Exemplo de amostras extraídas por uma imagem de folha de citros, nos canais de cores vermelho, verde e nível de cinza.

4.5.2. Aplicação dos descritores de textura local LBP e LFP, e dos descritores de Haralick

Nesta fase foi aplicado o descritor LBP (OJALA, PIETIKÄINEN, e HARWOOD, 1996), e o descritor LFP (VIEIRA et al., 2013), conforme descrito na seções 3.2.4 e 3.4.

Foram aplicados também os descritores de Haralick., conforme descritos na seção 3.2.2, utilizando a função Haralick do programa Matlab (MATLAB, 2014) que se encontra no apêndice C.

Os resultados da aplicação dos descritores de Haralick, foram armazenados em arquivo com extensão “arff” para mineração de dados, utilizando o *toolbox* Weka, para classificar os dados obtidos das amostras extraídas para cada classe de doença.

4.5.3. Cálculo da sensibilidade e classificação das classes de doenças pelo descritores LBP e LFP

O processo de classificação utilizado pelo descritor LFP com as funções de pertinências (sigmóide, triangular e gaussiana) e pelo descritor LBP, foi a métrica χ^2 (chi-quadrado), dada pela Equação (4.7).

$$\chi^2 (P_i, Q_i) = \frac{1}{2} \sum_{i=0}^{255} \frac{(P_i - Q_i)^2}{(P_i + Q_i)} \quad (4.7)$$

onde, Q_i é a frequência do nível de cinza da amostra que está sendo avaliada e P_i é a frequência do nível de cinza da amostra do conjunto, a qual está sendo comparada com a amostra avaliada. Utilizando validação cruzada *leave-one-out*, foram comparados os histogramas gerados para cada amostra com o restante das amostras do conjunto (VIEIRA, 2013).

As amostras são comparadas e classificadas numa mesma classe, quando se obtém a menor distância χ^2 entre as demais amostras da mesma classe. O processo de classificação é ilustrado na Figura (4.10).

Figura 4. 10 - Ilustração do processo de classificação. Fonte: Vieira (2013).

Os resultados da classificação são armazenados em uma matriz de confusão, como pode ser visto um exemplo na Tabela 4.5. O cálculo da sensibilidade (S) é dado pela Equação (4.8) e um exemplo é apresentado na Tabela 4.6:

$$S = \frac{VP}{VP + FN} \quad (4.8)$$

onde, VP são os verdadeiros positivos e FN os falsos negativos.

Tabela 4. 5 – Tabela com a matriz de confusão do descritor LBP do primeiro quadrante.

Tabela com a matriz confusão do LBP						
	CVC	Greening	Magnésio	Manganês	Rubelose	Zinco
CVC	420	0	1	1	1	2
Greening	0	420	1	1	2	3
Magnésio	0	0	416	0	8	6
Manganês	0	0	0	407	2	1
Rubelose	0	0	1	5	406	5
Zinco	0	0	1	6	1	403

Na tabela 4.5 foram extraídas sete amostras por quadrante, com o tamanho 300 x 300 pixels das imagens do banco 3.

Como pode ser observado na Tabela 4.5 o resultado da sensibilidade para o descritor LBP foi 98,1%, de acordo com a Equação 4.8, sendo que os valores verdadeiros positivos ficam na posição diagonal com o valor de 420 amostras classificadas corretamente para uma determinada classe.

Tabela 4. 6 – Tabela com a sensibilidade média calculada para cada classe de doença para o primeiro quadrante.

Tabela de sensibilidade por classe de doença	
LBP_1Q	Sensibilidade (%)
CVC	100,00
<i>Greening</i>	100,00
Magnésio	99,05
Manganês	96,91
Rubelose	96,67
Zinco	95,95

A Tabela 4.6 apresenta uma média das sensibilidades obtidas para o primeiro quadrante.

4.5.4. Extração dos histogramas dos descritores LBP e LFP

Os resultados obtidos após a aplicação dos descritores LBP e LFP são avaliados, e os histogramas correspondentes são gerados e salvos para cada amostra analisada, sendo gerado para cada amostra de doença um histograma, como pode ser ilustrado na Figura 4.11. Cada linha do histograma foi separada como atributos e salvos em um arquivo com extensão “arff” para serem posteriormente avaliados pelos classificadores do *toolbox* Weka.

Figura 4. 11 - Histograma do LBP para uma amostra.

4.5.5. Classificação das classes de doenças utilizando os algoritmos IBK e RNA PMC.

Além da classificação realizada com a métrica χ^2 da seção 4.5.3, foi realizada outra classificação utilizando os histogramas gerados conforme mencionados na seção 4.5.4, com os algoritmos IBK e RNA PMC do *toolbox* Weka. Os resultados obtidos foram comparados com os resultados anteriores da seção 4.5.3.

Os resultados obtidos pelos descritores de Haralick foram também armazenados como atributos e classificados utilizando os algoritmos IBK e RNA PMC pelo *toolbox* Weka para comparação de resultados.

4.6. Ferramentas utilizadas

Para o desenvolvimento do trabalho, foram utilizadas as seguintes ferramentas:

- Metodologia utilizando RNA PMC

Foi desenvolvido um *software* em linguagem *Java* (JAVA, 2010) no ambiente de desenvolvimento integrado *Netbeans* (NETBEANS, 2010), e com o uso da API

(*Application Programming Interface*) do *toolbox Weka* versão 3.6.4 (WEKA, 2011) para o treinamento e classificação da RNA PMC. Para o processamento das imagens utilizou-se a biblioteca *Imagem*, desenvolvida no laboratório de imagens e modelamento da Embrapa Instrumentação, a biblioteca *ImageJ* (IMAGEJ, 2011), a API da *Jai* (*Java Advanced Imaging*) (JAI, 2011), a API da *Jxl* (*Java Excel*) para gerar as tabelas com o resultado em Excel (JXL, 2011).

- Metodologia utilizando descritores de textura

As amostras foram processadas utilizando o Matlab versão 7.6.0 R2008a (MATLAB, 2014) e o *toolbox Weka* versão 3.7.10 (WEKA, 2011).

4.7. Considerações finais

Neste capítulo foram apresentas duas metodologias. A primeira metodologia utilizando segmentação por cor com RNA PMC e a segunda metodologia utilizando os descritores de textura (LBP e LFP e descritores de Haralick). Nesta última os resultados dos descritores foram avaliados pela métrica χ^2 , utilizada por Vieira (2013) e pelos algoritmos IBK e RNA PMC do *toolbox Weka*.

No próximo capítulo serão exibidos e discutidos os resultados obtidos para cada descritor.

Capítulo 5

Resultados e Discussões

5.1. Considerações Iniciais

Neste capítulo são apresentados os resultados obtidos da classificação das amostras utilizando a metodologia RNA PMC e utilizando a metodologia de análise de textura LBP, LFP e os descritores de Haralick.

Para os descritores de textura foram utilizadas amostras extraídas por folha, amostras extraídas por canais de cores e amostras extraídas por quadrante de cada folha. Os resultados de classificação obtidos após a aplicação dos descritores LBP e LFP são comparados com a classificação utilizando o *toolbox* Weka.

5.2. Resultado da metodologia utilizando RNA PMC

Como mencionado na seção 4.5, no apêndice A e apêndice E, encontram-se todas as tabelas com os valores de porcentagem de cor em cada quadrante, para cada folha do banco1, juntamente com os gráficos de dispersão das doenças para cada cor entre os quadrantes. Observando-se os resultados dessas tabelas, pode-se fazer as seguintes considerações:

- para o CVC, os gráficos de dispersão mostram que os maiores valores de porcentagem de cor marrom (lesões com necrose) encontram-se no primeiro quadrante, seguido pelo quarto quadrante; para a cor amarela os maiores valores encontram-se no primeiro e quarto quadrante;
- o *greening* caracteriza-se pelas manchas assimétricas distribuídas na folha; os gráficos de dispersão mostram que os maiores valores de porcentagem de cor verde claro estão presentes em todos os quadrantes; para a cor amarela os maiores valores encontram-se no primeiro, segundo e terceiro quadrantes e para a cor marrom nos segundo, terceiro e quarto quadrantes;
- o magnésio apresenta como sintoma o amarelecimento em forma de “V” invertido; os gráficos de dispersão indicam a presença de cor verde escuro e

verde claro em todos os quadrantes; para as cores amarela e marrom, apresentam baixos valores de porcentagem;

- o manganês apresenta clorose entre as nervuras; os gráficos de dispersão indicam altos valores de porcentagem para as cores verde escuro e verde claro e baixa porcentagem para as cores amarela e marrom, em todos os quadrantes;
- a rubelose apresenta como sintoma o amarelecimento da folha; os gráficos de dispersão ilustram alta porcentagem de cor verde claro para todos os quadrantes e baixa para a cor amarela para todos os quadrantes;
- o zinco possui mancha amarela acentuada entre as nervuras da folha, o que difere esta das outras doenças; o gráfico de dispersão apresenta maior valor de porcentagem da cor amarela no primeiro quadrante.

Estes resultados mostram que a divisão por quadrantes auxilia a evidenciar as classes de doenças e a cor influencia na diferenciação do *greening* de outras doenças. No entanto, a metodologia utilizando RNA PMC não foi eficiente na classificação das classes de doenças, e dessa forma foi investigada a metodologia utilizando análise de textura.

5.3. Resultados da metodologia utilizando análise de textura

Inicialmente, antes de se aplicar os descritores de textura sobre as amostras das imagens do banco 3, foi avaliado o número de amostras extraídas por folha, o tamanho da amostra a resolução para as imagens do banco 2. Esses resultados são apresentados nas Tabelas 5.1, 5.2 e 5.3.

Na Tabela 5.1 são apresentados os resultados da sensibilidade (seção 4.5.3) para os descritores LBP, LFP e os descritores de Haralick, considerando amostras com o tamanho de 30 x 30 pixels e 100 x 100 pixels.

Tabela 5. 1 – Tabela da sensibilidade obtida com variação do tamanho da amostra WxW pixels.

Tabela da sensibilidade com variação no tamanho da amostra W x W pixels		
	30 x 30 pixels	100 x 100 pixels
LBP	32,70%	43,20%
LFP-s	34,30%	37,80%
LFP-t	25,30%	31,70%
LFP-g	26,80%	32,80%
Teste1	34,67%	36,00%
Teste2	34,17%	36,17%

Na Tabela 5.1 foram avaliadas 120 folhas de citros, sendo 20 imagens de folhas de citros para cada doença. Foram extraídas 5 amostras em nível de cinza de cada imagem digitalizada das folhas de citros, sendo 3 amostras da parte superior e 2 da parte inferior em relação à nervura central. Foram avaliadas as seis classes de doenças (CVC, *greening*, magnésio, manganês, rubelose e zinco), para os descritores LFP com função de pertinência (sigmóide, triangular e gaussiana) e o LBP, considerando uma vizinhança de 3x3. Foram avaliadas também as seis classes de doenças para os descritores de Haralick.

Observa-se na Tabela 5.1, que para as amostras com tamanho 100 x 100 pixels, os valores de sensibilidade foram superiores aos valores das amostras com tamanho 30 x 30 pixels, para todos os descritores. Além disso, os descritores LFP-t e LFP-g apresentaram resultados de sensibilidade inferiores ao descritor LFP-s, resultado semelhante ao obtido no trabalho publicado por Vieira (2013), onde o melhor resultado foi do descritor LFP-s.

A sensibilidade para o teste 1 e teste 2 dos descritores de Haralick foi calculada usando o algoritmo IBK, pelo *toolbox* Weka. Para o teste 1 foram utilizados treze descritores (segundo momento angular ou energia, contraste, correlação, variância, momento de diferença inversa, média da soma, variância da soma, entropia da soma, entropia, variância da diferença, entropia da diferença, medidas de informações da correlação (primeira propriedade), medidas de informações da correlação (segunda propriedade)). Para o teste 2 foram utilizados onze descritores (segundo momento angular ou energia, contraste, correlação, variância, momento de diferença inversa, média da soma, variância da soma, entropia da soma, entropia, variância da diferença, entropia da diferença).

Nas Tabelas 5.2 e 5.3 foram avaliados os descritores LBP e LFP-s em função do número de folhas para cada doença, utilizando amostras com tamanho 100 x 100 pixels.

A Tabela 5.2 apresenta os resultados de sensibilidade, para as 10 amostras extraídas aleatoriamente em nível de cinza, para cada folha, sendo avaliada a sensibilidade para as seis classes de doenças.

Tabela 5. 2 – Tabela da sensibilidade com variação do número das folhas de citros, para 10 amostras extraídas por folha.

Tabela da sensibilidade com variação do número das folhas			
	5 Folhas	10 Folhas	20 Folhas
LBP	41,30%	38,20%	38,70%
LFP-s	37,30%	34,30%	33,60%

Os resultados da Tabela 5.2 mostram que a sensibilidade foi maior para menor número de folhas avaliadas (5 folhas). Além disso, o descritor LBP apresentou os melhores resultados de sensibilidade em relação ao LFP-s.

A Tabela 5.3 diferencia da Tabela 5.2 pela quantidade de amostras extraídas por folha, que foi reduzida para 5 amostras. Para essa tabela foram avaliadas 20 e 25 folhas para cada doença. Os resultados mostram novamente que a sensibilidade é maior para o menor número de folhas avaliadas. Além disso, o descritor LBP apresentou maior valor de sensibilidade em relação ao LFP-s, similar ao resultado obtido com a Tabela 5.2.

Comparando-se as Tabelas 5.3 e Tabela 5.2, para avaliar a quantidade de amostras por folha, considerando a coluna de 20 folhas dessas tabelas, conclui-se que os maiores valores de sensibilidade são para 5 amostras para ambos descritores.

Tabela 5. 3 - Tabela da sensibilidade com variação no número das folhas de citros, para 5 amostras extraídas por folha.

Tabela da sensibilidade com variação do número das folhas		
	20 Folhas	25 Folhas
LBP	43,20%	40,20%
LFP-s	37,80%	37,10%

Como os resultados obtidos pela segmentação por cor, utilizando a metodologia RNA PMC, evidenciaram o potencial de diferenciação do *greening* das demais doenças a partir da divisão em quadrantes, o próximo passo da metodologia utilizando descritores de textura foi analisar as amostras extraídas por quadrantes nas imagens do banco 3.

As amostras foram inicialmente extraídas nos canais de cores vermelho, verde e níveis de cinza. Foram realizados dois experimentos onde, no primeiro, as amostras são avaliadas considerando cada canal de cor separadamente, para todos quadrantes. O objetivo desse experimento foi analisar a influência das cores. No segundo experimento as amostras são todas avaliadas para cada quadrante separadamente, para as cores vermelho e verde e níveis de cinza. O objetivo desse experimento foi analisar a influência da divisão por quadrantes.

Para o primeiro experimento (Tabela 5.4), foram utilizadas 5 folhas para cada doença, para as 6 classes de doenças, totalizando 30 imagens de folhas. Para cada folha foram extraídas 2 amostras em cada quadrante, com tamanho de 200 x 200 pixels, gerando 240 amostras extraídas para cada cor, totalizando 720 amostras extraídas para este experimento.

Tabela 5. 4 – Tabela da sensibilidade obtida pelo primeiro experimento.

Tabela da sensibilidade do primeiro experimento			
	Nível de cinza (%)	Vermelho(%)	Verde (%)
LBP	37,90	41,70	34,60
LFP-s	33,80	42,90	37,90
Teste1	33,68	37,29	40,14
Teste2	33,13	36,94	41,11

Os resultados da sensibilidade da Tabela 5.4 apresentados para os descritores de textura são abaixo de 50%, podendo-se concluir que a separação por canais de cores não evidencia a diferenciação das classes de doenças.

Para o segundo experimento (Tabela 5.5), foram utilizadas 5 folhas para cada doença, para as 6 classes de doenças, totalizando 30 imagens de folhas. Para cada folha foram extraídas 2 amostras em cada quadrante, com tamanho de 200 x 200 pixels, gerando 180 amostras por quadrante, totalizando 720 amostras extraídas para todos os quadrantes.

Tabela 5. 5 – Tabela da sensibilidade obtida pelo segundo experimento.

Tabela da sensibilidade obtida pelo segundo experimento				
	1º Quadrante(%)	2º Quadrante(%)	3º Quadrante(%)	4º Quadrante(%)
LBP	95,00	98,30	97,20	94,40
LFP-s	71,10	82,80	84,40	76,70
Teste1	35,37	31,48	35,56	36,48
Teste2	36,11	30,56	38,89	38,24

Na Tabela 5.5, os maiores valores de sensibilidade foram para o descritor LBP, entre 94,40% e 98,30%, seguido pelo descritor LFP-s com valores entre 71,10% e 84,40%, enquanto com os descritores de Haralick foram obtidos os menores valores de sensibilidade.

Portanto os resultados do segundo experimento com divisão por quadrantes, evidenciam que o LBP e LFP-s, são os mais adequados para serem utilizados na diferenciação das classes das doenças.

Nas seções 5.4, 5.5 e 5.6 são analisados os resultados obtidos com os descritores LBP, LFP-s e descritores de Haralick, respectivamente, considerando as amostras extraídas por quadrante para os canais de cores vermelho, verde e níveis de cinza.

5.4. Análise dos Resultados Obtidos com o Descritor LBP

Para analisar o descritor LBP, foram utilizadas as imagens do banco 3, e extraídas amostras por quadrante com tamanho 200 x 200 pixels. O número de amostras foi variado, sendo gerados os resultados de sensibilidade em cada quadrante, para este descritor, conforme apresentado na Tabela 5.6.

Tabela 5. 6 – Tabela de sensibilidade do LBP, por quadrante, variando o número de amostras.

Tabela de sensibilidade do LBP, por quadrante				
Nº de Amostras	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
2	71,10	82,80	84,40	76,70
3	97,69	98,24	98,70	96,76
7	98,21	98,65	98,53	97,70
10	97,92	98,47	98,58	97,11

Analisando os resultados, observa-se que, quando se passa de 2 para 3 amostras a sensibilidade aumenta para todos os quadrantes. Para o número de amostras igual a 7 há um pequeno aumento da sensibilidade no primeiro, segundo e quarto quadrante. Aumentando-se a quantidade de amostras de 7 para 10, não há um aumento significativo de sensibilidade.

Como os resultados da Tabela 5.6 foram melhores para o número de amostras 7 e 10, foram gerados os resultados de sensibilidade, variando o tamanho da amostra de 200 x 200 pixels para 300 x 300 pixels.

Tabela 5. 7 - Tabela de sensibilidade do LBP, por quadrante, variando o tamanho da amostra.

Tabela de sensibilidade do LBP, por quadrante, variando o tamanho da amostra					
Tamanho da amostra (pixels)	Nº de Amostras	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
200x200	7	98,21	98,65	98,53	97,70
200x200	10	97,92	98,47	98,58	97,11
300x300	7	98,10	99,12	99,41	98,25
300x300	10	98,33	99,00	99,25	98,08

Analisando os resultados da Tabela 5.7, observa-se que, aumentando o tamanho da amostra há um pequeno aumento da sensibilidade para cada quadrante. Com esses resultados foi realizado um média dos valores de sensibilidade para cada doença, gerando uma classificação das doenças pelo descritor LBP, como pode ser observado na Tabela 5.8.

Tabela 5. 8 - Tabela de sensibilidade das doenças para o LBP variando o tamanho das amostras.

Tabela de classificação das doenças pelos quadrantes LBP							
Tamanho da amostra (pixels)	Nº de Amostras	CVC (%)	Greening (%)	Magnésio (%)	Manganês (%)	Rubelose (%)	Zinco (%)
200x200	7	99,70	99,88	99,40	99,17	95,00	96,49
200x200	10	98,79	99,42	99,29	99,00	95,33	96,29
300x300	7	99,76	99,94	99,40	98,63	97,56	97,02
300x300	10	99,75	99,96	99,29	98,67	97,08	97,25

O gráfico 5.1 representa os valores obtidos na Tabela 5.8, com a variação das doenças em relação ao número de amostras e o tamanho das amostras.

Ao analisar o gráfico 5.1, observa-se que os melhores resultados da classificação das doenças foram para as amostras com o tamanho 300 x 300 pixels, com número de 7 e 10 amostras extraídas por quadrante, totalizando 2520 e 3600 amostras analisadas, respectivamente, para o descritor LBP.

Considerando o custo computacional, como os resultados o número de amostras de 7 e 10 são próximos, a avaliação com 7 amostras torna-se mais conveniente por apresentar o menor custo computacional.

Gráfico 5. 1 – Gráfico ilustrando a Tabela 5.8.

5.5. Análise dos Resultados Obtidos pelo Descritor LFP

Inicialmente, para o descritor LFP foram avaliadas as funções de pertinência (sigmóide, triangular e gaussiana), no que se refere à sensibilidade. Para isso foram utilizados as imagens do banco 3, sendo extraídos 3 amostras de cada quadrante, com tamanho 300 x 300 pixels, com 20 folhas de citros para cada classe de doença. A Tabela 5.9 e o Gráfico 5.2 apresentam os resultados obtidos. Analisando esses resultados, observa-se que o descritor LFP-s apresentou o melhor valor de sensibilidade por quadrante, com valores acima de 90% de sensibilidade, enquanto os descritores LFP-t e LFP-g apresentaram valores de sensibilidade abaixo de 90%. Com base nesses resultados o descritor LFP-s foi selecionado como o descritor de textura para avaliação das imagens de folhas.

Tabela 5. 9 - Tabela de sensibilidade do LFP com as funções de pertinência.

Tabela de sensibilidade do LFP com as funções de pertinência				
	1º Quadrante(%)	2º Quadrante(%)	3º Quadrante(%)	4º Quadrante(%)
LFP-s	90,56	92,13	92,13	90,09
LFP-t	84,54	85,19	87,41	87,87
LFP-g	78,89	82,87	83,80	80,00

Gráfico 5. 2 – Gráfico de comparação das funções de pertinência (sigmóide, triangular e gaussiana).

Para analisar o descritor LFP-s, foram utilizadas as imagens do banco 3, e extraídas amostras por quadrante com tamanho 200 x 200 pixels. O número de amostras foi variado, sendo gerados os resultados de sensibilidade em cada quadrante, para este descritor, conforme apresentado na Tabela 5.10.

Tabela 5. 10 – Tabela de sensibilidade do LFP-s, por quadrante, variando o número de amostras.

Tabela de sensibilidade do LFP-s, por quadrante				
Nº de Amostras	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
2	95,00	98,30	97,20	94,40
3	90,56	92,13	92,13	90,09
7	96,75	97,38	97,02	95,91
10	93,58	95,50	94,69	93,25

Analisando os resultados, observa-se que, quanto se passa de 2 para 3 amostras a sensibilidade diminui para todos os quadrantes. Para o número de amostras igual a 7 há um pequeno aumento da sensibilidade no primeiro e quarto quadrantes, em relação aos valores de sensibilidade para 2 amostras. Aumentando-se a quantidade de amostras de 7 para 10, diminui a sensibilidade para todos os quadrantes. Com esses resultados foi selecionado o número de amostras igual a 7.

Na Tabela 5.11 são apresentados os resultados da avaliação da sensibilidade em relação ao tamanho da amostra, tendo sido utilizado dois tamanhos de amostras: 200 x 200

pixels e 300 x 300 pixels. Para possibilitar a comparação dos resultados de sensibilidade obtidas para o LBP (Tabela 5.8), foram consideradas 7 e 10 amostras.

Tabela 5. 11 - Tabela de sensibilidade do LFP-s, por quadrante, variando o tamanho da amostra.

Tabela de sensibilidade do LFP-s, por quadrante, variando o tamanho da amostra					
Tamanho da amostra (pixels)	Nº de Amostras	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
200x200	7	96,75	97,38	97,02	95,91
200x200	10	93,58	95,50	94,69	93,25
300x300	7	97,38	97,81	97,74	96,98
300x300	10	96,81	98,11	97,39	96,67

Analisando os resultados da Tabela 5.11, e considerando o número de amostras igual a 7 observa-se uma pequena melhoria da sensibilidade quando se aumenta o tamanho da amostra. O mesmo ocorre para 10 amostras, no entanto quando se compara os resultados para 7 e 10 amostras com tamanho 300 x 300 pixels a sensibilidade ainda é ligeiramente maior para 7 amostras.

Com esses resultados foi realizado um média dos valores de sensibilidade para cada doença, gerando uma classificação das doenças pelo descritor LFP-s, como pode ser observado na Tabela 5.12.

Tabela 5. 12 – Tabela de sensibilidade das doenças para o LFP-s variando o tamanho das amostras.

Tabela de sensibilidade das doenças pelos quadrantes LFP-s							
Tamanho da amostra(pixels)	Nº de Amostras	CVC (%)	Greening (%)	Magnésio (%)	Manganês (%)	Rubelose (%)	Zinco (%)
200x200	7	99,40	99,52	97,68	98,99	91,01	93,99
200x200	10	93,21	97,08	96,08	97,50	89,67	92,00
300x300	7	99,52	99,46	98,33	99,05	93,39	95,12
300x300	10	99,33	99,63	98,33	98,83	92,75	94,58

O gráfico 5.3 representa os valores obtidos na Tabela 5.12, com a variação das doenças em relação ao número de amostras e o tamanho das amostras.

Gráfico 5.3 – Gráfico ilustrando a Tabela 5.12.

Ao analisar o gráfico 5.3, observa-se que o melhor resultado da classificação das doenças foi para as amostras com o tamanho 300 x 300 pixels, com número de 7 amostras extraídas por quadrante, totalizando 2520 amostras.

5.6. Análise dos Resultados Obtidos pelo Descritores de Haralick

Conforme mencionado na seção 5.3 para os descritores de Haralick foram utilizadas as amostras do banco 1, com tamanho de 30 x 30 pixels e 100 x 100 pixels. Esses descritores foram avaliados em dois testes, sendo que a diferença entre eles está na quantidade de descritores utilizados em cada teste. O objetivo foi avaliar o tamanho da amostra, comparar os resultados dos algoritmos IBK e RNA PMC

Os resultados gerados pelos descritores de Haralick foram classificados utilizando o *Toolbox* Weka com os algoritmos IBK e RNA PMC, com validação cruzada de 10 *folds*.

A Tabela 5.13 mostra os resultados obtidos para o teste 1 e teste 2 submetidos aos dois algoritmos.

Tabela 5. 13 – Tabela de sensibilidade com a variação do tamanho das amostras

Tabela de classificação com variação no tamanho das amostras		
	30 x 30 pixels	100 x 100 pixels
Teste1-IBK	34,67%	36,00%
Teste2-IBK	34,17%	36,17%
Teste1-RNA PMC	39,00%	39,80%
Teste2-RNA PMC	40,30%	44,00%

Analisando os resultados obtidos na Tabela 5.13, observa-se que não há grande variação da sensibilidade do teste 1 para o teste 2, seja com o algoritmo IBK ou com o RNA PMC. No entanto, os resultados de sensibilidade para o algoritmo RNA PMC mostraram-se superiores aos resultados obtidos para o algoritmo IBK. Com relação ao tamanho da amostra, o melhor resultado de sensibilidade obtida foi para tamanho 100 x 100 pixels, com a métrica RNA PMC.

Na sequência os descritores de Haralick foram avaliados com os mesmos experimentos descritos na seção 5.3, sendo que no primeiro, as amostras são avaliadas considerando cada canal de cor separadamente, para todos quadrantes, para analisar a influência das cores, e no segundo experimento as amostras são todas avaliadas para cada quadrante separadamente, para as cores vermelho e verde e níveis de cinza. Foram utilizadas as amostras extraídas do banco 3, com amostras com tamanho de 200 x 200 pixels.

A Tabela 5.14 apresenta os resultados para os descritores de Haralick para o primeiro experimento.

Tabela 5. 14 – Tabela de sensibilidade para o primeiro experimento com os descritores de Haralick.

Tabela de sensibilidade para o primeiro experimento			
	Nível de cinza (%)	Vermelho (%)	Verde (%)
Teste1-IBK	33,68	37,29	40,14
Teste2-IBK	33,13	36,94	41,11
Teste1- RNA PMC	40,80	52,10	42,50
Teste2-RNA PMC	41,70	52,50	42,50

Observa-se na Tabela 5.14 que os melhores resultados são para o canal de cor vermelho, para a métrica RNA PMC, para ambos os testes.

A Tabela 5.15 apresenta os resultados para os descritores de Haralick, para o segundo experimento.

Tabela 5. 15 – Tabela de sensibilidade para o segundo experimento com os descritores de Haralick.

Tabela de sensibilidade para o segundo experimento				
	1º Quadrante(%)	2º Quadrante(%)	3º Quadrante (%)	4º Quadrante(%)
Teste1-IBK	35,37	31,48	35,56	36,48
Teste2-IBK	36,11	30,56	38,89	38,24
Teste1-RNA PMC	45,60	45,00	48,90	44,40
Teste2-RNA PMC	45,00	45,00	55,00	44,40

Com os resultados da Tabela 5.15 observa-se que os valores de sensibilidade são próximos para todos os quadrantes, e abaixo de 55% , sendo que para o algoritmo RNA PMC os valores de sensibilidade são superiores em relação o algoritmo IBK.

Na Tabela 5.16 e Gráfico 5.4 são apresentados os resultados se sensibilidade para amostras com tamanho de 300 x 300 pixels, variando o número de amostras por quadrantes. Como nas seções 5.4 e 5.5 foram utilizados o número de amostras iguais a 7 e 10, nesse experimento foi mantido o mesmo padrão.

Tabela 5. 16 - Tabela de sensibilidade, variando o número de amostras.

Tabela de sensibilidade, variando o número de amostras					
	Nº de Amostras	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
Teste1-IBK	7	38,73	37,54	45,67	40,63
Teste2-IBK	10	38,69	38,42	44,25	41,36
Teste1-RNA PMC	7	45,90	45,40	50,70	48,70
Teste2-RNA PMC	10	47,17	45,47	49,94	48,28

Gráfico 5. 4 – Gráfico ilustrando a Tabela 5.16.

Pode-se observar na Tabela 5.16 e no gráfico 5.4, que os resultados de sensibilidade para a métrica RNA PMC, tanto para 7 como 10 amostras, são superiores aos resultados obtidos pela métrica IBK. Porém apresentaram valores de sensibilidade inferiores à 50%.

A Tabela 5.17 apresenta os valores de sensibilidade para as classes de doenças, por quadrante, considerando 7 amostras extraídas por quadrante.

Tabela 5. 17 – Tabela com os valores médios de sensibilidade dos quadrantes para cada doença.

Tabela de sensibilidade das doenças		
Doenças	IBK (%)	RNA PMC (%)
CVC	33,65	38,53
Greening	40,28	49,90
Magnésio	32,63	34,15
Manganés	41,13	47,13
Rubelose	38,45	35,48
Zinco	58,73	66,70

Os resultados apresentados na Tabela 5.17 evidenciam novamente que o RNA PMC gera valores de sensibilidade maiores do que o IBK e que somente para a doença relacionada ao zinco a sensibilidade foi acima de 50%. Conclui-se que os descritores de Haralick não são os mais adequados para diferenciar o *greening* das demais doenças.

5.7. Análise Geral dos Descritores

Nessa seção são analisados os melhores resultados obtidos pelos descritores LBP e LFP-s, e os descritores de Haralick, das respectivas seções 5.4, 5.5 e 5.6. Para os descritores Haralick foi utilizado o resultado do teste 1

A Tabela 5.18 apresenta os resultados para a comparação desses descritores, considerando 7 amostras extraídas com tamanho de 300 x 300 pixels. Para os descritores de Haralick são apresentados os resultados que utilizam o IBK, para manter o mesmo algoritmo utilizado pelos demais descritores.

Tabela 5. 18 – Tabela de comparação dos descritores.

Tabela de sensibilidade com a métrica da distância χ^2				
	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
LBP	98,09	99,12	99,41	98,25
LFP-s	97,38	97,81	97,74	96,98
Haralick	38,73	37,54	45,67	40,63

Os resultados apresentados na Tabela 5.18 evidenciam que os valores de sensibilidade para os descritores LBP e LFP-s são superiores a 97% para LFP-s e 98 % para o LBP. Os descritores de Haralick resultaram em valores de sensibilidade abaixo de 46%

A Tabela 5.19 apresenta a sensibilidade para as classes de doenças para os descritores LBP, LFP-s e descritores de Haralick. Observa-se que o descritor LBP classifica as classes de doenças com valores de sensibilidade acima de 97%, enquanto que o descritor LFP-s classifica as classes de doenças com valores de sensibilidade acima de 93%. No entanto para as classes de doenças CVC, *greening*, magnésio, manganês, tanto o descritor LBP quanto o descritor LFP-s apresentaram valores acima de 98% de sensibilidade, mostrando serem adequados para a diferenciação das doenças.

Tabela 5. 19 – Tabela de sensibilidade das doenças pelo cálculo da distância χ^2 .

Tabela de sensibilidade das doenças			
Doenças	LBP(%)	LFP-s(%)	Haralick (%)
CVC	99,76	99,52	33,65
<i>Greening</i>	99,94	99,46	40,28
Magnésio	99,41	98,33	32,63
Manganês	98,63	99,05	41,13
Rubelose	97,56	93,39	38,45
Zinco	97,02	95,12	58,73

Considerando o resultado obtido pela Tabela 5.18 para o descritor LFP-s, variou-se no número de *bins*, como foi realizado no trabalho de Chierici et al. (2013) e de Ojala, Pietikäinen, Mäenpää (2002), com o objetivo de encontrar o menor valor de *bins*, para reduzir o tempo de processamento. A Tabela 5.20 apresenta os resultados obtidos, podendo-se observar que podem ser utilizados 128 ou 64 *bins* sem que haja a redução da sensibilidade.

Tabela 5. 20 – Tabela da sensibilidade obtida com a variação do número de *bins* para os quadrantes.

Tabela de sensibilidade obtida com a variação do número de <i>bins</i>				
Nº <i>bins</i>	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
256	97,4	97,8	97,7	97
128	97,4	97,8	97,7	99,8
64	97,4	97,8	97,7	99,8

Com objetivo de avaliar a influência das classes de doenças, foram realizados vários testes, variando o número de classes de doenças para o descritor de Haralick.

A Tabela 5.21 apresenta a classificação das classes de doenças variando o número de classes, utilizando 7 amostras extraídas por quadrante, para 20 imagens de folhas para cada classe de doença, e a métrica RNA PMC com validação cruzada de 10 *folds*, com total de 1260 amostras avaliadas.

Tabela 5. 21 – Tabela de sensibilidade das classes de doenças, com a variação no número de classes de doenças para o descritor de Haralick.

Tabela de sensibilidade das classes de doenças			
Classes de doenças			Sensibilidade (%)
<i>Greening</i>	Manganês	Zinco	78,3
<i>Greening</i>	Magnésio	Zinco	73,5
<i>Greening</i>	CVC	Zinco	72,1
<i>Greening</i>	Rubelose	Zinco	68,8
<i>Greening</i>	Magnésio	Manganês	66,9
<i>Greening</i>	CVC	Manganês	64,1
<i>Greening</i>	Manganês	Rubelose	63,2
<i>Greening</i>	Magnésio	Rubelose	53,2
<i>Greening</i>	CVC	Rubelose	52,7
Todas 6 Classes de doenças			45,9

Como se pode observar, as classes de doenças com *greening*, manganês e zinco apresentaram a melhor classificação, com 78,3 % de sensibilidade.

Foi realizado um segundo teste, considerando agora os descritores LBP e LFP-s, para as três classes de doenças *greening*, manganês e zinco, que obtiveram melhor sensibilidade para o descritor de Haralick. A Tabela 5.22 apresenta os resultados obtidos, com total de 1260 amostras, podendo-se observar que os valores de sensibilidade para LBP e LFP-s aumentaram ligeiramente em relação as seis classes de doenças e que os descritores de Haralick apresentaram valores superiores em relação as seis classes de doenças. No entanto esses descritores ainda apresentam valores de sensibilidade abaixo de 83%, enquanto os descritores LBP e LFP-s apresentam valores acima de 98%.

Tabela 5. 22 - Tabela de sensibilidade para as classes *greening*, manganês e zinco.

Tabela de sensibilidade para as classes (<i>greening</i> , manganês e zinco)				
	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
LBP	98,80	99,90	99,70	98,90
LFP-s	98,60	99,50	98,80	98,90
Haralick	78,32	73,57	78,49	82,78

5.8. Classificação das Amostras Pelos Histogramas Dos Descritores LBP e LFP-s

Nas seções anteriores, para a classificação dos resultados obtidos pelos descritores LBP e LFP-s foi utilizada a métrica χ^2 . Para isso foram gerados os histogramas extraídos para cada amostra, e montada a matriz de confusão para o cálculo da sensibilidade., como descrito na seção 4.5.3.

Nessa seção serão utilizados os valores extraídos dos histogramas para cada descritor LBP e LFP-s, conforme descrito na seção 4.5.4. Os valores extraídos são armazenados em arquivo com extensão “arff” para mineração de dados utilizando o *toolbox* Weka. São considerados os dados referentes ao banco 3, com 7 amostras para cada folha, 20 imagens de folhas de citros para cada doença, para as 6 classes de doenças com resolução de 300 x 300 pixels. No *toolbox* Weka são aplicadas os algoritmos IBK e RNA PMC, com validação cruzada de 10 *fold* (ambos algoritmos), aos resultados dos arquivos com extensão “arff” para os descritores LBP e LFP-s. Os resultados são apresentados nas tabelas abaixo.

A Tabela 5.23 apresenta o resultado da sensibilidade dos valores extraídos dos histogramas para o LBP, por quadrante.

Tabela 5. 23 – Tabela de sensibilidade dos valores extraídos dos histogramas para o LBP, por quadrantes.

Tabela de sensibilidade dos valores extraídos dos histogramas para LBP			
1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
99,2	99,6	99,6	99,2

A Tabela 5.24 apresenta o resultado da sensibilidade para os valores extraídos dos histogramas para o LBP, para as classes de doenças, considerando a avaliação por quadrantes.

Tabela 5. 24 – Tabela de sensibilidade dos valores extraídos dos histogramas para o LBP com IBK.

Tabela de sensibilidade dos valores extraídos dos histogramas para LBP utilizando IBK				
Doenças	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
CVC	99,8	100,0	99,5	98,8
Greening	98,6	99,1	99,8	99,5
Magnésio	98,6	99,1	99,8	99,1
Manganês	99,5	100,0	99,5	98,6
Rubelose	99,0	99,8	100,0	99,5
Zinco	100,0	99,8	99,1	99,5

A Tabela 5.25 apresenta os valores de sensibilidade médios dos quadrantes, obtidos a partir dos valores da Tabela 5.24.

Tabela 5. 25 – Tabela com os valores de sensibilidade médios dos quadrantes, para o descritor LBP com IBK.

Tabela de sensibilidade das classes de doenças	
Doenças	Sensibilidade (%)
CVC	99,5
Greening	99,3
Magnésio	99,2
Manganês	99,4
Rubelose	99,6
Zinco	99,6

As Tabelas 5.23, 5.24 e 5.25 apresentaram valores de sensibilidade acima de 98,5% para o descritor LBP com o IBK, confirmando que este é um descritor eficiente na diferenciação das classes de doenças.

Na segunda análise, foram utilizados os resultados extraídos dos histogramas com o descritor LBP, e aplicado o RNA PMC. A Tabela 5.26 apresenta os resultados dessa classificação, por quadrante.

Tabela 5. 26 - Tabela de sensibilidade dos valores extraídos dos histogramas para o LBP, por quadrantes, para RNA PMC.

Tabela de sensibilidade dos valores extraídos dos histogramas para LBP, utilizando RNA PMC			
1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
88,10	91,6	92,6	90,5

A Tabela 5.27 apresenta o resultado da sensibilidade para os valores extraídos dos histogramas para o LBP, para as classes de doenças, considerando a avaliação por quadrantes.

Tabela 5. 27 - Tabela de sensibilidade para os valores extraídos dos histogramas para o LBP com RNA PMC .

Tabela de sensibilidade para os valores extraídos dos histogramas para LBP utilizando métrica RNA PMC				
	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
CVC	88,6	92,8	92,5	91,7
Greening	92,3	92,5	95,7	93,7
Magnésio	84,2	90,5	90,4	88,3
Manganês	89,2	88,6	89,7	89,9
Rubelose	87,2	92,7	94	89,3
Zinco	87,3	90	93,6	90,2

A Tabela 5.28 apresenta os valores de sensibilidade médios dos quadrantes, obtidos a partir dos valores da Tabela 5.27.

Tabela 5. 28- Tabela com os valores médios, de sensibilidade, dos quadrantes, para o descritor LBP com IBK.

Tabela de sensibilidade das classes de doenças	
Doenças	Sensibilidade (%)
CVC	91,4
Greening	93,6
Magnésio	88,4
Manganês	89,4
Rubelose	90,8
Zinco	90,3

As Tabelas 5.26, 5.27 e 5.28 apresentaram valores de sensibilidade acima de 84,2% para o descritor LBP com o RNA PMC, que é adequado para a classificação das classes de doenças, mas inferior aos resultados obtidos pelo IBK.

Na terceira análise, foram utilizados os resultados extraídos dos histogramas com o descritor LFP-s, e aplicado o IBK. A Tabela 5.29 apresenta os resultados dessa classificação, por quadrante.

A Tabela 5.29 apresenta o resultado da classificação dos valores extraídos dos histogramas para o LFP-s, por quadrante.

Tabela 5. 29 - Tabela de sensibilidade para os valores extraídos dos histogramas para o LFP-s, por quadrantes.

Tabela de sensibilidade para os valores extraídos dos histogramas para LFP-s			
1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
73,8	77,7	83,3	75,1

A Tabela 5.30 apresenta o resultado da sensibilidade para os valores extraídos dos histogramas para o LFP-s, para as classes de doenças, considerando a avaliação por quadrantes.

Tabela 5. 30 - Tabela de sensibilidade dos valores extraídos dos histogramas para o LFP-s com o IBK .

Tabela de sensibilidade dos valores extraídos dos histogramas para LFP-s utilizando IBK				
	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
CVC	77,5	85,1	89,7	91,7
<i>Greening</i>	71	71,5	79,2	93,7
Magnésio	77,9	77,4	82,6	88,3
Manganês	82,5	88,3	90,4	89,9
Rubelose	66,5	79,3	82,7	89,3
Zinco	66,6	65,7	74,9	90,2

A Tabela 5.31 apresenta os valores de sensibilidade médios dos quadrantes, obtidos a partir dos valores da Tabela 5.30.

Tabela 5. 31 - Tabela com os valores médios de sensibilidade dos quadrantes, para o descritor LFP-s com o IBK

Tabela de sensibilidade das classes de doenças	
Doenças	Sensibilidade (%)
CVC	86,0
<i>Greening</i>	78,9
Magnésio	81,6
Manganês	87,8
Rubelose	79,5
Zinco	74,4

As Tabelas 5.29, 5.30 e 5.31 apresentaram valores de sensibilidade acima de 65,7% para o descritor LFP-s com o IBK, confirmando que este não é um descritor adequado para a classificação das classes de doenças.

Na quarta análise, foram utilizados os resultados extraídos dos histogramas com o descritor LFP-s, e aplicado o RNA PMC. A Tabela 5.32 apresenta os resultados dessa classificação, por quadrante.

Tabela 5. 32 - Tabela de sensibilidade para os valores extraídos dos histogramas para o LFP-s, por quadrantes.

Tabela de sensibilidade para os valores extraídos dos histogramas para LFP-s			
1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
25,8	31,2	36,3	26,2

A Tabela 5.33 apresenta o resultado da classificação dos valores extraídos dos histogramas para o LFP-s, para as classes de doenças, considerando a avaliação por quadrantes.

Tabela 5. 33 - Tabela de sensibilidade dos valores extraídos dos histogramas para o LFP-s com RNA PMC

Tabela de sensibilidade dos valores extraídos dos histogramas para LFP-s utilizando RNA PMC				
	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
CVC	53,6	53,1	59,6	34,8
Greening	22,8	24,6	57,5	48,4
Magnésio	57,3	29,1	34,7	33,2
Manganês	26,1	34,1	56	35,4
Rubelose	21,2	28,6	22,6	20,2
Zinco	20,9	23,9	24,2	23,4

A Tabela 5.34 apresenta os valores médios dos quadrantes, obtidos a partir dos valores da Tabela 5.33.

Tabela 5. 34 - Tabela com os valores médios de sensibilidade dos quadrantes, para o descritor LFP-s com RNA PMC.

Tabela de sensibilidade das classes de doenças	
Doenças	Sensibilidade (%)
CVC	50,3
Greening	38,3
Magnésio	38,6
Manganês	37,9
Rubelose	23,2
Zinco	23,1

As Tabelas 5.32, 5.33 e 5.34 apresentaram valores de sensibilidade acima de 20,2% para o descritor LFP-s com o RNA PMC, confirmando que este não é um descritor adequado para a diferenciação das classes de doenças.

O Gráfico 5.5 apresenta um resumo da classificação das classes de doenças com os descritores LBP e LFP-s e utilizando para a classificação os algoritmos IBK e RNA PMC. Como se pode observar o descritor LBP com o IBK, apresentou o melhor resultado na diferenciação das doenças.

Gráfico 5. 5 – Gráfico com resumo da classificação das doenças.

O Gráfico 5.6 apresenta uma comparação geral de todos os descritores utilizados no trabalho (LBP e LFP-s calculados pela distância χ^2 , os descritores de Haralick, LBP e LFP-s com os dados extraídos dos histogramas e classificados com os algoritmos IBK e RNA PMC). Nesse gráfico destacam-se o LBP e o LFP com métrica da distancia χ^2 e o descritor LBP com o algoritmo IBK.

Gráfico 5.6 - Gráfico de comparação geral dos descritores.

5.8.1. Classificação de 1 folha

Após classificar as amostras extraídas avaliadas pelos descritores LBP e LFP-s conforme descrito anteriormente nessa seção, foi salvo o modelo da classificação pelo *toolbox* Weka, para cada algoritmo e para cada descritor.

Em seguida, foi escolhida uma nova imagem de folha de *greening* digitalizada e não utilizada na análise anterior. Foram extraídos novamente 7 amostras de cada quadrante para esta única imagem, que foram analisadas pelos descritores de LBP e LFP-s, gerados os histogramas destas amostras e salvos em um arquivo com extensão “arff”. Esses resultados foram classificados pelos algoritmos IBK e RNA PMC do *toolbox* Weka, utilizando o modelo salvo anteriormente.

A Tabela 5.35 apresenta os resultados obtidos para análise desta única folha de *greening*.

Tabela 5.35 – Tabela de sensibilidade de 1 folha de *greening*.

Tabela de sensibilidade de 1 folha de <i>greening</i>				
	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
LBP IBK	47,62	42,86	85,71	66,67
LBP RNA PMC	33,33	52,38	61,91	61,91
LFP-s IBK	52,38	42,86	28,57	4,76
LFP-s RNA PMC	0	0	0	0

Os resultados da Tabela 5.35 mostram que o modelo salvo de classificação utilizando uma única folha não é adequado para identificação da classe de doença.

5.8.2. Classificação de 10 folhas

Após classificar uma única amostra foi realizado novamente outro teste avaliando agora 10 novas imagens de folhas de *greening* que continham manchas variadas da doença.

Foi utilizado novamente o modelo salvo pelo *toolbox* Weka, como descrito na seção 5.8.1.

Foram extraídos novamente 7 amostras de cada quadrante para cada imagem de folha, que foram analisadas pelos descritores LBP e LFP-s, os histogramas foram gerados e salvos em um arquivo com extensão “arff”. Os resultados foram classificados pelos algoritmos IBK e RNA PMC utilizando o modelo salvo. A Tabela 5.36 apresenta os resultados obtidos.

Tabela 5. 36 - Tabela de sensibilidade de 10 folha de *greening*.

Tabela de sensibilidade de 10 folha de <i>greening</i>				
	1º Quadrante (%)	2º Quadrante (%)	3º Quadrante (%)	4º Quadrante (%)
LBP IBK	43,33	37,62	45,71	35,24
LBP RNA PMC	42,38	40,95	46,19	42,38
LFP-s IBK	37,62	26,67	32,86	27,14
LFP-s RNA PMC	0,48	0	4,76	0

Da mesma forma que na seção 5.8.1 os resultados obtidos da Tabela 5.36 mostram que o modelo salvo de classificação utilizando dez folhas não é adequado para identificação da classe de doença.

5.9. Considerações Finais

Neste capítulo foram apresentados os resultados obtidos para a primeira metodologia utilizando segmentação por cor com RNA PMC e para a segunda metodologia utilizando os descritores de textura LBP, LFP e suas funções de pertinência (sigmóide, triangular, gaussiana) e os descritores de Haralick, utilizando os algoritmos IBK e RNA PMC.

Para os descritores LBP e LFP foram avaliadas a influência do número de imagens de folhas, o tamanho da amostra e número de amostras extraídas por quadrante e por folha.

Para o descritor LFP foram avaliadas as funções de pertinência. A função sigmóide apresentou os melhores resultados para a classificação das classes de doenças.

Todos os descritores foram avaliados considerando as amostras extraídas dos canais de cores vermelho e verde e amostras em níveis de cinza. Foram realizados dois experimentos, sendo o primeiro para avaliar a influência das cores na classificação e o segundo para avaliar a influência da divisão da folha por quadrante.

Os melhores resultados foram para avaliação da folha por quadrante, com 7 amostras extraídas de cada quadrante, tamanho de 300 x 300 pixels.

Os descritores que apresentaram os melhores resultados foram o LBP e LFP-s pela métrica χ^2 (VIEIRA, 2013). Utilizando os algoritmos de classificação do *toolbox* Weka, aplicado aos resultados obtidos com esses descritores, o melhor resultado foi para o LBP utilizando o algoritmo IBK. Os descritores de Haralick mostraram-se não adequados para a diferenciação das classes de doenças.

Foram analisados os resultados obtidos na classificação de três classes de doenças (*Greening*, Manganês e Zinco) ao invés das seis classes doenças, concluindo-se que as classes de doenças influenciam na diferenciação das doenças.

Finalmente, foram salvos os modelos Weka de classificação, utilizados pelos descritores LBP e LFP-s e classificados os histogramas gerados para 1 e 10 folhas de *greening*, para os dois descritores e para os algoritmos IBK e RNA PMC. Os resultados mostraram que os modelos não são adequados para classificar corretamente a doença.

As diferenças nos resultados obtidos pela métrica χ^2 e pelo algoritmo IBK devem-se à técnica de validação cruzada, que para a métrica χ^2 a validação cruzada foi a *leave-one-out* enquanto que para o IBK foi 10 *folds*.

No próximo capítulo serão apresentadas as conclusões finais.

Capítulo 6

Conclusões

6.1. Conclusões Finais

Este trabalho teve por objetivo avaliar uma metodologia baseada em segmentação por cor utilizando RNA PMC e outra baseada em descritores de textura para avaliação de folhas de citros sintomáticas, identificando se estão contaminadas com o *greening* ou outras doenças e deficiências nutricionais.

Foram gerados três bancos de imagens digitalizadas de folhas de citros, contendo seis tipos de doenças (CVC, deficiência de manganês, de magnésio, de zinco, *greening* e rubelose).

Os resultados da metodologia utilizando segmentação por cor, não foi eficiente na classificação das classes de doenças, mas mostrou que a divisão por quadrantes auxilia a evidenciar as classes de doenças e a cor influencia na diferenciação do *greening* de outras doenças.

Na segunda metodologia foram avaliados os descritores LBP, LFP e os descritores de Haralick nas imagens digitalizadas de folhas de citros doentes. Inicialmente foi variado o número de amostras extraídas, o número de imagens de folhas, o tamanho das amostras e a resolução da imagem. As amostras foram inicialmente extraídas nos canais de cores vermelho, verde e níveis de cinza. Foram realizados dois experimentos onde, no primeiro, as amostras foram avaliadas considerando cada canal de cor separadamente, para todos quadrantes, para analisar a influência das cores. No segundo experimento as amostras foram todas avaliadas para cada quadrante separadamente, para as cores vermelho e verde e níveis de cinza, para analisar a influência da divisão por quadrantes.

Os resultados da configuração que apresentou a melhor sensibilidade de diferenciação das classes de doenças foi a avaliação por quadrante, com 7 amostras extraídas para cada quadrante, para 20 imagens de folhas para cada doença, totalizando 120 imagens analisadas, nas seis classes de doenças avaliadas, para um tamanho de amostra de 300 x 300 pixels, com total de 2520 amostras.

Foram avaliados os descritores de textura LBP, LFP e suas funções de pertinência (sigmóide, triangular, gaussiana) e os descritores de Haralick, utilizando os algoritmos IBK e RNA PMC. Para o descritor LFP, a função de pertinência que apresentou melhor eficiência na diferenciação das amostras das imagens analisadas foi à função sigmóide.

Os descritores que apresentaram os melhores resultados foram o LBP e LFP-s pela distância X^2 (VIEIRA, 2013), sendo que o descritor LBP classificou as classes de doenças com valores de sensibilidade entre 97,02% e 99,94% , enquanto que para o descritor LFP-s os valores de sensibilidade foram entre 93% e 99,52%.

Utilizando os algoritmos de classificação do *toolbox* Weka, aplicado aos resultados obtidos com LBP e LFP-s, o melhor resultado foi para o LBP utilizando a métrica IBK com valores entre 98,50% e 100%, mostrando ser eficiente na diferenciação das classes de doenças. Os melhores valores de sensibilidade para o LFP-s foram com a métrica IBK, com valores entre 65,70% e 90,40% de sensibilidade.

Os descritores de Haralick mostraram não ser adequados para a diferenciação das classes de doenças em todos os testes realizados , com valores de sensibilidade abaixo de 50%.

Foram analisados os resultados obtidos na classificação de três classes de doenças (*greening*, manganês e zinco) ao invés das seis classes doenças, concluindo-se que as classes de doenças influenciam na diferenciação das doenças.

Finalmente, foram salvos os modelos Weka de classificação, utilizados pelos descritores LBP e LFP-s e classificados os histogramas gerados para 1 e 10 folhas de *greening*, para os dois descritores e para os algoritmos IBK e RNA PMC. Os resultados mostraram que os modelos não são adequados para classificar corretamente a doença.

6.2. Sugestões de Trabalhos Futuros

Sugestão para dar continuidade do trabalho na diferenciação do *greening*.

- Dividir as amostras extraídas em quadrantes, gerando os histogramas correspondentes para cada quadrante.
- Avaliar as imagens de folhas de citros utilizando os descritores LBP e LFP-s no modelo de cor HSV.

- Investigar com mais detalhes os modelos salvos pelo *toolbox* Weka, avaliando os resultados das métricas, para uma amostra e um conjunto de amostras de *greening*.

6.3. Trabalhos Publicados

Vinculado ao tema desta pesquisa foram publicados os seguintes trabalhos:

6.3.1. Capítulos de livros

RIBEIRO, P. P. E. ; JORGE, L. A. de C. ; PAIVA, M. S. V. de . Diferenciação do Greening de Outras Doenças Foliares em Citros Utilizando Técnicas de Processamento de Imagens. In: Luis Antônio Pereira Neves, Hugo Vieira Neto, Adilson Gonzaga. (Org.). Avanços em Visão Computacional. 1ed.: Omnipax, 2012, v. , p. 141-160.

RIBEIRO, P. P. E . ; PAIVA, M. S. V. de ; INAMASU, R. Y. ; JORGE, L. A. de C. . Aplicação de técnicas de processamentos de imagens para diferenciação do Greening de outra pragas. In: INAMASU, R. Y.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; BERNARDI, A. de C. (Ed.). (Org.). Agricultura de Precisão: um novo olhar. 1ed.: CUBO, 2011, v. 1, p. 73-77.

6.3.2. Trabalhos publicados em anais de congresso

RIBEIRO, P. P. E.; JORGE, L. A. de C.; PAIVA, M. S. V. de. Diferenciação da *Greening* do citros de outras doenças foliares a partir de descritores de cor e forma. In: WORKSHOP DE VISÃO COMPUTACIONAL, 7., 2011, Curitiba. **Anais...** Curitiba: UFPR, 2011. p. 225-230.

SILVA, D. C. P. da ; SOUSA, P. P. E. ou SOUZA, P. P. E. ou RIBEIRO, P. P. E . ; SOUSA, P. P. E. ou SOUZA, P. P. E. ou RIBEIRO, P. P. E . ; JORGE, L. A. de C. ; PAIVA, M. S. V. de ; MILORI, D. M. B. P. ; GONÇALVES, D. S. ; CARVALHO, C. M. ; VENÂNCIO, A. L. ; PEREIRA, F. M. V. . Extração de características para geração de um classificador para detecção precoce do HLB em citros. In: WORKSHOP DE VISÃO COMPUTACIONAL, 2010, Presidente Prudente-SP. WORKSHOP DE VISÃO COMPUTACIONAL. Presidente Prudente: FCT/UNESP, 2010. p. 224-229.

6.3.3. Trabalho submetido

RIBEIRO, P. P. E.; PAIVA, M. S. V. de. Diferenciação da Greening do citros de outras doenças foliares a partir de descritores de cor e forma. In: WORKSHOP DE VISÃO COMPUTACIONAL, 10., 2014, Uberlandia. Anais... Uberlandia: UFU, 2014.

6.3.4. Resumo de trabalhos publicados em anais de congresso

SILVA, D. C. P. da ; SOUSA, P. P. E. ou SOUZA, P. P. E. ou RIBEIRO, P. P. E . ; SOUSA, P. P. E. ou SOUZA, P. P. E. ou RIBEIRO, P. P. E . ; MILORI, D. M. B. P. ; Ednaldo José Ferreira ; JORGE, L. A. de C. . Geração de um classificador para detecção precoce do HLB em citros. In: JORNADA CIENTÍFICA - EMBRAPA SÃO CARLOS, 2010, São Carlos-SP. Anais da II Jornada Científica. São Carlos-SP: Embrapa Pecuária Sudeste: Embrapa Instrumentação Agropecuária, 2010. p. 85-85.

SOUSA, P. P. E. ou SOUZA, P. P. E. ou RIBEIRO, P. P. E . ; SOUSA, P. P. E. ou SOUZA, P. P. E. ou RIBEIRO, P. P. E . ; JORGE, L. A. de C. ; INAMASU, R. Y. ; MILORI, D. M. B. P. . Geotecnologias para inspeção, gerenciamento e análise da propagação de Greening dos citros. In: JORNADA CIENTÍFICA-EMBRAPA SÃO CARLOS, 2009, São Carlos-SP. JORNADA CIENTÍFICA-EMBRAPA SÃO CARLOS. São Carlos-SP: Embrapa Pecuária Sudeste: Embrapa Instrumentação Agropecuária, 2009. p. 69-69.

Referências

ALVES, E. A.; KHOURY JUNIOR, J. K.; PINTO, F. A. C.; de QUEIROZ, D. M. Classificação de plantas daninhas utilizando características Texturais em imagens digitais, 2º Simpósio Internacional de Agricultura de Precisão - SIAP 2002, Viçosa - MG.

AGRIANUAL (2008): Anuário da Agricultura Brasileira. São Paulo: *FNPP Pesquisas*, [S.I.], p.520, 2008.

AGRISOFT (2009). A citricultura em risco – o pesadelo da Greening. Disponível em: < <http://www.agrosoft.org.br/agropag/103543.htm> >. Acesso em: 11 Jan 2011.

AGX (2011). Disponível em: < <http://www.agx.com.br/n2/pages/index.php> >. Acesso em: 27 Outubro 2011.

AMARAL, V. do; THOMAZ, C. E. Extração e comparação de características locais e globais para o reconhecimento automático de imagens de faces. Anais do VIII Workshop de Visão Computacional, WVC'2012, 27 a 30 de maio de 2012, Goiânia, GO, ISSN: 2175-6120, CD, 6 pp.

ANDRADE, M. C. de; PINTO, L. C. M. Classificação de Folhas por Tamanho e Forma Através de Descritores Geométricos e Análise dos Componentes Principais. Anais do IV Workshop em Tratamento de Imagens, NPDI/DCC/ICEx/UFMG, p.54-61, Junho de 2003.

ANDRIGUETO, J.R.; NASSER, L.C.B.; TEIXEIRA, J.M.A.; SIMON, G.; VERAS, M.C.V.; MEDEIROS, S.A.F.; SOUTO, R.F.; MARTINS, M.V. de M.; KOSOSKI, A. R. Produção Integrada de Frutas e Sistema Agropecuário de Produção Integrada. **Livro PIF-SAPI**. Junho 2008.

BARROS, L.; BASSANEZI, R. C. *Tópicos de Lógica Fuzzy e Biomatemática*. Coleção IMECC Textos Didáticos, v. 5, 2006.

BELASQUE JR. J.; BERGAMIM FILHO A.; BASSANEZI R. B.; BARBOSA J. C.; GIMENES-FERNANDES N.; YAMAMOTO P.T.; LOPES A. S.; MACHADO M. A.; LEITE JR. R. P.; AYRES A. J.; MASSARI C. A. (2009b). A instrução normativa nº 53 e a necessidade de um controle efetivo de Greening no Brasil, p.1-5, 2009.

BELASQUE JR. J.; YAMAMOTO P. T.; MIRANDA M. P.; BASSANEZI R. B.; AYRES A. J.; BOVÉ J. M. (2010) Controle do *huanlongbing* no estado de São Paulo, Brasil. **Citrus Research & Technology**, Cordeirópolis, v.31, n.1, p.1-100, 2010.

BOAVENTURA, I. A. G. *Números Fuzzy em Processamento de Imagens Digitais e suas aplicações na Detecção de Bordas*. PhD thesis, Universidade de São Paulo, Departamento de Engenharia Elétrica, SEL São Carlos - SP, Brasil, 2010.

BOVÉ, J. M. Huanglongbing: a destructive, newly-emerging, century-old disease of citrus. **Journal of Plant Pathology**, Pisa, v. 88, p.7-37, 2006.

BRASIL (2008), Instrução Normativa N°53, de 16 de Outubro de 2008. Diário Oficial da União, 17 de Outubro de 2008. Seção 1, N° 202. Dispõe sobre a delimitação da extensão das áreas afetadas e a adoção de medidas de prevenção e erradicação do *Huanglongbing* (HLB) – *Greening*, 2008.

CAPONETTI, L.; CASTIELLO, C.; FANELLI, A. M.; GÓRECKI, P. *Texture segmentation with local fuzzy patterns and neuro-fuzzy decision support*. In: Gabrys, B.; Howlett, R. J.; Jain, L. C.(Ed). KES 2006, Springer-Verlag, Berlin, Heidelberg, 2006, v. PartII, p. 340-347.

CAVANI, F. A.; TRONCO, M. L.; SOUSA, R. V. de; PORTO, A. J. V. Segmentação e Classificação de Imagens de laranjeiras utilizando JSEG e Perceptron Multicamadas. **Revista Minerva**, v. 3, p. 189-197, 2006.

CHIERICI, C.; VIEIRA, R. T.; FERRAZ, C. T.; TRAVAINI, J.; GONZAGA, A.; A new approach for analyzing rotated textures, Anais do IX Workshop de Visão Computacional, WVC'2013, 03 a 05 de junho de 2013, Rio de Janeiro, RJ, ISSN: 2175-6120, CD, 6 pp.

CHEN, Q. A report of a study on yellow shoot of citrus in Chaoshan. *New Agric. Q. Bull.* 3:142-75 (refs. 173, 343), 1943.

CHEN, H. X.; TANG, Y. Y.; FANGY, B. A Multi-layer contrast analysis method for texture classification based on lbp. *International Journal of Pattern Recognition and Artificial Intelligence*. Vol. 25, No. 1, p.147-155, 2011.

COLETTA FILHO, H. D.; TAKITA, M. A.; TARGON, M. L. P. N.; CARLOS, F. E.; MACHADO, M. A. A bactéria *Candidatus Liberibacter* em plantas com Huanglongbing (ex-greening) no Estado de São Paulo. **Laranja**, Cordeirópolis, v.25, n.2, p.367- 374, 2004.

COLETTA FILHO, H. D.; CARLOS, E. F. Ferramentas para diagnóstico de huanglongbing e detecção de agentes associados: dos sintomas aos ensaios de laboratório. *Citrus Research & technology*, Cordeirópolis, v.31, n.2, p.129-143, 2010.

CUBERO, J.; GRAHAM, J.H.; GOTTWALD, T. R. Quantitative PCR method for diagnosis of citrus bacterial canker. **Applied and Environmental Microbiology**, v. 67, n.6, p. 2849-2852, 2001.

DIAS, D. O.; NETO, J. B. Identificação de Ferrugem por meio de imagens aéreas das áreas cultivadas com cana de açúcar. II Workshop de tecn. da Inf. aplicada ao meio ambiente - CB COMP 2004. Inteligência Artificial. 2004.

ETXEBERRIA, E.; GONZALEZ, P.; DAWSON, W. O.; SPANN, T. An iodine-based starch test to assist in selecting leaves for HLB testing. Horticultura Sciences Department. Florida. p.1-5, 2007.

FERREIRO, C. A.; LEE, H. D.; CHUNG, W. F.; COY, C. S. R.; FAGUNDES, J. J.; GÓES, J. R. N. “Seleção de Características Baseadas em Textura para a Identificação de

Anormalidades em Imagens de Colonoscopia”. In: X Congresso Brasileiro de Informática em Saúde – CBIS’2006, Florianópolis, SC-Brazil, 2006.

FISCHER. Disponível em:
<http://www.citrosuco.com.br/fischer/fischer/sites/fischer/portal_grupo/home/index.html>.
Acessado em: 28 Set. de 2011.

FLOYD, J.; KRASS, C. 2008. New pest response guidelines: citrus greening disease. Technical report, USDA APHIS PPQ Emergency and Domestic Programs, Riverdale, Maryland. Disponível em:
<http://www.aphis.usda.gov/plant_health/plant_pest_info/citrus_greening/downloads/pdf_file_s/cg-nprg.pdf>. Acessado em 19/05/2011.

FUNDECITRUS (2009a). **Greening: manual técnico**, Araraquara, 2009. Disponível em:
<<http://www.fundecitrus.com.br/ImageBank/PageFlip/pageflip.aspx?idPage=143>>. Acesso em: 29 abril de 2011.

FUNDECITRUS (2009b) **A Instrução Normativa Nº 53 e a necessidade de um controle efetivo do Greening no Brasil**, Araraquara 2009. Disponível em:
<http://www.fundecitrus.com.br/ImageBank/FCKEditor/file/pdf/artigo_controle_greening.pdf>. Acesso em: 04 abr. 2011.

FUNDECITRUS (2010). **Greening atinge 38,8% dos talhões dos pomares paulistas**, Araraquara 2010. Disponível em: < <http://www.fundecitrus.com.br/Noticias/31.08.10---Greening-atinge-38,8--dos-talhoes-dos-pomares-paulistas,136>>. Acesso em: 04 Jan. 2011.

GONZALEZ, R. C.; WOODS, R. E. **Processamento digital de imagens**; 3 ed., São Paulo: Ed. Pearson Hall, 2010.

GONZALEZ-MORA, J.; VALLESPI, C.; DIMA, C. S.; EHSANI, R. HLB Detection Using Hyperspectral Radiometry. The 10th International Conference in Precision Agriculture, Denver, CO, July 2010.

GOOL, L.V.; DEWAELE, P. ; OOSTERLINCK, A. “Survey: Texture Analysis anno 1983.” Computer Vision, Graphics, and Image Processing, 1985, 336–357.

GRAÇA, J. K. *Citrus greening disease*. **Annual Review of Phytopathology**, 1991, v. 29, p.109-136.

HASSE, G. A laranja no Brasil. Associação Brasileira de Exportadores de Cítricos (ABECITRUS). ABECITRUS. [S.l.]: Duprat & Lobe Propaganda, 1987. Disponível em:<<http://www.citrosuco.com.br/fischer/fischer/sites/fischer/citrosuco/pomares/laranja/trajetoria.html>>. Acesso em: 03 Jan. 2011.

HARALICK, R. M.; SHANMUGAN, K.; DINSTEN, I. H. Textural Features for Image Classification, **IEEE Transactions on Systems, Man and Cybernetics**, Vol. 3, Issue: 6, p: 610-621, Nov. 1973.

HE, D. C.; WANG, L. Texture Unit, Texture Spectrum, and Textures Analysis, *IEEE Transaction On Geoscience And Remote Sensing*. v. 28, p. 509-512, 1990.

HUANG, K. Application of artificial neural network for detecting Phalaenopsis seedling diseases using color and texture features. *Computer and electronics in agriculture*. n.57, p.3-11, 2007.

HUANG, D.; SHAN, C.; ARDABILIAN, M.; WANG, Y.; CHEN, L. Local Binary Patterns and Its Application to Facial Image Analysis: A Survey. *IEEE TRANSACTIONS ON SYSTEMS*, vol. 41, n. 6, p.765 – 781, 2011.

IAKOVIDIS, D. K.; KERAMIDAS, E. G.; MAROULIS, D. *Fuzzy Local Binary Patterns for Ultrasound Texture Characterization*. In Campilho, A.; Kamel, M. (Ed). *Lecture Notes in Computer Science*. Springer-Verlag Berlin Heidelberg, 2008, v. 5112, p. 750-759.

IMAGEJ. Image Processing and Analysis in Java. Disponível em: <<http://rsbweb.nih.gov/ij/>>. Acesso em: 28 Set. 2011.

INNIS, M. A.; GELFAND, D. H.; SNINSKY, J. J.; WHITE, T. J. (eds.), *CR Protocols: A guide to methods and applications*, Academic Press: San Diego, 1990.

INSTITUTO DE ECONOMIA AGRÍCOLA. Divulgação da safra paulista de laranja 2009/10. Disponível em: <<http://www.iea.sp.gov.br/out/LerTexto.php?codTexto=12002>>. Acesso em: 28 Dez 2010.

INSTITUTO AGRONÔMICO DE CAMPINAS. Citros: Principais informações e recomendações de cultivo. Disponível em: <<http://www.iac.sp.gov.br/Tecnologias/Citros/Citros.htm>>. Acesso em : 03 Jan 2010.

JAI. Java Advanced Imaging. Disponível em:<<http://java.sun.com/products/javamedia/jai/iio.html>>. Acesso em: 28 Set. 2011.

JAIN, A. K. **Image Analysis and Processing**. Ed. Pearson Hall,p.342-430, 1989.

JAVA. Disponível em: <<http://www.java.com>>. Acesso em: 26 Nov. 2010.

JXL. Java Excel. Disponível em: <<http://jexcelapi.sourceforge.net/>>. Acesso em: 28 Set. 2011.

JORGE, L. A. C. Determinação da cobertura de solo em fotografias aéreas do Projeto ARARA. 2001, 97 f, Dissertação (Mestrado em ciência de computação e matemática computacional) – ICMC-USP, Universidade de São Paulo, São Paulo, 2001.

KIM D.G., BURKS T.F., SCHUMANN A.W., ZEKRI M., ZHAO X., QIN J. “Detection of Citrus Greening Using Microscopic Imaging”. *Agricultural Engineering International: the CIGR Ejournal*. Manuscript p.1194. Vol. 11, 2009.

KOWATA, L. S.; MAY-DE-MIO, L. L.; DALLA-PRIA, M.; SANTOS H. A. A. Escala Diagramática para avaliar severidade de mildio na soja. **Scientia Agraria**, Curitiba, v.9, n.1, p.105-110, 2008.

KUMAR, A.; LEE, W.S.; EHSANI, R.; ALBRIGO, L.G.; YANG, C.; MANGAN, R.L. Citrus greening disease detection using airborne multispectral and hyperspectral imaging. 10th International Conference on Precision Agriculture. Julho 18-21, 2010, Hyatt Regency Tech Center, Denver CO.

LIU, L.; ZHAO, L.; LONG, Y.; HUANG, G.; FIEGUTH, P. Extended local binary patterns for texture classification. *Image and Vision Computing*. Elsevier, p.86-99, 2012.

MCCLEAN, A.P.D.; OBERHOLZER, P.C.J. Greening disease of the sweet orange: evidence that is caused by a transmissible vírus. *South African J. Agric. Sci.* vol.8, p.253-276, 1965.

MÄENPÄÄ, T.; OJALA, T. PIETIKÄINEN, M.; SORIANO, M. Robust texture classification by subsets of local binary patterns. In: *Proc. 15th International conference on Pattern Recognition*. 2000, v.3, p. 947-950.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens**, Rio de Janeiro: Brasport, 1999.

MARTINS, M.C.; GUERZONI, R.A.; CÂMARA, G.M.S., MATTIAZZI, P., LOURENÇO, S.A. & AMORIM, L. Escala diagramática para a quantificação do complexo de doenças foliares de final de ciclo em soja. **Fitopatologia Brasileira**, vol.29, p.179-184, 2004.

MARTINS, E. R. da S.; MAZZONCINI, P. de A. M.; OLIVEIRA, L. F. de O.; PEREIRA JR, R. R.; TRAD, C. S. Caracterização de lesões intersticiais de pulmão em radiograma de tórax utilizando análise local de textura. *Radiol Bras*, São Paulo , v. 38, n. 6, Dec. 2005

MATLAB. Disponível pelo site < <http://www.mathworks.com/products/matlab/> >. Acessado em: 21 de Março de 2014.

MUELEER, A. Uma aplicação de redes neurais artificiais na previsão do mercado acionário. 1996. Dissertação (Mestrado em Engenharia de Produção) – Universidade de Florianópolis, Florianópolis, 1996.

MUSCI, M.; FEITOSA, R. Q.; NOVACK. T. Padrões binários locais na classificação de imagens de sensoriamento remoto. *Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.7651.

NANNI, L. LUMINI, A. BRAHNAM, S. Local binary patterns variants as texture descriptors for medical image analysis. **Artificial Intelligence in Medicine**. vol. 49, Issue 2, p.117–125, 2010.

NETBEANS. Disponível em: < www.netbeans.org/ >. Acesso em: 26 Nov. 2010.

NUTTER, JR., F.W.; SCHULTZ, P.M. Improving the accuracy and precision of disease assessments: selection of methods and use of computer-aided training programs. **Canadian Journal of Plant Pathology**, Ottawa, v.17, n.1, p.174-184, 1995.

OTSU, N., "A Threshold Selection Method from Gray-Level Histograms," **IEEE Transactions on Systems, Man, and Cybernetics**, Vol. 9, No. 1, 1979, pp. 62-66.

OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A. Comparative study of texture measures with classification based on feature distributions. **Pattern Recognition**. v.29, n., p.51-59, 1996.

OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 24, n. 27, p.971-987, 2002.

PEREIRA NETO, O. C.; JORGE, L. A. de C.; GUIMARÃES, M. de F. Quantificação de plantas daninhas em soja através de classificador digital por redes neurais. **V Congresso Brasileiro de Agroinformática**. Londrina, PR: SBI-AGRO, 2005.

PIETIKÄINEN, M.; HADID, A.; ZHAO, G.; AHONEN, T. *Computer Vision Using Local Binary Patterns*. London: Springer-Verlag, 2011.

PLOTZE, R. O.; FALVO, M. ; BRUNO, O. M.. Identificação de Espécies Arbóreas Através da Dimensão Fractal. In: I Workshop de Tecnologia da Informação Aplicada ao Meio Ambiente, 2003, Itajaí - SC. Congresso Brasileiro de Computação 2003, v. 1. p. 1770-1779, 2003.

PORTAL REDE DE INOVAÇÃO E PROSPECÇÃO TECNOLÓGICA PARA O AGRONEGÓCIO. Disponível em: <<http://www.ripa.com.br/index.php?id=1823>> Acesso em: 04 Jan. 2011.

QUEIROZ, D.P.; ARAUJO, A. da L. J.; ARAUJO, A. de A. Classificação Automática de Imagens do Acervo de Obras de Candido Portinari. Relatório Técnico NPDI/DCC/UFGM, Belo Horizonte, MG, 2008, 17p.

QUINTA, L. N. B. Seleção de Atributos para a Segmentação do Couro Bovino. In: WORKSHOP DE VISÃO COMPUTACIONAL, 4., 2008, Bauru. **Anais...** Bauru: UNESP, 2008. p. 262-267.

RIBEIRO, P. P. E . ; PAIVA, M. S. V. de ; INAMASU, R. Y. ; JORGE, L. A. de C. . Aplicação de técnicas de processamentos de imagens para diferenciação do Greening de outras pragas. In: INAMASU, R. Y.; NAIME, J. de M.; RESENDE, A. V. de; BASSOI, L. H.; BERNARDI, A. de C. (Ed.). (Org.). Agricultura de Precisão: um novo olhar. 1ed.: CUBO, 2011, v. 1, p. 73-77.

SANKARAN, S.; EHSANI, R.; ETXEBERRIA, E. Mid-infrared spectroscopy for detection of Huanglongbing (greening) in citrus leaves. **Talanta**, v.83, p.574-581, 2010.

SANKARAN, S; MISHRA, A.; MAJA, J. M.; EHSANI, R. Visible-near infrared spectroscopy for detection of Huanglongbing in citrus orchards. **Computer and Electronics in Agriculture**, v.77, p.127-134, 2011.

SANTOS, A. P. de O. Desenvolvimento de descritores de imagens para reconhecimento de padrões de plantas invasoras. 2009. p.203. Dissertação de Mestrado, DC-UFSCAR, São Carlos, 2009.

SANTOS, A. P. O.; NUNES, F. L. S.; DELAMARO, M. E. Implementação de uma Ferramenta para Recuperação de Imagens Mamográficas Baseada em Conteúdo In: **WORKSHOP DE VISÃO COMPUTACIONAL**, 3., 2007, São José do Rio Preto. Anais... São José do Rio Preto: UNESP, 2007. p. 247-252

SARTORI, A. L. **Métodos para extração de informações a partir de imagens multiespectrais de escalas grandes**. 2006. p.129. Dissertação de Mestrado, FCT-UNESP, Presidente Prudente, 2006.

SCHWARZ , R. E. A fluorescent substance present in tissues of greening-affected sweet orange. **South African Journal of Agricultural Science**, v.8, p.1177-1180, 1965.

SETTE, P. G.; MAILLARD, P. Análise de textura de imagem de alta resolução para aprimorar a acurácia da classificação da mata atlântica no sul da Bahia. In: **15º Simpósio Brasileiro de Sensoriamento Remoto (SBSR)**, 2011, Curitiba. Anais...Curitiba: INPE, p. 2020-2027, 2011.

SHAN, C.; GONG, S.; McOWAN, P. W. Facial expression recognition based on local binary patterns: A comprehensive study. *Image and Vision Computing*, vol. 27, p.803–816, 2009.

SIMÕES, A. S. e COSTA, A. H. R.. Classificação de Laranjas Baseada em Padrões Visuais. In: **6º Simpósio Brasileiro de Automação Inteligente (SBAI)**. Sociedade Brasileira de Automática. Bauru, setembro 14-17, p. 77-81, 2003.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para Engenharia e Ciências Aplicadas**. São Paulo: Artliber, 2010.

SILVA, M. F. e; CARDINALI, M. C. B.; MARTINS, P. K.; ASTÚA, J. F.; MILORI, D. M. B. P.; MASCARENHAS, Y. P. Aplicação da espectroscopia na região do infravermelho com transformada de Fourier (FTIR) no estudo da doença *Greening* em plantações de citros. In: **JORNADA CIENTÍFICA - EMBRAPA SÃO CARLOS**, 2., 2010, São Carlos, SP. **Anais...** São Carlos: Embrapa Instrumentação Agropecuária: Embrapa Pecuária Sudeste, 2010. p. 24. (Embrapa Instrumentação Agropecuária. Documentos online, 01).

SORENSEN, L.; SHAKER, S.B.; BRUIJNE, M. Quantitative Analysis of Pulmonary Emphysema Using Local Binary Patterns. **IEEE Transactions on Medical Imaging**, Vol. 29, No. 2, 2010.

STEIN, T. Avaliação de descritores de textura para segmentação de imagens. Dissertação (Mestrado engenharia elétrica). Universidade Federal do Paraná, Departamento de Informática, Setor de Ciências Exatas, Brasil, 2005.

SUMATHI, S.; SUREKHA, P. *Computational intelligence paradgms: theory & application using MATLAB*. New York: Talor Francis Group, 2010.

SURULIANDI, A.; RAMAR, K. Local Texture Patterns - A Univariate Texture Model for Classification of Images. In: *16th International Conference on Advanced Computing and Communication*, 2008, p.32-39.

TABA, S; NASU, K; TAKAESU, K; OOSHIRO, A; MOROMIZATO, Z. Detection of Citrus Huanglongbing using an Iodo-starch Reaction. The Science Bulletin of the Faculty of Agriculture. University of the Ryukyus(53): p.19-24, 2006.

TODA FRUTA. História da Laranja. Disponível em: <<http://www.todafruta.com.br/portal/icNoticiaAberta.asp?idNoticia=2382>>. Acesso em: 28 Dez. 2010.

VENÂNCIO, A. L. **Avaliação da precocidade do diagnóstico do greening por técnicas de fluorescência**. 2010. p.111. Dissertação de Mestrado, FFCLRP-USP, Ribeirão Preto, 2010.

VIEIRA, R. T.; CHIERICI, C. E. O.; FERRAZ, C. T.; GONZAGA, A. (2012a). Image micro-pattern analysis using fuzzy numbers, SIBGRAPI 2012 - XXV Conference on Graphics, Patterns and Images, Ouro Preto, MG, August 22-25, pp. 87-93, 2012,

_____ (2012b). Local Fuzzy Pattern: A New Way for Micro-pattern Analysis, IDEAL 2012, H. Yin et al. (Eds.): LNCS 7435, Springer-Verlag Berlin Heidelberg 2012, pp. 602–611, 2012.

VIEIRA, R.T.; FERRAZ, C. T.; LANGONI, V. M.; GONZAGA, A.(2012c); Uma nova proposta para análise de textura local por conjuntos fuzzy, Anais do VIII Workshop de Visão Computacional, WVC'2012, 27 a 30 de maio de 2012, Goiânia, GO, ISSN: 2175-6120, CD, 6 pp.

VIEIRA, R. T.; GONZAGA, A.; Vermiculite ore classification by texture analysis, Anais do IX Workshop de Visão Computacional, WVC'2013, 03 a 05 de junho de 2013, Rio de Janeiro, RJ, ISSN: 2175-6120, CD, 6 pp.

VIEIRA, R. T. *Análise de micropadrões em imagens digitais baseada em números fuzzy*. Dissertação (Mestrado engenharia elétrica). Universidade de São Paulo, Departamento de Engenharia Elétrica, São Carlos - SP, Brasil, 2013.

ZADEH, L. A. *Fuzzy sets. Information and Control*. v.8, p.338-53, 1965.

ZAGHI, A. F. Diagnóstico de doenças de citros utilizando espectroscopia de fluorescência. 2008. Dissertação (Mestrado em Ciência química analítica)- IQ-USP, Universidade de São Paulo, São Paulo, 2008.

WEKA. Disponível em: < <http://www.cs.waikato.ac.nz/ml/weka/> >. Acesso em: 29 abr. 2011.

Apêndice A- Resultados da tabelas da divisão por quadrantes

Tabelas do CVC

Classificado 1Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
1Q-Folha01.jpg	18,689	74,862	0,059	6,390
1Q-Folha02_alt.jpg	6,479	88,131	4,658	0,733
1Q-Folha03.jpg	0,669	0,271	17,004	82,056
1Q-Folha04.jpg	44,342	47,568	0,418	7,672
1Q-Folha05_alt.jpg	0,518	93,895	2,931	2,656
1Q-Folha06.jpg	3,846	78,126	15,123	2,905
1Q-Folha07_alt.jpg	3,252	77,435	11,756	7,556
1Q-Folha08_alt.jpg	61,356	38,546	0,000	0,098
1Q-Folha09_alt.jpg	0,594	78,275	3,872	17,258
1Q-Folha10.jpg	7,684	54,967	28,557	8,792
1Q-Folha11_alt.jpg	22,615	66,706	4,519	6,161
1Q-Folha12_alt.jpg	55,024	44,748	0,114	0,114
1Q-Folha13_alt.jpg	7,102	66,186	0,216	26,496
1Q-Folha14.jpg	37,357	62,320	0,254	0,069
1Q-Folha15_alt.jpg	24,842	60,018	3,222	11,917
1Q-Folha16.jpg	55,960	35,254	2,384	6,402
1Q-Folha17_alt.jpg	22,502	77,237	0,014	0,247
1Q-Folha18.jpg	37,904	61,790	0,253	0,054
1Q-Folha19_alt.jpg	7,235	12,969	0,000	79,796
1Q-Folha20_alt.jpg	24,779	75,209	0,000	0,012
1Q-Folha21_alt.jpg	7,489	79,974	9,919	2,617
1Q-Folha22_alt.jpg	62,796	37,193	0,000	0,011
1Q-Folha23_alt.jpg	0,431	70,409	10,905	18,254
1Q-Folha24.jpg	53,223	40,668	3,037	3,071
1Q-Folha25.jpg	11,312	80,630	0,379	7,679
1Q-Folha26.jpg	35,740	56,983	3,487	3,790
1Q-Folha27.jpg	11,041	88,900	0,048	0,012
1Q-Folha28_alt.jpg	36,687	62,311	0,114	0,888
1Q-Folha29_Alt.jpg	5,880	88,576	0,021	5,523
1Q-Folha30_alt.jpg	10,654	70,732	14,026	4,588
1Q-Folha31_Alt.jpg	28,551	66,064	3,614	1,771
1Q-Folha33_alt.jpg	3,094	43,772	1,626	51,508
1Q-Folha34_alt.jpg	24,518	73,932	0,803	0,747
1Q-Folha35_alt.jpg	8,900	85,275	0,043	5,782
1Q-Folha36.jpg	19,148	79,121	1,127	0,603
1Q-Folha37.jpg	2,897	57,929	22,448	16,726
1Q-Folha38.jpg	15,846	77,940	2,841	3,373
1Q-Folha39.jpg	46,781	47,352	0,385	5,483
1Q-Folha40_alt.jpg	39,519	59,527	0,175	0,779
1Q-Folha41_alt.jpg	22,941	76,887	0,041	0,132

soma	890,198	2538,689	170,391	400,722
------	---------	----------	---------	---------

Classificado 2Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
2Q-Folha01.jpg	36,386	60,311	0,030	3,273
2Q-Folha02_alt.jpg	17,918	78,468	3,007	0,608
2Q-Folha03.jpg	12,145	25,948	12,901	49,006
2Q-Folha04.jpg	56,595	39,466	0,193	3,746
2Q-Folha05_alt.jpg	2,801	94,013	1,675	1,511
2Q-Folha06.jpg	13,071	75,994	8,683	2,252
2Q-Folha07_alt.jpg	13,348	73,728	7,867	5,057
2Q-Folha08_alt.jpg	71,594	28,346	0,000	0,060
2Q-Folha09_alt.jpg	0,550	80,090	7,943	11,417
2Q-Folha10.jpg	22,480	56,828	15,077	5,615
2Q-Folha11_alt.jpg	21,519	71,725	2,661	4,095
2Q-Folha12_alt.jpg	62,229	37,607	0,075	0,090
2Q-Folha13_alt.jpg	59,607	32,375	0,065	7,953
2Q-Folha14.jpg	41,848	57,972	0,137	0,043
2Q-Folha15_alt.jpg	38,490	53,587	1,636	6,287
2Q-Folha16.jpg	44,326	42,047	1,458	12,168
2Q-Folha17_alt.jpg	22,135	77,686	0,009	0,169
2Q-Folha18.jpg	66,881	32,970	0,110	0,039
2Q-Folha19_alt.jpg	30,168	27,913	0,000	41,920
2Q-Folha20_alt.jpg	25,053	72,921	1,136	0,890
2Q-Folha21_alt.jpg	19,816	72,331	6,089	1,764
2Q-Folha22_alt.jpg	62,488	37,499	0,000	0,013
2Q-Folha23_alt.jpg	14,569	74,419	4,082	6,930
2Q-Folha24.jpg	63,494	33,722	1,380	1,403
2Q-Folha25.jpg	33,846	62,125	0,189	3,840
2Q-Folha26.jpg	70,954	26,206	1,343	1,496
2Q-Folha27.jpg	16,801	83,162	0,025	0,012
2Q-Folha28_alt.jpg	34,841	63,894	0,066	1,200
2Q-Folha29_Alt.jpg	43,118	53,947	0,011	2,924
2Q-Folha30_alt.jpg	44,919	45,643	7,098	2,340
2Q-Folha31_Alt.jpg	41,092	56,430	1,633	0,845
2Q-Folha33_alt.jpg	22,672	52,576	0,757	23,995
2Q-Folha34_alt.jpg	24,447	74,553	0,509	0,491
2Q-Folha35_alt.jpg	27,291	69,277	0,025	3,407
2Q-Folha36.jpg	21,396	77,224	0,895	0,484
2Q-Folha37.jpg	7,418	70,634	12,574	9,374
2Q-Folha38.jpg	30,590	65,581	1,386	2,443
2Q-Folha39.jpg	63,225	33,636	0,205	2,933
2Q-Folha40_alt.jpg	42,357	57,138	0,091	0,414
2Q-Folha41_alt.jpg	25,032	74,856	0,025	0,087
soma	1369,515	2304,847	103,043	222,595

Classificado 3Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
3Q-Folha01.jpg	40,041	57,573	0,022	2,364
3Q-Folha02_alt.jpg	22,443	73,825	2,171	1,560
3Q-Folha03.jpg	11,940	45,157	8,943	33,960
3Q-Folha04.jpg	56,851	40,318	0,139	2,693

3Q-Folha05_alt.jpg	7,453	90,278	1,189	1,080
3Q-Folha06.jpg	23,072	69,360	5,996	1,573
3Q-Folha07_alt.jpg	24,049	66,500	5,753	3,698
3Q-Folha08_alt.jpg	78,686	21,275	0,000	0,039
3Q-Folha09_alt.jpg	3,002	81,557	7,205	8,236
3Q-Folha10.jpg	21,738	58,464	13,693	6,105
3Q-Folha11_alt.jpg	27,058	68,453	1,730	2,759
3Q-Folha12_alt.jpg	62,902	36,945	0,051	0,102
3Q-Folha13_alt.jpg	60,688	34,699	0,034	4,578
3Q-Folha14.jpg	39,920	59,844	0,088	0,148
3Q-Folha15_alt.jpg	39,639	55,310	1,007	4,044
3Q-Folha16.jpg	53,399	35,984	1,136	9,482
3Q-Folha17_alt.jpg	30,483	68,282	0,006	1,230
3Q-Folha18.jpg	69,477	30,162	0,107	0,254
3Q-Folha19_alt.jpg	43,515	23,769	0,000	32,716
3Q-Folha20_alt.jpg	21,984	75,346	0,729	1,941
3Q-Folha21_alt.jpg	26,644	68,148	4,038	1,170
3Q-Folha22_alt.jpg	57,894	41,901	0,000	0,206
3Q-Folha23_alt.jpg	20,998	70,500	3,517	4,985
3Q-Folha24.jpg	58,694	39,470	0,910	0,925
3Q-Folha25.jpg	39,326	57,763	0,131	2,779
3Q-Folha26.jpg	71,770	26,375	0,877	0,977
3Q-Folha27.jpg	20,320	79,646	0,017	0,017
3Q-Folha28_alt.jpg	28,923	70,175	0,133	0,768
3Q-Folha29_Alt.jpg	59,929	38,016	0,008	2,047
3Q-Folha30_alt.jpg	43,840	49,669	4,568	1,923
3Q-Folha31_Alt.jpg	47,748	50,627	1,054	0,571
3Q-Folha33_alt.jpg	36,081	48,415	0,474	15,030
3Q-Folha34_alt.jpg	21,529	77,833	0,321	0,317
3Q-Folha35_alt.jpg	45,396	52,328	0,017	2,259
3Q-Folha36.jpg	21,322	77,759	0,592	0,328
3Q-Folha37.jpg	13,915	68,665	9,658	7,762
3Q-Folha38.jpg	28,080	68,982	0,983	1,956
3Q-Folha39.jpg	61,053	36,380	0,173	2,395
3Q-Folha40_alt.jpg	38,577	59,907	0,070	1,446
3Q-Folha41_alt.jpg	24,324	75,204	0,089	0,383
soma	1504,703	2250,863	77,629	166,805

Classificado 4Q(amarelo)				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
4Q-Folha01.jpg	33,717	60,767	2,916	2,601
4Q-Folha02_alt.jpg	22,531	73,046	1,876	2,547
4Q-Folha03.jpg	9,194	35,759	26,118	28,929
4Q-Folha04.jpg	50,572	47,354	0,102	1,973
4Q-Folha05_alt.jpg	6,023	75,251	11,603	7,123
4Q-Folha06.jpg	18,433	71,789	6,281	3,497
4Q-Folha07_alt.jpg	20,361	63,352	12,638	3,649
4Q-Folha08_alt.jpg	65,726	31,506	0,000	2,768
4Q-Folha09_alt.jpg	2,874	77,303	9,301	10,522
4Q-Folha10.jpg	16,666	57,098	17,876	8,360
4Q-Folha11_alt.jpg	27,755	66,374	3,020	2,851

4Q-Folha12_alt.jpg	58,549	41,324	0,041	0,086
4Q-Folha13_alt.jpg	50,244	46,372	0,037	3,348
4Q-Folha14.jpg	31,489	63,774	0,741	3,996
4Q-Folha15_alt.jpg	43,535	51,573	0,774	4,119
4Q-Folha16.jpg	54,506	36,795	0,931	7,768
4Q-Folha17_alt.jpg	29,046	67,655	1,297	2,003
4Q-Folha18.jpg	57,136	42,216	0,078	0,570
4Q-Folha19_alt.jpg	35,714	17,778	0,023	46,485
4Q-Folha20_alt.jpg	20,374	77,417	0,603	1,606
4Q-Folha21_alt.jpg	24,347	70,234	4,430	0,990
4Q-Folha22_alt.jpg	50,628	49,024	0,003	0,345
4Q-Folha23_alt.jpg	16,685	71,347	7,868	4,099
4Q-Folha24.jpg	52,013	45,966	0,728	1,293
4Q-Folha25.jpg	37,826	59,880	0,096	2,198
4Q-Folha26.jpg	57,889	30,785	1,603	9,723
4Q-Folha27.jpg	18,314	81,463	0,036	0,187
4Q-Folha28_alt.jpg	30,892	68,422	0,101	0,585
4Q-Folha29_Alt.jpg	59,585	37,909	0,151	2,355
4Q-Folha30_alt.jpg	34,094	49,466	8,138	8,301
4Q-Folha31_Alt.jpg	36,819	51,610	3,132	8,439
4Q-Folha33_alt.jpg	27,734	53,810	5,561	12,895
4Q-Folha34_alt.jpg	17,633	81,141	0,369	0,858
4Q-Folha35_alt.jpg	55,929	42,376	0,012	1,682
4Q-Folha36.jpg	28,040	71,232	0,447	0,282
4Q-Folha37.jpg	19,730	65,481	8,392	6,397
4Q-Folha38.jpg	21,532	76,265	0,730	1,472
4Q-Folha39.jpg	62,408	35,551	0,136	1,905
4Q-Folha40_alt.jpg	34,295	63,484	0,051	2,169
4Q-Folha41_alt.jpg	22,781	74,825	0,973	1,421
soma	1363,619	2284,772	139,214	212,396

Tabela do Greening

Classificado 1Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
1Q-Folha01_alt.jpg	16,384	81,089	0,262	2,264
1Q-Folha02_alt.jpg	17,980	82,020	0,000	0,000
1Q-Folha03.jpg	85,093	14,897	0,000	0,011
1Q-Folha04.jpg	22,036	77,954	0,000	0,011
1Q-Folha05_alt.jpg	8,571	89,225	1,729	0,474
1Q-Folha06.jpg	23,062	76,929	0,000	0,009
1Q-Folha07.jpg	1,528	48,002	49,297	1,173
1Q-Folha08.jpg	30,276	69,724	0,000	0,000
1Q-Folha09_alt.jpg	21,124	78,265	0,192	0,419
1Q-Folha10.jpg	58,460	41,540	0,000	0,000
1Q-Folha11.jpg	90,578	9,367	0,000	0,055
1Q-Folha12_alt.jpg	33,959	65,910	0,000	0,131
1Q-Folha13.jpg	9,061	90,652	0,000	0,287
1Q-Folha14_alt.jpg	11,417	88,362	0,026	0,195
1Q-Folha15_alt.jpg	14,913	85,043	0,000	0,044
1Q-Folha16_alt.jpg	36,317	63,683	0,000	0,000

1Q-Folha17_alt.jpg	5,501	91,043	2,789	0,666
1Q-Folha18_alt.jpg	3,191	95,030	0,794	0,985
1Q-Folha19.jpg	50,243	49,708	0,012	0,036
1Q-Folha20.jpg	2,416	91,007	6,404	0,173
1Q-Folha21_alt.jpg	3,841	70,060	23,821	2,279
1Q-Folha22.jpg	4,831	93,564	0,695	0,910
1Q-Folha23.jpg	5,600	89,986	4,239	0,174
1Q-Folha24.jpg	3,163	87,715	5,372	3,751
1Q-Folha25.jpg	15,905	83,136	0,663	0,296
1Q-Folha26_alt.jpg	0,960	94,785	3,953	0,302
1Q-Folha27_alt.jpg	3,514	95,101	1,274	0,111
1Q-Folha28_alt.jpg	16,401	83,177	0,141	0,281
1Q-Folha29_alt.jpg	84,815	15,185	0,000	0,000
1Q-Folha30_alt.jpg	8,585	84,044	7,336	0,035
1Q-Folha31.jpg	29,003	70,959	0,000	0,038
1Q-Folha32.jpg	13,306	86,683	0,000	0,011
1Q-Folha33.jpg	6,564	76,007	14,481	2,948
1Q-Folha34.jpg	14,201	85,799	0,000	0,000
1Q-Folha35.jpg	2,390	76,381	20,527	0,702
1Q-Folha36.jpg	4,724	95,013	0,263	0,000
1Q-Folha37_alt.jpg	2,193	65,696	31,039	1,073
1Q-Folha38_alt.jpg	6,034	87,331	2,627	4,008
1Q-Folha39.jpg	2,858	89,330	6,550	1,262
1Q-Folha40_alt.jpg	42,730	57,193	0,000	0,078
soma	813,725	2976,592	184,487	25,195

Classificado 2Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
2Q-Folha01_alt.jpg	11,0651	87,31018	0,180525	1,444197
2Q-Folha02_alt.jpg	12,54476	87,44289	0	0,012347
2Q-Folha03.jpg	82,77499	17,18547	0,011299	0,028247
2Q-Folha04.jpg	18,49134	81,50187	0	0,006796
2Q-Folha05_alt.jpg	5,666686	83,49856	10,07215	0,762598
2Q-Folha06.jpg	26,9611	73,01717	0	0,02173
2Q-Folha07.jpg	1,002287	45,25091	43,87865	9,868156
2Q-Folha08.jpg	31,92088	68,02727	0	0,051856
2Q-Folha09_alt.jpg	26,93206	72,54002	0,250974	0,276936
2Q-Folha10.jpg	74,47345	25,51394	0	0,012612
2Q-Folha11.jpg	83,37669	16,57453	0	0,04878
2Q-Folha12_alt.jpg	30,36287	69,43311	0,036433	0,16759
2Q-Folha13.jpg	17,61199	82,20391	0	0,184097
2Q-Folha14_alt.jpg	8,234681	90,96121	0,647755	0,156355
2Q-Folha15_alt.jpg	18,73472	81,23653	0	0,028756
2Q-Folha16_alt.jpg	49,66077	50,32525	0	0,013989
2Q-Folha17_alt.jpg	3,690348	89,48903	5,20178	1,618843
2Q-Folha18_alt.jpg	2,408459	86,3129	9,535931	1,742706
2Q-Folha19.jpg	34,58836	65,23236	0,086059	0,09323
2Q-Folha20.jpg	3,119584	91,57279	4,735702	0,571924
2Q-Folha21_alt.jpg	2,761249	56,32145	39,2659	1,651401
2Q-Folha22.jpg	4,958722	87,62196	5,076659	2,342661
2Q-Folha23.jpg	4,048785	91,50255	4,29871	0,149955

2Q-Folha24.jpg	3,910872	89,80407	3,918555	2,3665
2Q-Folha25.jpg	18,65343	77,174	3,246995	0,92558
2Q-Folha26_alt.jpg	1,942887	95,04499	2,640501	0,371626
2Q-Folha27_alt.jpg	4,384208	92,56902	2,803605	0,24317
2Q-Folha28_alt.jpg	14,62267	85,02745	0,090487	0,259396
2Q-Folha29_alt.jpg	92,5179	7,472017	0	0,010084
2Q-Folha30_alt.jpg	12,3132	73,93481	12,79809	0,953895
2Q-Folha31.jpg	17,87154	66,26584	15,40179	0,46083
2Q-Folha32.jpg	16,32954	83,57209	0,055334	0,043037
2Q-Folha33.jpg	7,308101	83,02951	7,839451	1,822938
2Q-Folha34.jpg	11,50178	88,46643	0,006358	0,025432
2Q-Folha35.jpg	1,83644	76,22945	19,91196	2,022147
2Q-Folha36.jpg	4,329994	94,3858	0,853896	0,43031
2Q-Folha37_alt.jpg	1,430605	35,49547	61,64332	1,430605
2Q-Folha38_alt.jpg	9,80587	85,92725	1,649772	2,617107
2Q-Folha39.jpg	2,021108	76,25026	18,45209	3,27654
2Q-Folha40_alt.jpg	32,96237	66,99261	0	0,045031
soma	809,132	2877,717	274,591	38,560

Classificado 3Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
3Q-Folha01_alt.jpg	15,05826	83,73589	0,125763	1,080081
3Q-Folha02_alt.jpg	11,76215	88,20227	0,003954	0,031629
3Q-Folha03.jpg	69,79985	30,1742	0,007413	0,018532
3Q-Folha04.jpg	19,10338	80,88706	0	0,009559
3Q-Folha05_alt.jpg	4,007966	83,90175	10,76674	1,323542
3Q-Folha06.jpg	26,85199	73,1331	0	0,014905
3Q-Folha07.jpg	1,115018	64,37087	28,13706	6,377048
3Q-Folha08.jpg	23,6545	76,30787	0	0,037636
3Q-Folha09_alt.jpg	17,46171	76,45606	5,418016	0,664215
3Q-Folha10.jpg	81,11073	18,82762	0	0,061658
3Q-Folha11.jpg	87,0639	12,89983	0	0,036266
3Q-Folha12_alt.jpg	20,74536	78,97476	0,073652	0,206226
3Q-Folha13.jpg	18,87119	80,98338	0	0,145429
3Q-Folha14_alt.jpg	5,896149	93,58319	0,422159	0,098504
3Q-Folha15_alt.jpg	14,78338	85,19343	0,004639	0,018555
3Q-Folha16_alt.jpg	40,30417	59,68681	0	0,009026
3Q-Folha17_alt.jpg	2,262277	85,0469	11,55968	1,131138
3Q-Folha18_alt.jpg	1,607259	89,8315	7,219702	1,341542
3Q-Folha19.jpg	28,29179	71,58286	0,062678	0,062678
3Q-Folha20.jpg	2,310675	87,98834	9,217063	0,483928
3Q-Folha21_alt.jpg	1,979391	48,45435	46,67146	2,8948
3Q-Folha22.jpg	3,854207	86,61497	7,134549	2,396278
3Q-Folha23.jpg	2,894233	93,94907	3,050294	0,106406
3Q-Folha24.jpg	3,256491	92,51638	2,72264	1,504489
3Q-Folha25.jpg	12,71682	70,20194	15,97233	1,108907
3Q-Folha26_alt.jpg	5,245886	92,46179	2,013127	0,279193
3Q-Folha27_alt.jpg	2,975617	93,90642	2,883776	0,234192
3Q-Folha28_alt.jpg	19,453	80,22496	0,102679	0,21936
3Q-Folha29_alt.jpg	94,844	5,149731	0	0,006265
3Q-Folha30_alt.jpg	8,494148	79,84395	11,0065	0,655397

3Q-Folha31.jpg	11,51901	73,90356	14,23864	0,338794
3Q-Folha32.jpg	11,61975	88,3118	0,038504	0,029948
3Q-Folha33.jpg	4,669098	55,23189	33,70506	6,393955
3Q-Folha34.jpg	8,895974	90,74818	0,295762	0,060077
3Q-Folha35.jpg	1,627941	82,09748	14,83986	1,434713
3Q-Folha36.jpg	2,78524	95,23941	1,378793	0,596555
3Q-Folha37_alt.jpg	0,93508	29,20177	68,28519	1,577948
3Q-Folha38_alt.jpg	12,73251	84,31973	1,137974	1,809789
3Q-Folha39.jpg	1,282219	84,68752	11,8409	2,189367
3Q-Folha40_alt.jpg	23,25396	76,71816	0	0,027873
soma	727,096	2925,551	310,337	37,016

Classificado 4Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
4Q-Folha01_alt.jpg	17,721	81,126	0,106	1,047
4Q-Folha02_alt.jpg	12,175	87,796	0,003	0,025
4Q-Folha03.jpg	63,802	36,179	0,006	0,014
4Q-Folha04.jpg	20,842	79,151	0,000	0,007
4Q-Folha05_alt.jpg	5,517	85,302	8,096	1,084
4Q-Folha06.jpg	27,298	72,690	0,000	0,012
4Q-Folha07.jpg	1,075	72,044	21,977	4,904
4Q-Folha08.jpg	19,133	80,837	0,000	0,030
4Q-Folha09_alt.jpg	13,587	76,276	8,569	1,568
4Q-Folha10.jpg	83,615	16,341	0,000	0,045
4Q-Folha11.jpg	89,176	10,791	0,000	0,034
4Q-Folha12_alt.jpg	15,962	83,747	0,136	0,155
4Q-Folha13.jpg	16,618	83,266	0,000	0,117
4Q-Folha14_alt.jpg	6,356	93,215	0,352	0,076
4Q-Folha15_alt.jpg	11,766	88,213	0,004	0,018
4Q-Folha16_alt.jpg	34,361	65,632	0,000	0,007
4Q-Folha17_alt.jpg	1,742	87,144	10,204	0,910
4Q-Folha18_alt.jpg	1,514	91,890	5,574	1,021
4Q-Folha19.jpg	24,241	75,598	0,067	0,094
4Q-Folha20.jpg	1,942	89,488	8,174	0,396
4Q-Folha21_alt.jpg	1,555	53,492	39,860	5,094
4Q-Folha22.jpg	3,275	88,982	5,787	1,955
4Q-Folha23.jpg	2,291	94,419	3,172	0,117
4Q-Folha24.jpg	2,579	92,022	4,139	1,260
4Q-Folha25.jpg	9,865	60,735	28,410	0,990
4Q-Folha26_alt.jpg	4,237	93,166	2,360	0,237
4Q-Folha27_alt.jpg	2,424	94,217	2,957	0,402
4Q-Folha28_alt.jpg	21,775	77,833	0,089	0,302
4Q-Folha29_alt.jpg	91,900	8,095	0,000	0,005
4Q-Folha30_alt.jpg	6,526	80,413	12,227	0,834
4Q-Folha31.jpg	9,412	78,722	11,586	0,280
4Q-Folha32.jpg	9,850	90,094	0,032	0,025
4Q-Folha33.jpg	3,609	45,896	41,313	9,182
4Q-Folha34.jpg	7,916	91,787	0,224	0,074
4Q-Folha35.jpg	1,347	78,681	18,408	1,565
4Q-Folha36.jpg	2,317	96,053	1,152	0,477
4Q-Folha37_alt.jpg	0,708	35,934	61,200	2,158

4Q-Folha38_alt.jpg	10,800	86,474	1,080	1,645
4Q-Folha39.jpg	1,096	86,725	10,257	1,923
4Q-Folha40_alt.jpg	19,422	80,557	0,000	0,021
soma	681,348	2971,023	307,521	40,108

Tabela do Magnésio

Classificado 1Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
1Q-Folha01_alt.jpg	55,371	44,525	0,000	0,104
1Q-Folha02_alt.jpg	52,066	47,913	0,000	0,021
1Q-Folha03_alt.jpg	4,088	64,584	13,212	18,116
1Q-Folha06_alt.jpg	12,896	82,697	0,526	3,881
1Q-Folha07.jpg	53,054	46,935	0,000	0,011
1Q-Folha08.jpg	54,913	44,314	0,303	0,471
1Q-Folha09.jpg	53,029	46,959	0,000	0,012
1Q-Folha11.jpg	6,483	48,024	14,097	31,396
1Q-Folha13.jpg	15,820	74,491	6,394	3,294
1Q-Folha14.jpg	89,418	10,560	0,000	0,022
1Q-Folha15.jpg	12,260	84,348	0,842	2,550
1Q-Folha16.jpg	29,529	70,471	0,000	0,000
1Q-Folha17_alt.jpg	37,593	62,154	0,011	0,242
1Q-Folha18_alt.jpg	36,576	63,411	0,000	0,014
1Q-Folha19_alt.jpg	25,422	70,821	1,191	2,567
1Q-Folha20.jpg	47,724	52,114	0,101	0,061
1Q-Folha21_alt.jpg	64,187	35,600	0,187	0,027
1Q-Folha22_alt.jpg	14,326	81,653	1,996	2,025
1Q-Folha23_alt.jpg	55,496	44,455	0,000	0,049
1Q-Folha24_alt.jpg	31,821	67,740	0,297	0,142
1Q-Folha25.jpg	54,000	45,971	0,000	0,029
1Q-Folha26_alt.jpg	41,457	58,521	0,000	0,021
1Q-Folha27_alt.jpg	84,859	15,078	0,000	0,064
1Q-Folha28_alt.jpg	16,946	74,522	6,686	1,846
1Q-Folha29.jpg	8,309	80,796	3,583	7,311
1Q-Folha30.jpg	27,298	72,692	0,000	0,010
1Q-Folha31_alt.jpg	80,723	19,277	0,000	0,000
1Q-Folha32.jpg	27,515	72,361	0,102	0,023
1Q-Folha33_alt.jpg	49,623	50,377	0,000	0,000
1Q-Folha34_alt.jpg	35,972	63,825	0,000	0,203
1Q-Folha35_alt.jpg	23,257	73,995	1,166	1,582
1Q-Folha36.jpg	60,259	39,717	0,000	0,024
1Q-Folha37_alt.jpg	17,107	76,325	3,134	3,433
1Q-Folha38_alt.jpg	37,677	62,300	0,000	0,023
1Q-Folha39.jpg	15,268	77,485	6,190	1,057
1Q-Folha40.jpg	27,456	72,544	0,000	0,000
1Q-Folha41.jpg	41,513	57,856	0,035	0,596
1Q-Folha42_alt.jpg	8,372	45,848	36,643	9,137
1Q-Folha43_alt.jpg	14,754	84,698	0,000	0,548
1Q-Folha44_alt.jpg	56,015	43,907	0,000	0,077
soma	1480,452	2331,862	96,698	90,988

Classificado 2Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
2Q-Folha01_alt.jpg	51,572	48,260	0,041	0,127
2Q-Folha02_alt.jpg	57,779	42,185	0,000	0,036
2Q-Folha03_alt.jpg	6,935	70,782	8,269	14,014
2Q-Folha06_alt.jpg	19,017	76,470	1,278	3,235
2Q-Folha07.jpg	40,354	59,640	0,000	0,006
2Q-Folha08.jpg	36,545	62,403	0,423	0,630
2Q-Folha09.jpg	49,660	50,327	0,000	0,013
2Q-Folha11.jpg	10,749	50,474	11,081	27,695
2Q-Folha13.jpg	34,168	58,888	4,281	2,663
2Q-Folha14.jpg	73,463	26,519	0,000	0,018
2Q-Folha15.jpg	13,619	84,042	0,894	1,446
2Q-Folha16.jpg	34,991	64,993	0,000	0,016
2Q-Folha17_alt.jpg	34,416	65,348	0,013	0,223
2Q-Folha18_alt.jpg	38,437	61,549	0,000	0,013
2Q-Folha19_alt.jpg	36,819	60,545	0,870	1,766
2Q-Folha20.jpg	53,154	46,739	0,059	0,047
2Q-Folha21_alt.jpg	61,163	38,572	0,210	0,056
2Q-Folha22_alt.jpg	17,810	78,150	1,819	2,220
2Q-Folha23_alt.jpg	58,179	41,788	0,000	0,032
2Q-Folha24_alt.jpg	48,186	51,512	0,189	0,113
2Q-Folha25.jpg	56,367	43,605	0,000	0,028
2Q-Folha26_alt.jpg	53,738	46,221	0,000	0,041
2Q-Folha27_alt.jpg	84,937	15,024	0,000	0,039
2Q-Folha28_alt.jpg	28,053	61,950	8,221	1,776
2Q-Folha29.jpg	13,291	79,787	2,398	4,525
2Q-Folha30.jpg	33,784	66,185	0,000	0,031
2Q-Folha31_alt.jpg	81,465	18,517	0,000	0,019
2Q-Folha32.jpg	48,140	51,779	0,056	0,025
2Q-Folha33_alt.jpg	48,040	51,954	0,000	0,006
2Q-Folha34_alt.jpg	42,446	57,432	0,000	0,122
2Q-Folha35_alt.jpg	27,715	67,572	3,092	1,621
2Q-Folha36.jpg	48,692	51,258	0,000	0,050
2Q-Folha37_alt.jpg	37,241	57,523	2,806	2,430
2Q-Folha38_alt.jpg	62,304	37,635	0,000	0,061
2Q-Folha39.jpg	9,866	70,185	19,060	0,890
2Q-Folha40.jpg	24,264	75,612	0,000	0,124
2Q-Folha41.jpg	44,094	55,273	0,056	0,577
2Q-Folha42_alt.jpg	27,631	43,162	23,216	5,991
2Q-Folha43_alt.jpg	18,385	80,658	0,000	0,957
2Q-Folha44_alt.jpg	52,784	47,138	0,016	0,063
soma	1620,252	2217,658	88,345	73,745

Classificado 4Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
4Q-Folha01_alt.jpg	35,674	60,540	0,413	3,372
4Q-Folha02_alt.jpg	37,544	62,198	0,043	0,215
4Q-Folha03_alt.jpg	6,434	78,368	4,858	10,339
4Q-Folha06_alt.jpg	25,979	71,744	0,642	1,635
4Q-Folha07.jpg	44,206	55,730	0,026	0,039

4Q-Folha08.jpg	32,984	66,482	0,208	0,326
4Q-Folha09.jpg	50,752	49,241	0,000	0,007
4Q-Folha11.jpg	14,249	65,412	5,837	14,502
4Q-Folha13.jpg	25,005	65,044	3,161	6,789
4Q-Folha14.jpg	41,910	53,133	3,652	1,305
4Q-Folha15.jpg	14,018	84,332	0,902	0,747
4Q-Folha16.jpg	32,214	67,453	0,000	0,334
4Q-Folha17_alt.jpg	24,850	74,616	0,120	0,414
4Q-Folha18_alt.jpg	34,068	65,879	0,028	0,025
4Q-Folha19_alt.jpg	30,873	67,507	0,485	1,135
4Q-Folha20.jpg	40,448	59,393	0,125	0,034
4Q-Folha21_alt.jpg	55,438	44,103	0,216	0,243
4Q-Folha22_alt.jpg	15,464	81,448	1,099	1,989
4Q-Folha23_alt.jpg	67,062	32,922	0,000	0,017
4Q-Folha24_alt.jpg	43,689	55,740	0,291	0,280
4Q-Folha25.jpg	48,023	51,962	0,000	0,015
4Q-Folha26_alt.jpg	43,574	56,405	0,000	0,022
4Q-Folha27_alt.jpg	80,874	19,105	0,000	0,021
4Q-Folha28_alt.jpg	33,089	62,226	3,833	0,852
4Q-Folha29.jpg	12,240	82,246	2,141	3,374
4Q-Folha30.jpg	33,619	66,365	0,000	0,017
4Q-Folha31_alt.jpg	67,475	32,490	0,006	0,029
4Q-Folha32.jpg	34,381	55,742	7,877	2,000
4Q-Folha33_alt.jpg	45,405	54,592	0,000	0,003
4Q-Folha34_alt.jpg	44,815	55,119	0,000	0,066
4Q-Folha35_alt.jpg	32,108	65,391	1,603	0,898
4Q-Folha36.jpg	45,096	54,005	0,000	0,899
4Q-Folha37_alt.jpg	41,487	55,413	1,591	1,509
4Q-Folha38_alt.jpg	40,733	55,135	1,852	2,280
4Q-Folha39.jpg	6,420	75,818	16,969	0,793
4Q-Folha40.jpg	16,014	83,129	0,150	0,707
4Q-Folha41.jpg	27,759	67,501	2,340	2,400
4Q-Folha42_alt.jpg	30,105	52,925	13,132	3,838
4Q-Folha43_alt.jpg	15,871	83,286	0,039	0,804
4Q-Folha44_alt.jpg	47,245	52,715	0,008	0,032
soma	1419,196	2442,853	73,649	64,303

Tabela do Manganês

Classificado 1Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
1Q-Folha01_alt.jpg	53,062	46,938	0,000	0,000
1Q-Folha02a.jpg	83,840	16,160	0,000	0,000
1Q-Folha03a_alt.jpg	57,514	42,486	0,000	0,000
1Q-Folha04a_alt.jpg	76,567	23,400	0,000	0,033
1Q-Folha05.jpg	20,450	79,550	0,000	0,000
1Q-Folha06_alt.jpg	70,387	29,578	0,000	0,035
1Q-Folha07a.jpg	76,559	23,392	0,033	0,016
1Q-Folha08a.jpg	76,185	23,815	0,000	0,000
1Q-Folha09a_alt.jpg	36,793	63,177	0,010	0,020
1Q-Folha10a_alt.jpg	68,099	31,901	0,000	0,000
1Q-Folha11a_alt.jpg	24,768	75,232	0,000	0,000

1Q-Folha12a.jpg	79,101	20,899	0,000	0,000
1Q-Folha13a_alt.jpg	19,529	80,459	0,012	0,000
1Q-Folha14a_alt.jpg	80,508	19,471	0,000	0,021
1Q-Folha15.jpg	60,860	39,140	0,000	0,000
1Q-Folha16a.jpg	80,699	19,290	0,000	0,011
1Q-Folha17a.jpg	32,293	67,707	0,000	0,000
1Q-Folha18a_alt.jpg	31,479	68,510	0,000	0,010
1Q-Folha19a_alt.jpg	36,169	63,818	0,000	0,012
1Q-Folha20a.jpg	55,117	44,851	0,000	0,032
1Q-Folha21a_alt.jpg	20,364	79,636	0,000	0,000
1Q-Folha22a.jpg	43,889	56,098	0,000	0,014
1Q-Folha23a_alt.jpg	70,680	29,320	0,000	0,000
1Q-Folha24a_alt.jpg	65,534	34,456	0,000	0,011
1Q-Folha25a.jpg	23,070	76,878	0,013	0,039
1Q-Folha26a_alt.jpg	62,145	37,835	0,000	0,020
1Q-Folha27a_alt.jpg	75,893	23,781	0,000	0,326
1Q-Folha28a.jpg	63,087	36,851	0,000	0,062
1Q-Folha29_alt.jpg	41,155	58,845	0,000	0,000
1Q-Folha30.jpg	73,089	26,895	0,000	0,016
1Q-Folha30_alt.jpg	72,712	27,243	0,000	0,045
1Q-Folha31a.jpg	21,202	78,787	0,000	0,011
1Q-Folha32_alt.jpg	86,464	13,515	0,000	0,021
1Q-Folha33a-alt.jpg	39,426	60,561	0,000	0,013
1Q-Folha34a_alt.jpg	66,211	33,760	0,000	0,029
1Q-Folha35a_alt.jpg	19,579	80,377	0,011	0,033
1Q-Folha36a_alt.jpg	83,040	16,909	0,000	0,051
1Q-Folha37_alt.jpg	64,686	35,304	0,000	0,010
1Q-Folha38a.jpg	83,138	16,847	0,000	0,015
1Q-Folha39a_alt.jpg	83,832	16,168	0,000	0,000
1Q-Folha40a_alt.jpg	49,245	50,746	0,000	0,008
soma	2328,421	1770,586	0,079	0,913

Classificado 2Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
2Q-Folha01_alt.jpg	61,151	38,843	0,000	0,006
2Q-Folha02a.jpg	86,613	13,381	0,000	0,006
2Q-Folha03a_alt.jpg	71,010	28,985	0,000	0,006
2Q-Folha04a_alt.jpg	72,201	27,777	0,000	0,021
2Q-Folha05.jpg	30,766	69,226	0,000	0,007
2Q-Folha06_alt.jpg	83,437	16,541	0,000	0,022
2Q-Folha07a.jpg	82,743	17,223	0,017	0,017
2Q-Folha08a.jpg	85,136	14,855	0,000	0,009
2Q-Folha09a_alt.jpg	47,973	51,941	0,005	0,080
2Q-Folha10a_alt.jpg	78,590	21,390	0,000	0,019
2Q-Folha11a_alt.jpg	26,844	73,150	0,000	0,007
2Q-Folha12a.jpg	87,209	12,784	0,000	0,006
2Q-Folha13a_alt.jpg	20,902	79,085	0,006	0,006
2Q-Folha14a_alt.jpg	85,896	14,084	0,000	0,020
2Q-Folha15.jpg	54,685	45,310	0,000	0,005
2Q-Folha16a.jpg	83,155	16,834	0,000	0,011
2Q-Folha17a.jpg	39,459	60,534	0,000	0,007

2Q-Folha18a_alt.jpg	30,277	69,713	0,000	0,010
2Q-Folha19a_alt.jpg	54,612	45,376	0,000	0,012
2Q-Folha20a.jpg	65,679	34,299	0,000	0,022
2Q-Folha21a_alt.jpg	39,343	60,650	0,000	0,007
2Q-Folha22a.jpg	40,400	59,585	0,000	0,015
2Q-Folha23a_alt.jpg	80,631	19,364	0,000	0,006
2Q-Folha24a_alt.jpg	69,834	30,137	0,000	0,029
2Q-Folha25a.jpg	27,300	72,667	0,007	0,026
2Q-Folha26a_alt.jpg	56,772	43,201	0,000	0,027
2Q-Folha27a_alt.jpg	83,714	16,125	0,000	0,161
2Q-Folha28a.jpg	63,113	36,733	0,000	0,154
2Q-Folha29_alt.jpg	50,270	49,725	0,000	0,006
2Q-Folha30.jpg	78,427	21,560	0,000	0,013
2Q-Folha30_alt.jpg	78,613	21,358	0,000	0,029
2Q-Folha31a.jpg	16,238	83,751	0,000	0,010
2Q-Folha32_alt.jpg	90,853	9,132	0,000	0,015
2Q-Folha33a-alt.jpg	54,270	45,717	0,000	0,013
2Q-Folha34a_alt.jpg	75,079	24,901	0,000	0,021
2Q-Folha35a_alt.jpg	28,080	71,893	0,005	0,021
2Q-Folha36a_alt.jpg	86,369	13,600	0,000	0,031
2Q-Folha37_alt.jpg	63,325	36,665	0,000	0,010
2Q-Folha38a.jpg	87,828	12,146	0,000	0,026
2Q-Folha39a_alt.jpg	84,258	15,735	0,000	0,007
2Q-Folha40a_alt.jpg	57,028	42,953	0,000	0,019
soma	2560,082	1538,930	0,040	0,947

Classificado 3Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
3Q-Folha01_alt.jpg	63,228	36,760	0,000	0,012
3Q-Folha02a.jpg	84,048	15,948	0,000	0,004
3Q-Folha03a_alt.jpg	70,439	29,503	0,008	0,050
3Q-Folha04a_alt.jpg	78,087	21,896	0,000	0,017
3Q-Folha05.jpg	38,812	61,183	0,000	0,005
3Q-Folha06_alt.jpg	67,700	32,285	0,000	0,015
3Q-Folha07a.jpg	83,553	16,415	0,013	0,019
3Q-Folha08a.jpg	89,879	10,111	0,000	0,011
3Q-Folha09a_alt.jpg	52,533	47,246	0,066	0,155
3Q-Folha10a_alt.jpg	75,830	24,156	0,000	0,013
3Q-Folha11a_alt.jpg	29,334	70,662	0,000	0,004
3Q-Folha12a.jpg	90,701	9,295	0,000	0,004
3Q-Folha13a_alt.jpg	29,003	70,979	0,005	0,014
3Q-Folha14a_alt.jpg	87,701	12,286	0,000	0,014
3Q-Folha15.jpg	58,778	41,206	0,000	0,017
3Q-Folha16a.jpg	82,452	17,539	0,000	0,009
3Q-Folha17a.jpg	43,488	56,488	0,000	0,023
3Q-Folha18a_alt.jpg	27,851	72,108	0,017	0,024
3Q-Folha19a_alt.jpg	59,202	40,721	0,000	0,077
3Q-Folha20a.jpg	68,893	31,092	0,000	0,015
3Q-Folha21a_alt.jpg	41,629	58,367	0,000	0,005
3Q-Folha22a.jpg	31,485	68,505	0,000	0,010
3Q-Folha23a_alt.jpg	86,393	13,603	0,000	0,004

3Q-Folha24a_alt.jpg	73,497	26,484	0,000	0,019
3Q-Folha25a.jpg	26,269	73,709	0,005	0,018
3Q-Folha26a_alt.jpg	63,331	36,651	0,000	0,018
3Q-Folha27a_alt.jpg	83,348	16,537	0,000	0,115
3Q-Folha28a.jpg	59,053	40,761	0,000	0,186
3Q-Folha29_alt.jpg	61,500	38,496	0,000	0,004
3Q-Folha30.jpg	75,643	24,348	0,000	0,009
3Q-Folha30_alt.jpg	76,042	23,937	0,000	0,020
3Q-Folha31a.jpg	24,844	75,149	0,000	0,007
3Q-Folha32_alt.jpg	91,534	8,456	0,000	0,010
3Q-Folha33a-alt.jpg	55,859	44,124	0,000	0,017
3Q-Folha34a_alt.jpg	80,684	19,299	0,000	0,017
3Q-Folha35a_alt.jpg	37,694	62,256	0,004	0,046
3Q-Folha36a_alt.jpg	86,142	13,833	0,000	0,025
3Q-Folha37_alt.jpg	55,538	44,455	0,000	0,007
3Q-Folha38a.jpg	90,537	9,447	0,000	0,016
3Q-Folha39a_alt.jpg	89,257	10,738	0,000	0,005
3Q-Folha40a_alt.jpg	56,188	43,798	0,000	0,014
soma	2627,979	1470,832	0,116	1,073

Classificado 4Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
4Q-Folha01_alt.jpg	63,008	36,979	0,000	0,012
4Q-Folha02a.jpg	81,717	18,276	0,000	0,007
4Q-Folha03a_alt.jpg	68,173	31,779	0,006	0,041
4Q-Folha04a_alt.jpg	76,205	23,779	0,000	0,015
4Q-Folha05.jpg	45,996	53,997	0,000	0,007
4Q-Folha06_alt.jpg	57,345	42,636	0,000	0,020
4Q-Folha07a.jpg	81,765	18,206	0,010	0,019
4Q-Folha08a.jpg	89,213	10,775	0,000	0,012
4Q-Folha09a_alt.jpg	46,270	53,536	0,057	0,137
4Q-Folha10a_alt.jpg	63,561	36,426	0,000	0,013
4Q-Folha11a_alt.jpg	32,822	67,172	0,000	0,006
4Q-Folha12a.jpg	87,488	12,506	0,000	0,006
4Q-Folha13a_alt.jpg	31,972	68,011	0,004	0,014
4Q-Folha14a_alt.jpg	83,238	16,749	0,000	0,013
4Q-Folha15.jpg	62,520	37,465	0,000	0,015
4Q-Folha16a.jpg	81,596	18,394	0,000	0,010
4Q-Folha17a.jpg	45,660	54,316	0,000	0,025
4Q-Folha18a_alt.jpg	25,988	73,978	0,013	0,021
4Q-Folha19a_alt.jpg	56,669	43,246	0,000	0,085
4Q-Folha20a.jpg	63,421	36,564	0,000	0,015
4Q-Folha21a_alt.jpg	40,400	59,593	0,000	0,007
4Q-Folha22a.jpg	26,611	73,377	0,000	0,012
4Q-Folha23a_alt.jpg	87,172	12,818	0,000	0,009
4Q-Folha24a_alt.jpg	67,396	32,586	0,000	0,018
4Q-Folha25a.jpg	26,402	73,573	0,004	0,022
4Q-Folha26a_alt.jpg	58,375	41,608	0,000	0,017
4Q-Folha27a_alt.jpg	79,098	20,812	0,000	0,091
4Q-Folha28a.jpg	55,818	44,037	0,000	0,145

4Q-Folha29_alt.jpg	61,024	38,958	0,000	0,018
4Q-Folha30.jpg	70,611	29,379	0,000	0,009
4Q-Folha30_alt.jpg	70,652	29,330	0,000	0,018
4Q-Folha31a.jpg	34,212	65,778	0,000	0,010
4Q-Folha32_alt.jpg	89,396	10,594	0,000	0,010
4Q-Folha33a-alt.jpg	54,064	45,920	0,000	0,016
4Q-Folha34a_alt.jpg	79,817	20,167	0,000	0,016
4Q-Folha35a_alt.jpg	41,380	58,579	0,003	0,038
4Q-Folha36a_alt.jpg	84,716	15,263	0,000	0,021
4Q-Folha37_alt.jpg	56,176	43,816	0,000	0,008
4Q-Folha38a.jpg	88,036	11,949	0,000	0,015
4Q-Folha39a_alt.jpg	90,352	9,640	0,000	0,008
4Q-Folha40a_alt.jpg	53,214	46,772	0,000	0,014
soma	2559,552	1539,336	0,095	1,017

Tabela do Rubelose

Classificado 1Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
1Q-Folha01a.jpg	4,927	94,419	0,000	0,653
1Q-Folha02a_alt.jpg	78,006	21,956	0,037	0,000
1Q-Folha03a.jpg	0,862	82,000	3,853	13,284
1Q-Folha04_alt.jpg	20,527	79,324	0,112	0,037
1Q-Folha05a_alt.jpg	5,905	94,095	0,000	0,000
1Q-Folha06_alt.jpg	3,103	81,752	13,938	1,207
1Q-Folha07a.jpg	10,254	58,349	0,977	30,421
1Q-Folha08a.jpg	0,396	10,208	0,424	88,972
1Q-Folha09.jpg	0,087	4,345	59,671	35,897
1Q-Folha11.jpg	1,188	82,576	0,915	15,321
1Q-Folha12a.jpg	55,178	44,799	0,000	0,023
1Q-Folha13a.jpg	8,652	91,064	0,000	0,284
1Q-Folha14_alt.jpg	0,686	3,129	3,308	92,877
1Q-Folha15a.jpg	7,428	92,199	0,249	0,124
1Q-Folha16_alt.jpg	5,491	93,776	0,240	0,492
1Q-Folha17_alt.jpg	1,616	80,683	1,248	16,452
1Q-Folha18.jpg	1,809	97,261	0,258	0,672
1Q-Folha19a_alt.jpg	20,255	79,444	0,015	0,285
1Q-Folha20a_alt.jpg	4,979	50,481	0,604	43,936
1Q-Folha21.jpg	57,051	41,322	0,641	0,985
1Q-Folha22a.jpg	14,861	68,689	0,341	16,109
1Q-Folha23a_alt.jpg	1,053	89,202	5,520	4,225
1Q-Folha24a_alt.jpg	9,443	90,509	0,000	0,049
1Q-Folha25.jpg	2,577	97,135	0,264	0,024
1Q-Folha26a.jpg	2,090	55,672	30,114	12,125
1Q-Folha27a.jpg	2,956	89,388	6,862	0,794
1Q-Folha28_alt.jpg	5,075	1,703	0,145	93,077
1Q-Folha29a_alt.jpg	2,097	97,903	0,000	0,000
1Q-Folha30_alt.jpg	0,333	6,271	87,026	6,370
1Q-Folha31_alt.jpg	41,704	52,481	0,000	5,815
1Q-Folha32a_alt.jpg	18,258	81,105	0,000	0,637
1Q-Folha33_alt.jpg	0,354	91,461	7,841	0,344
1Q-Folha34a_alt.jpg	2,059	54,797	37,426	5,718

1Q-Folha35.jpg	11,108	58,632	0,127	30,133
1Q-Folha36.jpg	21,892	40,026	0,010	38,072
1Q-Folha37_alt.jpg	41,453	58,547	0,000	0,000
1Q-Folha38a_alt.jpg	10,454	89,463	0,070	0,014
1Q-Folha39_alt.jpg	28,571	42,834	0,012	28,583
1Q-Folha40a.jpg	1,628	38,962	2,713	56,697
1Q-Folha41a.jpg	1,442	3,433	0,000	95,125
soma	507,810	2491,394	264,961	735,834

Classificado 2Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
2Q-Folha01a.jpg	14,882	70,072	0,000	15,046
2Q-Folha02a_alt.jpg	73,701	25,904	0,240	0,155
2Q-Folha03a.jpg	0,540	68,374	16,086	15,000
2Q-Folha04_alt.jpg	18,663	80,004	1,259	0,074
2Q-Folha05a_alt.jpg	3,726	90,710	4,487	1,076
2Q-Folha06_alt.jpg	4,339	85,238	9,404	1,020
2Q-Folha07a.jpg	23,829	54,483	0,516	21,172
2Q-Folha08a.jpg	0,629	35,931	0,727	62,713
2Q-Folha09.jpg	0,061	9,343	59,103	31,493
2Q-Folha11.jpg	0,874	83,764	0,953	14,410
2Q-Folha12a.jpg	44,702	54,259	0,120	0,920
2Q-Folha13a.jpg	19,085	79,729	0,000	1,185
2Q-Folha14_alt.jpg	0,852	15,674	5,141	78,333
2Q-Folha15a.jpg	14,378	83,710	1,756	0,156
2Q-Folha16_alt.jpg	4,534	95,089	0,120	0,257
2Q-Folha17_alt.jpg	1,374	75,018	0,983	22,625
2Q-Folha18.jpg	1,073	94,479	3,572	0,875
2Q-Folha19a_alt.jpg	23,506	76,044	0,075	0,374
2Q-Folha20a_alt.jpg	5,243	64,310	0,406	30,041
2Q-Folha21.jpg	42,420	53,309	1,931	2,341
2Q-Folha22a.jpg	13,307	75,852	0,699	10,142
2Q-Folha23a_alt.jpg	6,860	86,365	3,583	3,192
2Q-Folha24a_alt.jpg	15,114	80,935	3,456	0,495
2Q-Folha25.jpg	2,289	93,829	3,167	0,715
2Q-Folha26a.jpg	2,434	61,006	25,879	10,680
2Q-Folha27a.jpg	3,332	88,149	7,534	0,985
2Q-Folha28_alt.jpg	9,444	3,599	0,074	86,882
2Q-Folha29a_alt.jpg	2,490	97,482	0,018	0,009
2Q-Folha30_alt.jpg	0,504	12,856	80,897	5,744
2Q-Folha31_alt.jpg	47,344	49,217	0,000	3,439
2Q-Folha32a_alt.jpg	17,900	81,033	0,530	0,537
2Q-Folha33_alt.jpg	0,252	86,386	13,097	0,265
2Q-Folha34a_alt.jpg	8,211	65,948	22,455	3,387
2Q-Folha35.jpg	14,678	54,970	0,300	30,053
2Q-Folha36.jpg	19,127	33,962	0,006	46,905
2Q-Folha37_alt.jpg	25,856	72,426	0,850	0,867
2Q-Folha38a_alt.jpg	11,592	88,365	0,036	0,007
2Q-Folha39_alt.jpg	23,163	51,801	0,006	25,031
2Q-Folha40a.jpg	2,214	53,433	1,882	42,471
2Q-Folha41a.jpg	2,745	3,527	0,000	93,728

soma	527,267	2536,585	271,349	664,799

Classificado 3Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
3Q-Folha01a.jpg	11,793	65,135	0,764	22,308
3Q-Folha02a_alt.jpg	61,533	38,085	0,209	0,174
3Q-Folha03a.jpg	1,900	68,820	15,938	13,342
3Q-Folha04_alt.jpg	13,752	85,270	0,851	0,127
3Q-Folha05a_alt.jpg	5,376	91,118	2,823	0,682
3Q-Folha06_alt.jpg	7,530	85,196	6,368	0,906
3Q-Folha07a.jpg	16,051	41,275	0,343	42,331
3Q-Folha08a.jpg	0,749	34,199	3,666	61,386
3Q-Folha09.jpg	0,323	7,542	44,787	47,348
3Q-Folha11.jpg	1,965	70,823	2,080	25,131
3Q-Folha12a.jpg	43,325	56,004	0,077	0,594
3Q-Folha13a.jpg	22,060	74,922	0,000	3,019
3Q-Folha14_alt.jpg	1,690	23,163	8,643	66,504
3Q-Folha15a.jpg	16,954	81,017	1,901	0,129
3Q-Folha16_alt.jpg	7,298	91,718	0,473	0,511
3Q-Folha17_alt.jpg	5,166	69,148	2,347	23,339
3Q-Folha18.jpg	1,389	95,077	2,944	0,590
3Q-Folha19a_alt.jpg	38,665	61,008	0,053	0,273
3Q-Folha20a_alt.jpg	5,473	73,714	0,271	20,542
3Q-Folha21.jpg	39,398	55,882	1,666	3,055
3Q-Folha22a.jpg	19,226	73,415	0,475	6,885
3Q-Folha23a_alt.jpg	6,142	83,154	7,817	2,887
3Q-Folha24a_alt.jpg	11,050	85,701	2,917	0,333
3Q-Folha25.jpg	7,482	89,570	2,493	0,455
3Q-Folha26a.jpg	1,772	55,862	32,880	9,487
3Q-Folha27a.jpg	3,157	77,585	17,364	1,895
3Q-Folha28_alt.jpg	12,223	6,599	0,096	81,082
3Q-Folha29a_alt.jpg	2,616	97,161	0,217	0,006
3Q-Folha30_alt.jpg	0,436	21,263	73,195	5,105
3Q-Folha31_alt.jpg	53,516	44,109	0,000	2,375
3Q-Folha32a_alt.jpg	17,113	81,195	1,050	0,642
3Q-Folha33_alt.jpg	0,670	81,171	17,704	0,456
3Q-Folha34a_alt.jpg	8,644	57,023	23,292	11,041
3Q-Folha35.jpg	13,937	63,699	0,441	21,923
3Q-Folha36.jpg	15,204	46,773	0,068	37,956
3Q-Folha37_alt.jpg	29,537	69,412	0,528	0,523
3Q-Folha38a_alt.jpg	8,691	91,282	0,022	0,004
3Q-Folha39_alt.jpg	27,833	54,141	0,004	18,022
3Q-Folha40a.jpg	1,731	59,070	1,380	37,819
3Q-Folha41a.jpg	4,131	5,901	0,007	89,961
soma	547,500	2513,199	278,152	661,149

Classificado 4Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
4Q-Folha01a.jpg	10,815	70,509	0,598	18,078
4Q-Folha02a_alt.jpg	59,723	39,972	0,166	0,139

4Q-Folha03a.jpg	2,171	72,861	13,124	11,845
4Q-Folha04_alt.jpg	11,535	87,673	0,677	0,116
4Q-Folha05a_alt.jpg	9,108	88,215	2,156	0,521
4Q-Folha06_alt.jpg	6,541	85,041	6,102	2,317
4Q-Folha07a.jpg	13,656	38,576	3,027	44,740
4Q-Folha08a.jpg	1,026	31,040	3,084	64,850
4Q-Folha09.jpg	0,296	12,484	47,083	40,138
4Q-Folha11.jpg	3,187	71,025	2,481	23,306
4Q-Folha12a.jpg	40,615	58,575	0,259	0,551
4Q-Folha13a.jpg	20,610	76,774	0,017	2,599
4Q-Folha14_alt.jpg	2,829	24,342	8,843	63,987
4Q-Folha15a.jpg	18,239	80,161	1,499	0,102
4Q-Folha16_alt.jpg	10,597	88,210	0,485	0,709
4Q-Folha17_alt.jpg	5,939	65,877	4,195	23,989
4Q-Folha18.jpg	1,532	95,086	2,665	0,717
4Q-Folha19a_alt.jpg	38,393	61,345	0,043	0,219
4Q-Folha20a_alt.jpg	5,097	78,371	0,207	16,325
4Q-Folha21.jpg	44,175	52,080	1,321	2,423
4Q-Folha22a.jpg	17,515	76,182	0,374	5,929
4Q-Folha23a_alt.jpg	5,642	84,115	7,720	2,523
4Q-Folha24a_alt.jpg	8,562	87,787	3,272	0,379
4Q-Folha25.jpg	9,528	87,186	2,751	0,535
4Q-Folha26a.jpg	1,451	49,930	39,513	9,106
4Q-Folha27a.jpg	3,376	79,743	15,301	1,580
4Q-Folha28_alt.jpg	17,188	10,716	0,086	72,010
4Q-Folha29a_alt.jpg	2,277	97,548	0,171	0,004
4Q-Folha30_alt.jpg	0,361	30,519	65,111	4,009
4Q-Folha31_alt.jpg	48,668	48,560	0,000	2,772
4Q-Folha32a_alt.jpg	15,998	82,602	0,839	0,562
4Q-Folha33_alt.jpg	1,473	81,291	16,820	0,417
4Q-Folha34a_alt.jpg	7,426	49,803	25,753	17,017
4Q-Folha35.jpg	11,775	67,446	1,724	19,055
4Q-Folha36.jpg	12,894	55,419	0,091	31,597
4Q-Folha37_alt.jpg	38,231	60,933	0,416	0,420
4Q-Folha38a_alt.jpg	8,153	91,826	0,018	0,004
4Q-Folha39_alt.jpg	25,201	45,833	0,003	28,963
4Q-Folha40a.jpg	1,499	59,939	1,094	37,468
4Q-Folha41a.jpg	4,645	5,911	0,026	89,417
soma	547,946	2531,501	279,116	641,438

Tabela de Zinco

Classificado 1Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
1Q-Folha01a_alt.jpg	6,431	90,691	2,620	0,258
1Q-Folha02a_alt.jpg	5,377	94,524	0,099	0,000
1Q-Folha03a.jpg	6,567	91,604	1,822	0,007
1Q-Folha04a.jpg	18,217	52,867	28,821	0,096
1Q-Folha06a_alt.jpg	5,802	79,978	14,200	0,020
1Q-Folha07a_alt.jpg	16,315	83,597	0,089	0,000
1Q-Folha08a_alt.jpg	28,117	71,793	0,054	0,036
1Q-Folha09a.jpg	23,375	76,288	0,239	0,099

1Q-Folha10a_alt.jpg	32,929	66,573	0,487	0,011
1Q-Folha12a_alt.jpg	29,047	61,853	9,088	0,012
1Q-Folha13a_alt.jpg	31,390	65,122	3,465	0,023
1Q-Folha15a.jpg	27,792	72,208	0,000	0,000
1Q-Folha16a_alt.jpg	20,906	72,805	6,206	0,084
1Q-Folha17a_alt.jpg	4,104	62,458	33,426	0,012
1Q-Folha18a.jpg	28,825	71,035	0,026	0,114
1Q-Folha19a_alt.jpg	37,754	62,246	0,000	0,000
1Q-Folha20a_alt.jpg	13,300	86,592	0,084	0,024
1Q-Folha21a_alt.jpg	3,914	84,594	11,492	0,000
1Q-Folha22a.jpg	2,756	37,893	58,293	1,059
1Q-Folha22a_alt.jpg	2,827	45,614	50,333	1,226
1Q-Folha23a_alt.jpg	12,916	86,731	0,353	0,000
1Q-Folha24a_alt.jpg	5,639	61,509	32,828	0,024
1Q-Folha25.jpg	14,749	73,910	11,258	0,083
1Q-Folha26a_alt.jpg	11,536	88,443	0,011	0,011
1Q-Folha27a_alt.jpg	7,599	91,076	1,209	0,116
1Q-Folha28a_alt.jpg	0,979	44,679	53,106	1,237
1Q-Folha29a_alt.jpg	10,152	89,075	0,773	0,000
1Q-Folha30a.jpg	27,233	72,767	0,000	0,000
1Q-Folha31a.jpg	19,150	78,387	2,463	0,000
1Q-Folha32a_alt.jpg	14,765	71,583	13,297	0,354
1Q-Folha33_alt.jpg	17,064	66,798	15,588	0,550
1Q-Folha34.jpg	6,493	79,032	13,799	0,675
1Q-Folha35_alt.jpg	24,463	75,412	0,125	0,000
1Q-Folha36a_alt.jpg	33,631	66,332	0,000	0,037
1Q-Folha37a.jpg	18,481	81,096	0,410	0,013
1Q-Folha38a.jpg	12,463	51,529	35,724	0,284
1Q-Folha39_alt.jpg	12,923	86,562	0,463	0,051
1Q-Folha40a.jpg	24,589	75,391	0,010	0,010
1Q-Folha41_alt.jpg	4,756	82,907	12,338	0,000
1Q-Folha42a_alt.jpg	14,782	83,520	1,655	0,044
1Q-Folha43a_alt.jpg	13,433	75,335	11,147	0,085
soma	653,542	3012,405	427,398	6,655

Classificado 2Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
2Q-Folha01a_alt.jpg	9,347	88,065	2,383	0,205
2Q-Folha02a_alt.jpg	22,174	77,774	0,045	0,008
2Q-Folha03a.jpg	11,680	86,762	1,553	0,005
2Q-Folha04a.jpg	25,640	58,954	15,347	0,059
2Q-Folha06a_alt.jpg	10,688	80,257	9,043	0,012
2Q-Folha07a_alt.jpg	38,427	61,522	0,044	0,006
2Q-Folha08a_alt.jpg	40,933	59,003	0,024	0,040
2Q-Folha09a.jpg	34,442	65,332	0,165	0,061
2Q-Folha10a_alt.jpg	36,727	62,949	0,317	0,007
2Q-Folha12a_alt.jpg	38,492	55,421	6,079	0,008
2Q-Folha13a_alt.jpg	40,572	57,572	1,838	0,018
2Q-Folha15a.jpg	33,236	66,755	0,000	0,009
2Q-Folha16a_alt.jpg	29,934	66,516	3,494	0,056
2Q-Folha17a_alt.jpg	3,143	66,508	30,342	0,007

2Q-Folha18a.jpg	28,148	71,759	0,016	0,077
2Q-Folha19a_alt.jpg	49,981	50,011	0,000	0,008
2Q-Folha20a_alt.jpg	26,569	73,354	0,058	0,019
2Q-Folha21a_alt.jpg	16,984	77,151	5,858	0,007
2Q-Folha22a.jpg	7,414	58,152	33,231	1,204
2Q-Folha22a_alt.jpg	8,854	57,365	32,740	1,042
2Q-Folha23a_alt.jpg	27,857	71,946	0,190	0,006
2Q-Folha24a_alt.jpg	8,277	67,091	24,552	0,080
2Q-Folha25.jpg	15,160	76,833	7,950	0,057
2Q-Folha26a_alt.jpg	16,269	83,714	0,006	0,012
2Q-Folha27a_alt.jpg	11,108	87,991	0,838	0,062
2Q-Folha28a_alt.jpg	5,064	63,703	30,527	0,706
2Q-Folha29a_alt.jpg	15,294	84,234	0,466	0,006
2Q-Folha30a.jpg	30,253	69,740	0,000	0,007
2Q-Folha31a.jpg	35,086	63,703	1,201	0,010
2Q-Folha32a_alt.jpg	26,495	64,737	8,599	0,168
2Q-Folha33_alt.jpg	24,515	64,491	10,655	0,339
2Q-Folha34.jpg	14,243	75,004	10,240	0,514
2Q-Folha35_alt.jpg	24,197	75,717	0,080	0,006
2Q-Folha36a_alt.jpg	49,346	50,590	0,006	0,057
2Q-Folha37a.jpg	20,493	79,140	0,361	0,006
2Q-Folha38a.jpg	13,325	55,783	30,666	0,226
2Q-Folha39_alt.jpg	25,115	74,598	0,253	0,034
2Q-Folha40a.jpg	27,918	72,041	0,006	0,035
2Q-Folha41_alt.jpg	3,852	80,311	15,826	0,012
2Q-Folha42a_alt.jpg	17,688	81,092	1,188	0,033
2Q-Folha43a_alt.jpg	20,445	72,874	6,632	0,048
soma	945,382	2856,515	292,822	5,281

Classificado 3Q(amarelo)				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
3Q-Folha01a_alt.jpg	16,660	80,876	2,157	0,307
3Q-Folha02a_alt.jpg	23,713	76,254	0,028	0,005
3Q-Folha03a.jpg	10,979	87,524	1,493	0,004
3Q-Folha04a.jpg	21,551	68,152	10,261	0,036
3Q-Folha06a_alt.jpg	10,990	80,936	8,066	0,008
3Q-Folha07a_alt.jpg	39,469	60,495	0,032	0,005
3Q-Folha08a_alt.jpg	42,266	57,689	0,017	0,029
3Q-Folha09a.jpg	34,679	64,845	0,433	0,043
3Q-Folha10a_alt.jpg	35,264	64,479	0,252	0,005
3Q-Folha12a_alt.jpg	39,692	55,733	4,569	0,006
3Q-Folha13a_alt.jpg	39,371	59,296	1,320	0,013
3Q-Folha15a.jpg	26,523	70,100	3,371	0,006
3Q-Folha16a_alt.jpg	24,592	72,883	2,487	0,037
3Q-Folha17a_alt.jpg	4,005	65,275	30,707	0,013
3Q-Folha18a.jpg	25,182	74,689	0,072	0,057
3Q-Folha19a_alt.jpg	49,502	50,488	0,000	0,010
3Q-Folha20a_alt.jpg	28,588	71,360	0,039	0,013
3Q-Folha21a_alt.jpg	19,367	76,747	3,876	0,009
3Q-Folha22a.jpg	6,174	61,860	31,133	0,833
3Q-Folha22a_alt.jpg	8,064	61,028	30,136	0,772

3Q-Folha23a_alt.jpg	29,448	70,304	0,240	0,009
3Q-Folha24a_alt.jpg	5,820	66,297	27,828	0,054
3Q-Folha25.jpg	26,396	68,339	5,223	0,041
3Q-Folha26a_alt.jpg	17,463	82,525	0,004	0,008
3Q-Folha27a_alt.jpg	11,991	85,813	2,056	0,140
3Q-Folha28a_alt.jpg	3,972	71,949	23,600	0,479
3Q-Folha29a_alt.jpg	14,256	81,257	4,355	0,132
3Q-Folha30a.jpg	27,073	72,923	0,000	0,004
3Q-Folha31a.jpg	49,670	49,510	0,795	0,026
3Q-Folha32a_alt.jpg	25,983	67,731	6,176	0,109
3Q-Folha33_alt.jpg	29,574	61,832	8,368	0,226
3Q-Folha34.jpg	12,730	77,888	9,027	0,356
3Q-Folha35_alt.jpg	25,495	74,353	0,148	0,004
3Q-Folha36a_alt.jpg	45,917	53,941	0,104	0,038
3Q-Folha37a.jpg	34,354	65,410	0,224	0,012
3Q-Folha38a.jpg	11,230	53,922	34,432	0,417
3Q-Folha39_alt.jpg	28,974	70,823	0,181	0,023
3Q-Folha40a.jpg	28,832	71,133	0,009	0,026
3Q-Folha41_alt.jpg	7,874	78,473	13,533	0,119
3Q-Folha42a_alt.jpg	15,379	83,319	1,280	0,022
3Q-Folha43a_alt.jpg	25,064	70,526	4,378	0,032
soma	984,123	2838,979	272,409	4,489

Classificado 4Q				
Quadrante-Folha	verde escuro (%)	verde claro (%)	amarelo (%)	marrom (%)
4Q-Folha01a_alt.jpg	15,680	81,317	2,496	0,507
4Q-Folha02a_alt.jpg	21,401	78,574	0,022	0,004
4Q-Folha03a.jpg	10,637	87,285	2,063	0,015
4Q-Folha04a.jpg	17,572	72,944	9,455	0,029
4Q-Folha06a_alt.jpg	9,006	80,521	10,467	0,006
4Q-Folha07a_alt.jpg	40,722	59,164	0,077	0,037
4Q-Folha08a_alt.jpg	33,740	66,208	0,026	0,026
4Q-Folha09a.jpg	31,328	67,706	0,919	0,047
4Q-Folha10a_alt.jpg	29,996	68,623	1,377	0,004
4Q-Folha12a_alt.jpg	32,203	61,051	6,728	0,018
4Q-Folha13a_alt.jpg	36,287	62,532	1,166	0,014
4Q-Folha15a.jpg	25,146	67,513	7,332	0,009
4Q-Folha16a_alt.jpg	20,493	77,304	2,094	0,109
4Q-Folha17a_alt.jpg	3,560	65,115	31,315	0,011
4Q-Folha18a.jpg	23,703	76,168	0,078	0,050
4Q-Folha19a_alt.jpg	46,906	53,079	0,000	0,015
4Q-Folha20a_alt.jpg	22,963	76,936	0,091	0,010
4Q-Folha21a_alt.jpg	16,548	80,463	2,968	0,021
4Q-Folha22a.jpg	5,355	58,335	35,617	0,693
4Q-Folha22a_alt.jpg	7,296	57,559	34,499	0,645
4Q-Folha23a_alt.jpg	24,449	71,067	4,478	0,007
4Q-Folha24a_alt.jpg	4,587	66,029	29,343	0,041
4Q-Folha25.jpg	26,914	68,035	4,941	0,109
4Q-Folha26a_alt.jpg	15,667	84,324	0,003	0,006
4Q-Folha27a_alt.jpg	16,682	81,586	1,616	0,116
4Q-Folha28a_alt.jpg	3,000	70,224	26,396	0,381

4Q-Folha29a_alt.jpg	12,457	78,423	8,902	0,218
4Q-Folha30a.jpg	24,432	75,565	0,000	0,003
4Q-Folha31a.jpg	47,782	48,912	3,259	0,048
4Q-Folha32a_alt.jpg	22,203	68,965	8,749	0,082
4Q-Folha33_alt.jpg	27,994	61,393	10,296	0,318
4Q-Folha34.jpg	10,973	81,086	7,681	0,260
4Q-Folha35_alt.jpg	26,180	73,525	0,292	0,003
4Q-Folha36a_alt.jpg	39,097	60,643	0,232	0,028
4Q-Folha37a.jpg	36,958	62,843	0,188	0,010
4Q-Folha38a.jpg	9,814	51,796	37,947	0,443
4Q-Folha39_alt.jpg	25,767	74,001	0,215	0,017
4Q-Folha40a.jpg	24,471	75,475	0,034	0,020
4Q-Folha41_alt.jpg	9,003	78,002	12,893	0,102
4Q-Folha42a_alt.jpg	15,614	83,199	1,170	0,017
4Q-Folha43a_alt.jpg	22,841	71,341	5,631	0,187
soma	897,426	2884,832	313,056	4,686

Apêndice B- Imagens da folhas de citros

Imagens de CVC

Imagens de greening

Imagens de magnésio

Imagens de manganês

Imagens de rubelose

Imagens de zinco

Apêndice C- Rotina para extração dos descritores de haralick

```

function [ F ] = haralick( glcm )
% HARALICK Fast Calculation of Haralick Features
%   IN:   glcm = Co-Occurrence Matrix
%   OUT:  F = Feature Vector
%
%   Stefan Winzeck 2012
%   winzeck@hm.edu
%
%   Feature Calculation according to:
%   [1] R. Haralick: 'Textural Feature for Image Classification' (1979)
%   [2] E. Miyamoto: 'Fast Calculation of Haralick Texture Features'
%
% MISSING:   f14   [1]

%% ALLOCATION
S=size(glcm,1);

f_2=zeros(S);
f_3=zeros(S);
f_4=zeros(S);
f_5=zeros(S);
f_6=zeros(1,2*S);
f_7=zeros(1,2*S);
f_8=zeros(1,2*S);
f_9=zeros(S);
f_11=zeros(1,S);

pxy=zeros(1,2*S);
px_y=zeros(1,S);

HX_=zeros(1,S);
HY_=zeros(1,S);
HXY_1=zeros(S);
HXY_2=zeros(S);

%% CALCULATION
% Normalization
M = glcm/sum(glcm(:));

% Energy
f_1 = M.^2;
f1 = sum(f_1(:));

%-----%

u = mean2(M);
py = sum(M,1);
px = sum(M,2);

```

```

for i=1:S
    for j=1:S

        f_3(i,j) = i*j*M(i,j);
        f_4(i,j) = (i-u)^2*M(i,j);
        f_5(i,j) = M(i,j)/(1+(i-j)^2);
        f_9(i,j) = M(i,j)*log(M(i,j)+eps);

        pxy(i+j) = pxy(i+j)+M(i,j);
        px_y(abs(i-j)+1) = px_y(abs(i-j)+1)+M(i,j);

        HX_(i)= px(i)*log(px(i)+eps);
        HY_(j)= py(j)*log(py(j)+eps);
        HXY_1(i,j) = M(i,j)*log(px(i)*py(j)+eps);
        HXY_2(i,j) = px(i)*py(j)*log(px(i)*py(j)+eps);
    end
end

% Correlation
ux = mean(px); sx=std(px);
uy = mean(py); sy=std(py);
f3 =(sum(f_3(:))-(ux*uy))/(sx*sy);

% Sum of Variances
f4 = sum(f_4(:));

% Inverse Difference Moment
f5 = sum(f_5(:));

% Entropy
f9 = -sum(f_9(:));

% Information Measures of Correlation 1&2
HX = -sum(HX_);
HY = -sum(HY_);
HXY = f9;
HXY1 = -sum(HXY_1(:));
HXY2 = -sum(HXY_2(:));

f12 = (HXY-HXY1)/max([HX, HY]);
f13 = (1 - exp((-2)*(HXY2 - HXY)))^0.5;

%-----%

for i=2:2*S
    f_6(i) = i*pxy(i);
    f_8(i) = pxy(i)*log(pxy(i)+eps);
end

% Sum Average
%f_6(1) = []; % not necessary f_6(1) is zero anyway
f6 = sum(f_6);

% Sum Entropy
%f_8(1)=[]; % not necessary f_8(1) is zero anyway
f8 = -sum(f_8);

```

```

%-----%

for i=2:2*S
    f_7(i)=(i-f8)^2*pxy(i);
end

% Sum Variance
%f_7(1) = [];          % not necessary f_7(1) is zero anyway
f7 = sum(f_7);

% Difference Variance
f10 = var(px_y);

%-----%

for k=1:S
    f_2(k) = (k-1)^2*px_y(k);
    f_11(k) = px_y(k)*log(px_y(k)+eps);
end

% Contrast
f2 = sum(f_2(:));

% Difference Entropy
f11 = -sum(f_11);
%-----%

F = [f1;f2;f3;f4;f5;f6;f7;f8;f9;f10;f11;f12;f13];

end

```


Apêndice D- Rotina para gerar imagens nos canais de cores

```

clc
close all
clear all

dirData = dir('*.jpg');          %# Get the selected file data
fileNames = {dirData.name};      %# Create a cell array of file names

for iFile = 1:numel(fileNames)  %# Loop over the file names

    numImgs = length(fileNames{iFile});
    Name = fileNames{iFile};
    fileNamesNew = Name(1:numImgs-4);

    i1=imread(fileNames{iFile});

    % gera imagem no canal de cor vermelho
    iR = i1(:, :, 1);
    figure, imshow(iR);
    imwrite(iR, cat(2,num2str(fileNamesNew),'_red.jpg'));

    % gera imagem no canal de cor verde
    iG = i1(:, :, 2);
    figure, imshow(iG);
    imwrite(iG, cat(2,num2str(fileNamesNew),'_green.jpg'));

    % gera imagem em nível de cinza
    iC = rgb2gray(i1);
    figure, imshow(iC);
    imwrite(iC, cat(2,num2str(fileNamesNew),'_grey.jpg'));
    close all

end

```

Apêndice E- Gráfico de dispersão

Gráfico do CVC

Gráfico do Greening

Gráfico do Magnésio

Gráfico do Manganês

Gráfico da Rubelose

Gráfico da Rubelose

Gráfico do Zinco