

Application of texture analysis for differentiation of the *greening* from others pests

Patricia Pedroso Estevam Ribeiro
Departamento de Engenharia Elétrica
Escola de Engenharia de São Carlos -
Universidade de São Paulo - USP,
São Carlos, Brasil
patriciapedrosoestevam@hotmail.com

Maria Stela Veludo de Paiva
Departamento de Engenharia Elétrica
Escola de Engenharia de São Carlos -
Universidade de São Paulo - USP,
São Carlos, Brasil
mstela@sc.usp.br

Lúcio André de Castro Jorge
Embrapa Instrumentação Agropecuária
São Carlos, Brasil
lajorge@gmail.com

Abstract — The *greening* is one of the most serious diseases of citrus and in this paper is proposed a methodology based on texture analysis for assessment of symptomatic citrus leaves. To evaluate the methodology were used 120 images of citrus leaves containing leaves with diseases (*greening*, CVC and rubelose) and nutritional deficiencies (manganese, magnesium and zinc). Samples were extracted by leaf and quadrants in red and green colors channels and on grayscale. The samples were analyzed by LBP descriptors, LFP and Haralick. The results generated were classified by the X^2 distance and Weka, IBK and ANN MLP. The best results were for LBP descriptor and LFP-s using X^2 distance, with a sensitivity range between 97.02% and 99.94% and 93.39% and 99.52%, respectively, and LBP using IBK with a sensitivity range between 99.2% and 99.6% sensitivity.

Keywords— *Greening*, *Texture analysis*, *LBP*, *LFP*, *Haralick*, *matriz de co-ocorrência*.

I. INTRODUÇÃO

O *greening*, também conhecido como *Huanglongbing* (HLB), é considerado atualmente a mais grave doença dos citros no mundo [2]. Causada pela bactéria *Candidatus Liberibacter spp.*, é transmitida pelo inseto psílídeo *Diaphorina citri*, que adquire e transmite a bactéria às demais plantas ao se alimentar de uma planta já contaminada. O controle do *greening* é realizado periodicamente com inspeção constante e a eliminação imediata de plantas com sintomas, e o controle do inseto transmissor é feito com a montagem de armadilhas. Atualmente, o método de inspeção visual e a análise da leitura do DNA da bactéria pela análise de *Polymerase Chain Reaction* (PCR) [4] são os mais utilizados para diagnosticar a doença. O método PCR é utilizado para diagnosticar o patógeno de plantas suspeitas, mas o custo elevado e o longo tempo para a análise o tornam proibitivo de ser aplicado em escala necessária para o controle. As inspeções visuais podem ser realizadas por inspetores caminhando ao lado das plantas cítricas ou em plataformas acopladas a um trator. Nos experimentos apresentados por [1] e [5] 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. Em média esse tipo de inspeção detecta 47,61% das plantas sintomáticas.

O sintoma característico do *greening* aparece inicialmente, em alguns ramos apresentando folhas com clorose assimétrica (Figura 1). Estas manchas são facilmente confundidas com outras doenças e deficiências nutricionais que se assemelham às características visuais do *greening*, confundindo os inspetores na identificação destas doenças pelo método visual.



Fig. 1. Imagem de folhas de citros contaminada com o *greening*.

Este artigo propõe uma metodologia baseada em análise de textura para identificar folhas de citros sintomáticas, avaliando se estão contaminadas com o *greening* ou outras doenças e deficiências nutricionais.

O presente artigo está organizado nas seguintes seções: a seção 2 aborda a teoria relacionada ao trabalho, na seção 3 é apresentada a metodologia, na seção 4 os resultados e discussões, e finalmente na seção 5 a conclusão.

II. ANÁLISE DE TEXTURA

A. Introdução sobre textura

A textura é uma das características mais importantes para classificar e reconhecer objetos e cenas, sendo aplicada nas mais diversas áreas para: identificação de regiões por meio do padrão de cores, extração de informações de rugosidade ou suavidade de determinada superfície, e a sua regularidade, extração de características, segmentação, reconhecimento de padrões e classificação de atributos.

A textura pode ser descrita por diferentes abordagens [6], como a abordagem estatística, na qual se enquadram os descritores de Haralick [7], a estrutural, a espectral e a abordagem de micropadrões locais que analisa uma vizinhança local da imagem para extrair características que possibilitem a

descrição de textura local. Nessa última abordagem enquadram-se o descritor LBP (*Local Binary Pattern*) [8] e o LFP (*Local Fuzzy Pattern*) [9], que são descritos a seguir.

B. Local Binary Pattern

O LBP é um descritor de textura local que analisa a imagem em relação às intensidades relativas entre os pixels em uma pequena vizinhança [8].

Com o descritor LBP uma imagem em tons de cinza é analisada, considerando uma vizinhança 3x3 ao redor do pixel central (Figura 2a). Essa vizinhança é limiarizada pelo valor do pixel central gerando uma matriz com valores binários, podendo ser observado na Figura 2 (b), possibilitando gerar 2^8 (256) códigos. Cada pixel de vizinhança (V_i) adquire o valor (E_i), sendo atribuído a ele o valor '0', se estiver abaixo do valor do pixel central (V_0), caso contrário recebe o valor '1', como pode ser observado na Figura 2 (c). Os valores dos pixels na vizinhança limiarizada são multiplicados por uma matriz de pesos (Figura 2d). Realizando a soma desses valores, conforme a Equação 1, resulta no código LBP, como pode ser observado na Figura 2 (e) [9].

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

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

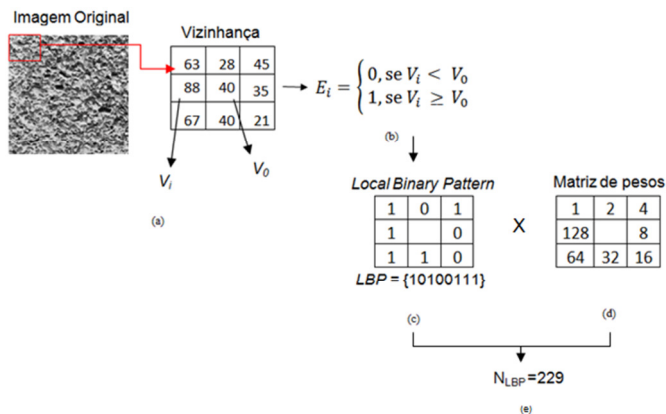


Fig. 2. Ilustração do cálculo do LBP [9].

C. Local Fuzzy Pattern

O descritor de textura local LFP foi proposto como um novo descritor para análise de micropadrões de imagens digitais baseado na lógica *fuzzy* [9]. 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, 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 (Figura 3). 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 $\hat{\mu}_{g(i,j)}$ do pixel central em relação à região definida pela amostra $W \times W$ pixels é dado pela média ponderada dos valores de pertinência individuais de cada pixel, gerando o código LFP. A Figura 3 demonstra o cálculo do código LFP, onde, $f_{g(i,j)}$ é a função de pertinência, gerando os valores das pertinências em relação ao pixel central e $P(k,l)$ é uma matriz de pesos para a vizinhança $A(k,l)$ com a mesma dimensão $W \times W$ pixels.

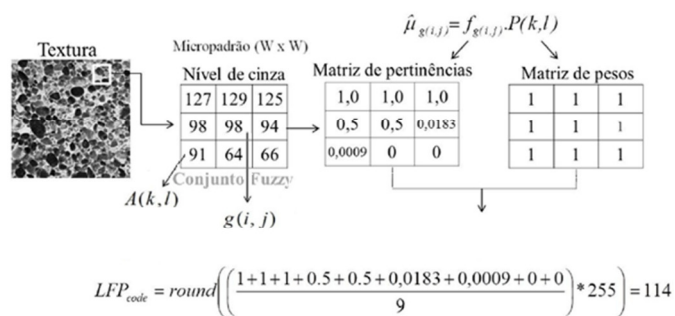


Fig. 3 - Ilustração do cálculo do código LFP [9].

D. Descritores de Haralick

Os descritores de Haralick são compostos por um conjunto de 14 descritores para descrever a textura, em que são definidas diversas características advindas do cálculo de matriz de co-ocorrência. Os descritores são obtidos a partir de cálculos estatísticos de segunda ordem, considerando as ocorrências de cada nível de cinza em pixels diferentes, ao longo de diferentes direções, e são os seguintes: 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 duas propriedades) e coeficiente de correlação máximo [7].

III. METODOLOGIA

Este artigo propõe um método baseado em análise de textura para auxiliar a diferenciação do *greening* de outras doenças similares. A Figura 4 mostra o diagrama do desenvolvimento.

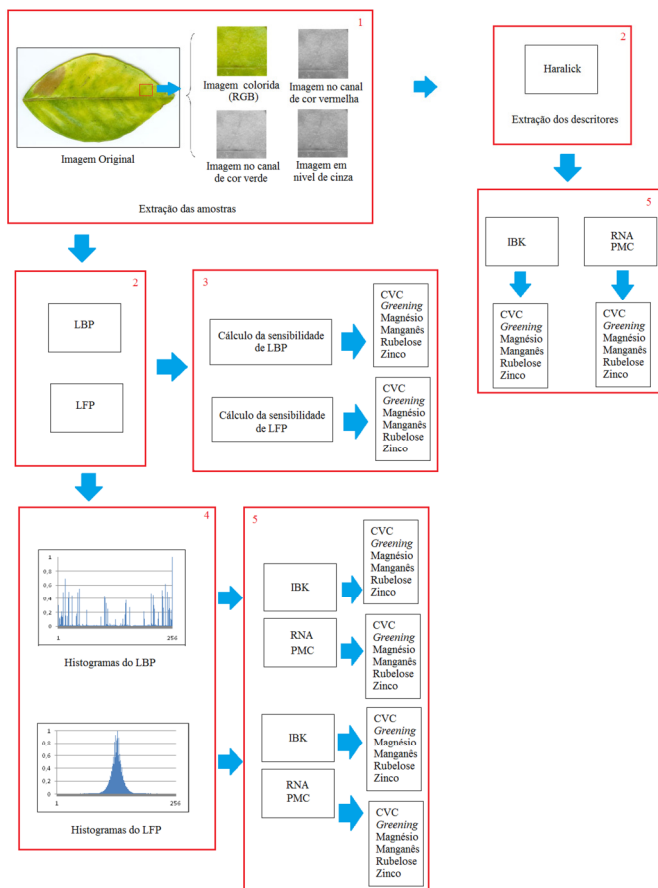


Fig. 4. Diagrama de desenvolvimento.

As etapas da metodologia proposta, ilustradas na Figura 4, são as seguintes: aquisição das imagens foliares, extração das amostras das folhas, aplicação dos descritores de textura LBP, LFP, e dos descritores de Haralick, cálculo da sensibilidade e classificação das classes de doenças pelos descritores LBP e LFP, extração dos histogramas do descritor LBP e LFP, classificação das classes de doenças utilizando o algoritmo IBK e RNA PMC.

A. Aquisição das Imagens Foliares

Foram digitalizadas 150 folhas de citros fornecidas pela empresa do grupo Fischer [10], divididas em seis classes de doenças e deficiências nutricionais, contendo 25 amostras para cada tipo de doença (*greening*, CVC e rubelose) e deficiência nutricional (manganês, magnésio e zinco), sem deformidades geométricas. 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 [11]. As folhas de citros foram digitalizadas por um scanner de mesa, modelo SCANNER HP SCANJET G4050, no modelo de cores RGB, utilizando a parte frontal da folha. O lado do caule foi direcionado para o lado esquerdo e a ponta da folha no lado direito, para manter o mesmo padrão de análise.

Foram gerados dois bancos de imagens de folhas de citros, onde, no banco 1 foram digitalizadas as 150 folhas de citros, com resolução de 100 DPI e dimensão de 400 x 200 pixels das

imagens originais em níveis de cinza. No banco 2 foram selecionadas e digitalizadas as 120 melhores folhas de citros, com resolução de 300 DPI e dimensão de 3000 x 1800 pixels das imagens originais em RGB.

B. Extração das amostras

Foram aplicados os descritores de textura LBP e LFP, e os descritores de Haralick nas amostras extraídas de cada folha. Inicialmente foi avaliado o número de amostras extraídas, o tamanho da amostra e o número de folhas para cada classe de doenças, considerando as melhores folhas sem deformidades geométricas.

O artigo [12] mostrou que as cores segmentadas influenciam na diferenciação das doenças. Devido a isso as amostras foram recortadas manualmente usando o Matlab, selecionando as áreas com manchas que caracterizam as doenças, gerando novas imagens recortadas nos canais de cores vermelho e verde, e em níveis de cinza usando a função *rgb2gray*. Não foi utilizado o canal de cor azul, pois este não apresentou propriedades discriminatórias nos testes. A Figura 5 ilustra um exemplo de uma amostra sendo extraída.




Fig. 5. Exemplo de amostra extraída por uma imagem de folha de citros nos canais de cores vermelho, verde e nível de cinza.

Foram feitas várias avaliações das amostras com os descritores com o objetivo de verificar a influência dos canais de cores e a influência da divisão em quadrantes (Figura 6).

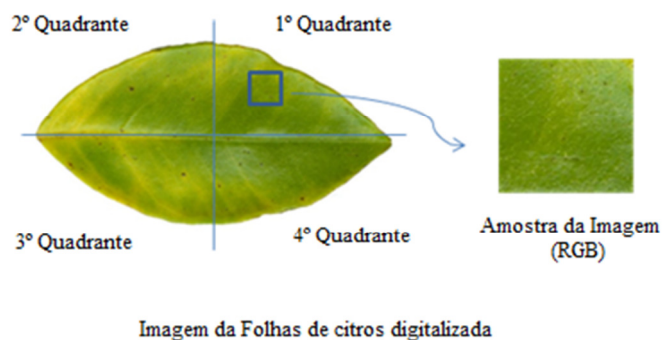


Fig. 6. Exemplo de amostras extraídas por uma imagem de folha de citros por quadrante.

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

Nesta fase foram aplicados os descritores LBP, LFP e os descritores de Haralick nas amostras extraídas. Os resultados obtidos para os treze primeiros descritores de Haralick e também para os descritores LBP e LFP foram armazenados

em arquivo com extensão “arff” para posterior classificação das classes de doenças utilizando o *toolbox* Weka [3]. Para os descritores LBP e LFP foi também realizada a classificação das classes de doenças utilizando a métrica X^2 , e calculada a sensibilidade, conforme detalhado na seção *D* seguinte.

D. Cálculo da sensibilidade e classificação das classes de doenças pelos 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 X^2 , dada pela Equação (2).

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

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 [9].

As amostras são comparadas e classificadas numa mesma classe, quando se obtêm a menor distância X^2 entre as demais amostras da mesma classe. Os resultados da classificação são armazenados em uma matriz de confusão e o cálculo da sensibilidade (*S*) é dado pela Equação (3).

$$S = \frac{VP}{VP + FN} \quad (3)$$

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

E. Extração dos histogramas do descritor LBP e LFP

Após a aplicação dos descritores LBP e LFP, são gerados e salvos os histogramas correspondentes para cada amostra analisada, sendo também gerado um histograma para cada amostra de doença. Cada linha do histograma foi separada como atributo e salva em um arquivo com extensão “arff” para ser posteriormente avaliada pelos classificadores do *toolbox* Weka, utilizando validação cruzada de 10 *folds*.

F. classificação das classes de doenças utilizando o algoritmo IBK e RNA PMC

Com os arquivos com extensão “arff”, mencionados na seção E, foi realizada a classificação das classes de doenças com o algoritmo IBK e o RNA PMC do *toolbox* Weka. Esses resultados foram comparados com os resultados de sensibilidade obtidos com a métrica X^2 (seção *D*). Os descritores de Haralick foram também armazenados como atributos e classificados utilizando o algoritmo IBK e RNA PMC para comparação de resultados.

G. Ferramentas

Foram utilizadas as ferramentas: Matlab versão 7.6.0 R2008a para analisar as amostras com os descritores LBP, LFP e os descritores de Haralick e para converter as amostras nos canais de cores. O *toolbox* Weka 3.7.10 foi utilizado para classificar amostras extraídas dos descritores de Haralick e os histogramas gerados utilizando o algoritmo IBK e RNA PMC.

IV. RESULTADOS E DISCUSSÕES

Inicialmente as amostras foram avaliadas em relação à influência do número de amostras extraídas por folha, o tamanho da amostra e a resolução para as imagens do banco 1.

Na Tabela 1 são apresentados os resultados de sensibilidade para os descritores LBP, LFP e os descritores de Haralick, considerando amostras com o tamanho de 30x30 e 100x100 pixels.

Tabela 1. Tabela da sensibilidade obtida com variação do tamanho da amostra.

Tabela com variação no tamanho da amostra W x W pixels		
Descritores	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%
Teste 1	34,67%	36,00%
Teste 2	34,17%	36,17%

Na Tabela 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 o descritor LFP com função de pertinência (sigmóide, triangular e gaussiana) e para o LBP, considerando uma vizinhança de 3x3. Foram avaliadas também as seis classes de doenças para os descritores de Haralick.

A sensibilidade para o teste 1 e teste 2 dos descritores de Haralick foram calculadas usando o algoritmo IBK pelo *toolbox* Weka. Para o teste 1 foram utilizados treze descritores. 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).

Observa-se na Tabela 1, que para as amostras com tamanho 100x100 pixels, os valores de sensibilidade foram superiores aos valores das amostras com tamanho 30x 30 pixels, para todos os descritores. Além disso, os descritores LFP-t (função de pertinência triangular) e LFP-g (função de pertinência gaussiana) apresentaram resultados de sensibilidade inferiores ao descritor LFP-s (função de pertinência sigmóide).

Foram realizados dois experimentos com o objetivo de avaliar a influência das classes de cores e das amostras

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

Para o primeiro experimento (Tabela 2), 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 2. 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 2 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 3), 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 200x200 pixels, gerando 180 amostras por quadrante, totalizando 720 amostras extraídas para todos os quadrantes.

Tabela 3. Tabela da sensibilidade obtida pelo segundo experimento.

Tabela do segundo experimento				
	1º Quad.(%)	2º Quad.(%)	3º Quad.(%)	4º Quad.(%)
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 3, 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 os descritores de Haralick obtiveram 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.

A. Análise Geral dos Descritores

Para analisar os descritores LBP e LFP-s, foram utilizadas as imagens do banco 2, e extraídas amostras por quadrante com tamanho e número variado de amostras, sendo gerados os resultados de sensibilidade em cada quadrante. A Tabela 4

apresenta os valores de sensibilidade do LBP e a Tabela 5 apresenta os valores de sensibilidade do LFP-s.

Tabela 4. 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 Quad.(%)	2º Quad.(%)	3º Quad.(%)	4º Quad.(%)
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

Observa-se que os melhores resultados da classificação das doenças na Tabela 4, 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.

Tabela 5 - 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 Quad.(%)	2º Quad.(%)	3º Quad.(%)	4º Quad.(%)
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

O melhor resultado da classificação das doenças da Tabela 5 foi para as amostras com o tamanho 300 x 300 pixels, com número de 7 amostras extraídas por quadrante, totalizando 2520 amostras.

A Tabela 6 apresenta os resultados da comparação dos descritores LBP e LFP-s, considerando 7 amostras extraídas com tamanho de 300 x 300 pixels. Para os descritores de Haralick são apresentados os resultados que utilizam o algoritmo IBK.

Tabela 6. Tabela de comparação dos descritores.

Tabela de sensibilidade com a métrica da distância X^2				
	1º Quad.(%)	2º Quad.(%)	3º Quad.(%)	4º Quad.(%)
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 de sensibilidade apresentados na Tabela 6 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 45,67%.

A Tabela 7 apresenta a sensibilidade média 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 97,02%, enquanto que o descritor LFP-s classifica as classes de doenças com valores de sensibilidade acima de 93,39%. 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 7. Tabela de sensibilidade média das doenças pelo cálculo da distância X^2 .

Tabela de sensibilidade das doenças			
Doenças	LBP(%)	LFP-s(%)	Haralick (%)
CVC	99,76	99,52	33,65
Greening	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

A Tabela 8 apresenta os resultados de sensibilidade média na classificação dos valores extraídos dos histogramas. O descritor LBP com o algoritmo IBK apresentou o melhor resultado na diferenciação das doenças, com valores de sensibilidades acima de 99,2% .

Tabela 8 – Tabela de sensibilidade média das classes de doenças dos valores extraídos dos histogramas.

Tabela de sensibilidade das doenças				
Doenças	LBP IBK(%)	LBP RNA PMC(%)	LFP-s IBK(%)	LFP-s RNA PMC(%)
CVC	99,5	91,4	86	50,3
Greening	99,3	93,6	78,9	38,3
Magnésio	99,2	88,4	81,6	38,6
Manganês	99,4	89,4	87,8	37,9
Rubelose	99,6	90,8	79,5	23,2
Zinco	99,6	90,3	74,4	23,1

Ao comparar os resultados das Tabelas 7 e 8, observa-se que os descritores LBP e LFP-s com a distância X^2 seguido pelo LBP com o algoritmo IBK obtiveram os melhores valores de sensibilidade.

V. CONCLUSÕES

Foi avaliada a metodologia baseada nos descritores de textura LBP, LFP e os descritores de Haralick, identificando se as folhas de citros estão contaminadas com o *greening* ou outras doenças e deficiências nutricionais. Foram construídos dois bancos de imagens digitalizadas de folhas de citros, contendo seis tipos de doenças (CVC, deficiência de manganês, deficiência de magnésio, deficiência de zinco, *greening* e rubelose). Os melhores resultados foram obtidos avaliando as amostras nos quadrantes, incluindo todas as amostras nos canais de cores vermelho, verde e níveis de cinza.

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.

Para o descritor LFP, a função de pertinência que apresentou uma 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 , 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 ficaram entre 93,39% e 99,52%.

Os melhores resultados da classificação pelo *toolbox* Weka foram para os descritores LBP e LFP-s, utilizando o algoritmo IBK. O LBP apresentou os valores de sensibilidade entre 99,2% e 99,6% , mostrando ser eficiente na diferenciação das classes de doenças. Para o LFP-s os valores de sensibilidade ficaram entre 74,4% e 87,8%.

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%.

AGRADECIMENTOS

Agradecemos à Embrapa Instrumentação Agropecuária e a Universidade de São Paulo - USP de São Carlos pela infraestrutura, e ao grupo FISHER pelo fornecimento das amostras de folhas cítricas.

REFERÊNCIAS

- [1] 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.
- [2] BOVÉ, J. M. Huanglongbing: a destructive, newlyemerging,century-old disease of citrus. *Journal of Plant Pathology*, Pisa, v. 88, p.7-37, 2006.
- [3] WEKA. Disponível em: < <http://www.cs.waikato.ac.nz/ml/weka/> >. Acesso em: 29 abr. 2011.
- [4] INNIS, M. A.; GELFAND, D. H.; SNINSKY, J. J.; WHITE, T. J. (eds.), PCR Protocols: A guide to methods and applications, Academic Press: San Diego, 1990.
- [5] 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.
- [6] GONZALEZ, R. C.; WOODS, R. E. *Processamento digital de imagens*; 3 ed., São Paulo: Ed. Pearson Hall, 2010.
- [7] 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.
- [8] 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.
- [9] VIEIRA, R. T.; CHIERICI, C. E. O.; FERAZ, C. T.; GONZAGA, A. 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.
- [10] FISCHER. Disponível em: <http://www.citrusuco.com.br/fischer/fischer/sites/fischer/portal_grupo/home/index.html>. Acessado em: 28 Set. de 2011.
- [11] 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.
- [12] 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.