

**Diferenciação do *Greening*
de Outras Doenças Foliares em Citros
Utilizando Técnicas de Processamento de Imagens**

Patricia Pedroso Estevam Ribeiro*, Lúcio André de Castro Jorge
e Maria Stela Veludo de Paiva

Resumo: O *greening* ou *huanglongbing* (HLB) é considerada atualmente uma das mais graves doenças dos citros no Brasil. Não possuindo cura ou tratamento, o controle da doença é realizado atualmente por meio de análise de PCR e por método visual por especialistas. Este trabalho utiliza técnicas de processamento de imagens para ajudar a diferenciar o *greening* de outras doenças. Isto é feito por segmentação da cor da imagem de folhas e classificação através de uma rede neural artificial (RNA) do tipo *Perceptron* Multicamada (PMC) com descritores de forma. Os resultados mostram que apenas a mancha amarela não é um diferencial forte desta doença.

Palavras-chave: *greening*, escala diagramática, métodos de segmentação por cor.

Abstract: *The greening or huanglongbing (HLB) is now considered one of the most serious diseases of citrus in Brazil. It has no cure or treatment and disease control is currently carried out by PCR analysis and visual method by experts. This paper uses image processing techniques to differentiate the greening from other diseases. This is done by color image segmentation of the leaves and further classification by means of a Multilayer Perceptron (MLP) artificial neural network (ANN) using shape descriptors. Results show that only the yellow spot is not a strong spread of this disease.*

Keywords: *greening, scale, segmentation methods by color.*

*Autor para contato: patriciapedrosoestevam@hotmail.com

1. Introdução

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, 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 consumo¹.

Apesar de sua eficiência e capacidade de produção, a citricultura paulista, desde o início do século XX tem sido exposta a vários ataques de pragas e doenças, e recentemente de uma forma mais intensa, ocasionando uma perda de 10% da produção média nos últimos anos².

Dentre estas doenças, o *greening*, também conhecido como *huanglong-bing* (HLB), é considerado atualmente a mais grave doença dos citros no mundo (Bové, 2006). Ela é causada pela bactéria *Candidatus Liberibacter* spp., e é transmitida pelo inseto psílideo *Diaphorina citri*, que adquire e transmite a bactéria às demais plantas ao se alimentar de uma planta já contaminada (FUNDECITRUS, 2009).

Por não possuir cura ou tratamento e por não existir variedade comercial de copa ou porta-enxerto resistente à doença, o controle do *greening* só pode ser feito com inspeção constante, eliminação imediata de plantas com sintomas e o controle do inseto transmissor. Atualmente, o método de inspeção visual e a análise do PCR (*Polymerase Chain Reaction*) (Innis et al., 1990), 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 são realizadas por inspetores caminhando a pé ou em plataformas movidas por tratores ao lado das plantas cítricas, como apresentado na Figura 1. Apesar de ser o método mais aplicado atualmente, sua eficácia depende de vários fatores, tais como, o conhecimento e prática na detecção de plantas sintomáticas, época do ano, genótipo e altura das plantas, incidência de raios solares nas plantas e no rosto do inspetor, apresentando em média 47,61% de precisão na detecção de plantas sintomáticas (Belasque et al., 2009).

O sintoma característico do *greening* aparece inicialmente em alguns ramos, apresentando folhas mosqueadas (manchas de formas irregulares, mescladas com o verde amareladas no fundo verde). Estas manchas são facilmente confundidas com outras doenças e deficiências nutricionais que se assemelham às características visuais do *greening* (FUNDECITRUS, 2009)

¹ Divulgação da safra paulista de laranja 2009/2010: <http://www.iea.sp.gov.br/out/LerTexto.php?codTexto=12002>

² <http://www.ripa.com.br/index.php?id=1823>

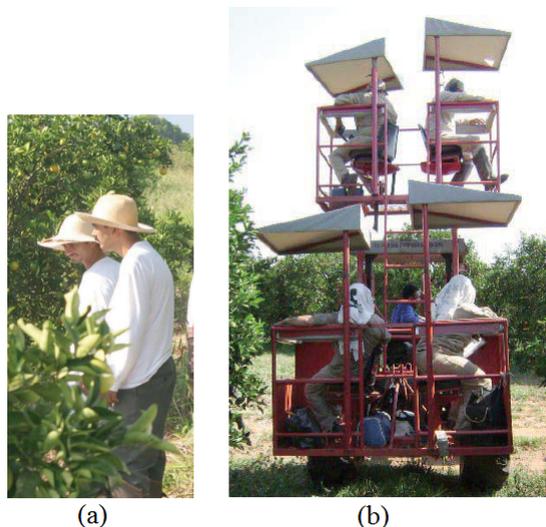


Figura 1. Inspeções visuais realizadas em pomares de citros, em a) realizada a pé, b) realizada por plataformas movidas por tratores (FUNDECITRUS, 2009).

como, por exemplo, as doenças CVC (Clorose Variiegado dos Citros), Rubelose e as deficiências de Magnésio, Manganês e Zinco. Isto causa confusão nos inspetores na identificação destas doenças pelo método visual. Nos experimentos apresentados por [Nutter Jr. & Schultz \(1995\)](#), [Martins et al. \(2004\)](#) e [Kowata et al. \(2008\)](#) é destacado a variação da mensuração entre os inspetores, evidenciando a necessidade de técnicas complementares.

Com os avanços na área de processamento digital de imagem, é possível fazer uso de métodos computacionais que auxiliem na diferenciação destas doenças. [Basset et al. \(2000\)](#) utilizam técnicas de visão computacional para inspeção da qualidade de produtos. [Sposito \(2004\)](#) elaborou uma escala diagramática para quantificar área foliar lesionada por doença a partir de processamento e análise de imagens e [Yonekawa et al. \(1996\)](#) verificam que os fatores de forma são úteis para a identificação de plantas por meio de suas folhas.

Este trabalho tem como objetivo aplicar técnicas de processamento de imagens, permitindo analisar imagens de folhas sintomáticas digitalizadas, por descritores de cor e forma, quantificando a severidade das manchas para auxiliar na diferenciação do *greening* e outras doenças em citros, possibilitando um diagnóstico mais rápido e preciso.

O capítulo está organizado da seguinte maneira: a Seção 2 aborda a teoria relacionada ao trabalho, na Seção 3 são apresentados os materiais e métodos, na Seção 4 são mostrados os resultados e a discussão, e finalmente na Seção 5 apresenta-se a conclusão.

2. Fundamentação Teórica

2.1 Extração de atributos

2.1.1 Segmentação por cor

A segmentação de uma imagem consiste em subdividir uma imagem em seus componentes básicos, com as características mais relevantes, sendo que estas características dependem do objeto de interesse. Para a segmentação por cor, encontra-se na literatura inúmeras aplicações com o uso de redes neurais artificiais (RNA) com bons resultados (Simões, 2000; Simões & Reali Costa, 2000). Em Cavani et al. (2006) e Simões et al. (2001) é utilizada segmentação por cor em imagens de frutas, utilizando-se uma RNA do tipo *Perceptron* multicamada (PMC) (Silva et al., 2010).

2.1.2 Descritores de forma

Em processamento de imagens, a aplicação de descritores de forma permite analisar e extrair características e parâmetros dos objetos da imagem. Para esta finalidade, nas Seções 2.1.2.1 até 2.1.2.5 foi utilizado o software Image Pro-Plus³.

2.1.2.1 Razão de aspecto

Razão de aspecto é a razão entre o eixo maior e eixo menor do objeto selecionado como, por exemplo, 4:3 ou 16:9, podendo ser observado na Figura 2, e implementado pela Equação 1 (Russ, 1998).



Figura 2. Ilustração da região representada pela razão de aspecto.

$$RazaodeAspecto = \frac{DiametroMaximo}{DiametroMinimo} \quad (1)$$

³ <http://www.mediacy.com/>

2.1.2.2 Diâmetro médio

São as medidas do comprimento do diâmetro medido a cada 2 graus de intervalo, passando pelo centróide do objeto, podendo ser observado na Figura 3.



Figura 3. Ilustração da região representada pelo diâmetro médio.

2.1.2.3 Razão do raio (*radius ratio*)

É a razão entre o raio máximo e o raio mínimo, em relação aos pontos centrais do objeto, como mostrado na Figura 4.



Figura 4. Ilustração da região representada pela razão do raio.

2.1.2.4 Aspecto arredondado (*roundness*)

Redondeza mede o a espessura média do objeto selecionado, como mostrado na Figura 5, Equação 2.

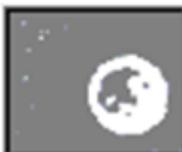


Figura 5. Ilustração da região representada redondeza.

$$\text{AspectoArredondado} = \frac{\text{Perimetro}^2}{4.\pi\text{Area}} \quad (2)$$

2.1.2.5 Feret médio

O diâmetro *feret* é a medida que caracteriza o tamanho do objeto selecionado (Russ, 1998), sendo a média dos *ferets* em várias direções. Pode ser observado na Figura 6.



Figura 6. Ilustração da região representada pelo diâmetro *feret*.

2.2 Quantificação de doenças

A escala diagramática é um método utilizado para quantificar uma doença, permitindo avaliar o grau de severidade e intensidade da lesão, mancha ou doença em uma folha. Desta maneira, pode-se providenciar a melhor medida de ação para o controle e combater a doença avaliada. Para o desenvolvimento das escalas diagramáticas devem ser observados os aspectos do limite superior e inferior da escala, que devem ser iguais à intensidade real de doença no campo. As subdivisões das escalas devem ser proporcionais ao logaritmo da intensidade do estímulo, respeitando as limitações da acuidade visual humana e baseando-se na lei de *Weber-Fechner* (Amorim, 1995), como se pode observar na Figura 7.

3. Materiais e Metodologia

A Figura 8 apresenta as etapas de processamento aplicadas às imagens foliares, sendo estas: aquisição, segmentação por cor, extração dos descritores de forma, divisão em quadrantes e classificação. A classificação visa a obtenção de um classificador para diferenciar as manchas amarelas das amostras das doenças e deficiências cujos sintomas mais se assemelham ao *greening*.

3.1 Aquisição dos dados

Foram fornecidas pela empresa Fischer⁴ seis tipos de folhas de citros com sintomas de doenças e deficiência nutricional, conforme a Figura 9. Es-

⁴ <http://www.citrusuco.com.br/fischer/fischer/sites/fischer/citrusuco/home/home.html>

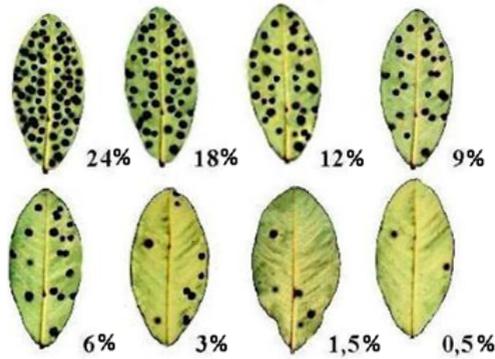


Figura 7. Exemplo de uma escala diagramática para mancha preta do amendoim. Fonte: (de Moraes, 2007).

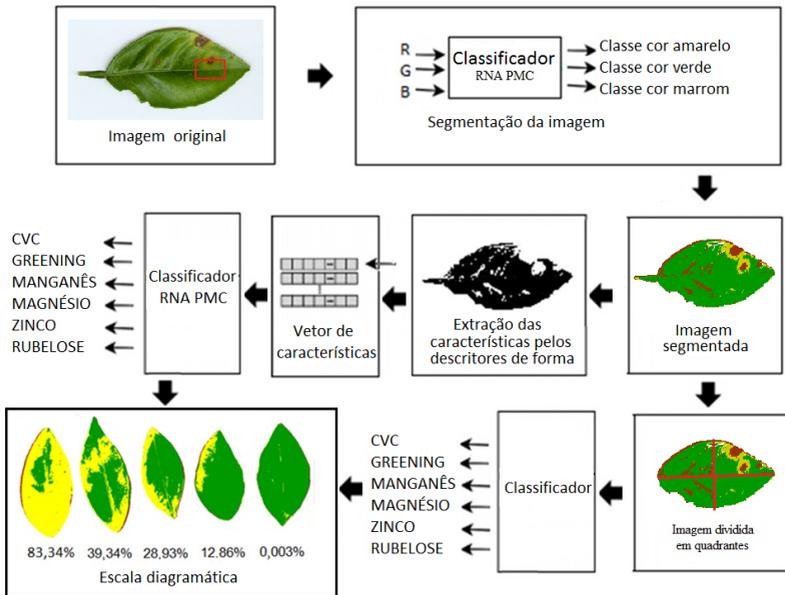


Figura 8. Etapas de processamento: aquisição, segmentação por cor, divisão por quadrante, processamento das doenças, extração de atributos e classificação das doenças com as informações extraídas do vetor de características e geração da escala diagramática.

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

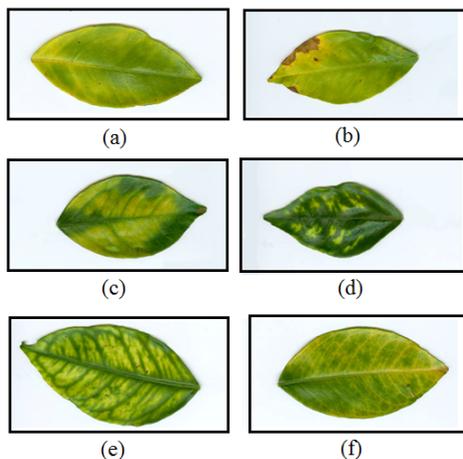


Figura 9. Amostras foliares com a) *Greening*, b) CVC, (c) Deficiência de Magnésio, (d) Deficiência de Manganês, (e) Deficiência de zinco, (f) Rubelose.

Conforme apresentado na Figura 9, os sintomas são:

- *Greening*: apresenta folhas mosqueadas ou clorose assimétrica;
- Deficiência de Magnésio: amarelecimento em forma de “V” invertido;
- Deficiência de Manganês: surge clorose entre as nervuras;
- Deficiência de Zinco: apresenta clorose acentuada do limbo entre as nervuras;
- CVC (Clorose Variegado dos Citros): apresenta pequenas manchas amareladas e irregulares, espalhada na frente, e lesões de cor palha nas costas da folha;
- Rubelose: apresenta lesão nas forquilhas dos ramos principais e as folhas da copa tornam-se amareladas.

Foram selecionadas 60 amostras de folhas, sendo 10 amostras para cada tipo de doença/deficiência. Estas amostras obtidas foram digitalizadas por um *scanner* fotográfico de mesa do modelo da HP Scanjet G4050, com resolução de 100 DPI, dimensão de 400 x 200 *pixels*, utilizando somente a parte frontal da folha.

3.2 Segmentação

A segmentação por cor foi utilizada para separar as manchas amarelas do fundo verde das folhas e de áreas com alguma necrose, caracterizada pela cor marrom. Foi aplicada a RNA com o algoritmo *backpropagation*, com uma camada de entrada, três camadas escondidas e três camadas saídas. Para o treinamento da rede foram utilizadas 46 amostras de um total de 60, sendo o restante utilizado para teste. Os parâmetros que melhor se ajustaram no treinamento com 96,04% de acurácia 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 sigmoideal. Os parâmetros de entrada da RNA foram as componentes de cor RGB de cada *pixel* das amostras selecionadas sobre a imagem, representando as cloroses, padrões de verde e necroses. Como saída, cada *pixel* analisado foi rotulado como sendo da classe amarelo, verde e marrom, correspondentes às manchas de clorose, área sadia e necrose, respectivamente. Um exemplo de imagem segmentada pode ser observado na Figura 10(a).

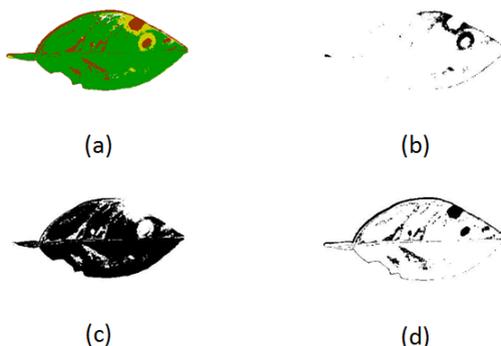


Figura 10. Apresenta as imagens das folhas segmentada por cor, em três classes de cores: a) imagem segmentada, b) somente amarelo, c) somente verde, d) somente marrom.

Após a imagem ser segmentada por cores (amarelo, verde e marrom), foram utilizadas cada imagem binária, geradas das porções amarela, verde e marrom da imagem, como apresentado nas Figura 10(b), 10(c), 10(d).

3.3 Extração dos descritores

Por meio das imagens binarizadas foram extraídos os valores estatísticos médio, máximo e mínimo das formas das manchas para os descritores de forma citados na Seção 2.1.2. Os valores médio, máximo e mínimo são demonstrados pelas Equações 3, 4 e 5, como se segue:

$$Media = \frac{1}{n} \sum_{i=0}^n f(x_i) \quad (3)$$

$$Maximo = Maxf(x_i) \quad (4)$$

$$Minimo = Minf(x_i) \quad (5)$$

Na Equação 3, n corresponde ao número de objetos ou manchas da imagem binarizada $f(x)$. Na Equação 4, o valor Máximo representa o maior valor dentre os objetos ou manchas encontrados na imagem binarizada $f(x)$. Na Equação 5, o valor Mínimo representa o menor valor dentre os objetos ou manchas encontrados na imagem binarizada $f(x)$.

Em seguida foram criados oito vetores de características descritos na Tabela 1 .

Tabela 1. Descrição de cada vetor.

Vetor	Cor	Atributos	Instância
1º	Amarelo	15	60
2º	Verde	15	60
3º	Marrom	15	60
4º	Amarelo+Verde	30	60
5º	Amarelo+Verde+Marrom	45	60
6º	Amarelo+Verde+Marrom	45	50
7º	Amarelo+Verde+Marrom	45	40
8º	Amarelo+Verde+Marrom	45	30

Do primeiro ao quinto vetor, foram utilizadas seis classes de doenças: CVC, Magnésio, Manganês, Zinco, *Greening*, Rubelose.

Para o sexto vetor foram utilizadas cinco classes de doenças: CVC, Magnésio, Manganês, Zinco, *Greening*.

Para o sétimo vetor foram utilizadas quatro classes: CVC, Manganês, Zinco, *Greening*.

Para o oitavo vetor foram utilizadas três classes de doenças: Manganês, Zinco, *Greening*.

3.4 Divisão em quadrantes

Devido às manchas de *greening* apresentarem a cor amarela assimetricamente, conforme mencionado na Seção 3.1, foi proposta 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 o centro de massa nas coordenadas (x_{CM}, y_{CM}) e os pontos delimitadores do momento central $(\alpha_{min}, \alpha_{max}, \beta_{min}$ e $\beta_{max})$, conforme apresentado na Figura 11.

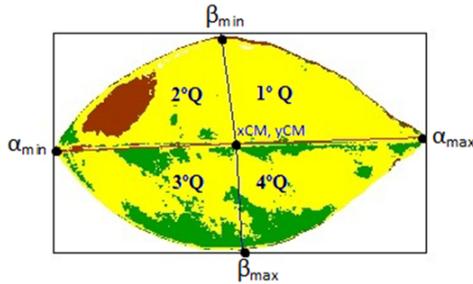


Figura 11. Imagem segmentada em quadrantes.

O cálculo do centro de massa em relação a uma região R é dado pelas Equações 6 e 7 (Jain, 1989).

$$x_{CM} = \frac{1}{N_t} \sum_{i=0 \in R}^{x-1} X_i \quad (6)$$

$$y_{CM} = \frac{1}{N_t} \sum_{i=0 \in R}^{y-1} Y_i \quad (7)$$

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 determina-se os valores de $\mu_{p,q}$ (momentos centrais) pela Equação 8, variando-se (p, q) entre $[0, 2]$, e o valor de θ_{CM} (ângulo do momento central) dado pela Equação 9 (Jain, 1989).

$$\mu_{p,q} = \sum_{i=0}^{x-1} \sum_{i=0}^{y-1} (X_i - x_{CM})^p (Y_i - y_{CM})^q \quad (8)$$

$$\theta_{CM} = \frac{1}{2} \tan^{-1} \left[\frac{2\mu_{1,1}}{\mu_{2,0} - \mu_{0,2}} \right] \quad (9)$$

$$\alpha_b = X \cdot \cos \cdot \theta_{CM} + Y \cdot \sin \cdot \theta_{CM} \quad (10)$$

$$\beta_b = -X \cdot \sin \cdot \theta_{CM} + Y \cdot \cos \cdot \theta_{CM} \quad (11)$$

Determinado o θ_{CM} , usam-se as Equações 10 e 11 para determinar os mínimos e máximos pontos 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, desta maneira, dividir a imagem em quadrantes.

3.5 Classificação

Para a classificação de padrões foi utilizada a API (*Application Programming Interface*) do *toolbox* WEKA⁵, para construção do classificador foi utilizado uma RNA do tipo *Perceptron* multicamada (PMC) com o algoritmo *backpropagation* (Witten & Frank, 2005).

4. Resultados e Discussão

O conjunto de classificação utilizou a combinação de atributos das classes de doenças, buscando encontrar a influência da distribuição das cores e forma na classificação entre as classes de doenças. Durante o processo de classificação foram utilizados 80% das instâncias para o treinamento da RNA e 20% das instâncias para os testes.

4.1 Influência das cores

Para verificar a influência da distribuição espacial das cores nas folhas, como por exemplo, a distribuição do *greening* que apresenta as manchas amarelas assimétricas nas folhas, foi aplicada uma RNA. Os parâmetros da mesma foram ajustados com base nos testes realizados previamente. Desta forma, para a RNA foi utilizado uma camada de entrada, três camadas de neurônios escondidos e uma camada de saída. Para a taxa de aprendizado foi utilizado o valor 0,3, para o momento 0,2 e o número de épocas foi limitado a 500. Em todos os testes foi utilizado o esquema de validação cruzada com 10 *folds*, e a função de ativação foi a sigmóide.

A Tabela 2 apresenta os resultados da classificação geral. Foram utilizadas 60 instâncias para cada vetor, sendo que deste total o classificador conseguiu classificar corretamente trinta e duas instâncias para o 1º vetor, representando um percentual de 53,33%, vinte e seis para o 2º vetor (43,33%), dezesseis para o 3º vetor (26,67%), trinta e três para o 4º vetor (55%) e trinta e oito para o 5º vetor (63,33%). Desta forma é possível observar que apenas a distribuição de uma única cor na folha não é o suficiente para diferenciar o *greening* de outras doenças. O quinto vetor, por exemplo, é composto pelas cores amarelo, verde e marrom, e apresenta o melhor resultado (63,33%) na classificação geral das instâncias, se comparado aos demais vetores. Os valores obtidos para o erro quadrático médio (EQM) e o valor do erro absoluto médio (EAM) para este vetor também foram inferiores aos demais valores obtidos com os outros vetores.

Na Tabela 3 para o quarto vetor o classificador obteve para a CVC a precisão de acertos de 71,40%, para o Magnésio 42,90%, para o Manganês 60%, para o Zinco 58,30%, para o *greening* 57,10% e para a Rubelose 50%. Para o quinto vetor o classificador obteve para a CVC 63,60%, para o Magnésio 57,10%, para o Manganês 63,60%, para o Zinco 69,20%, para

⁵ <http://www.cs.waikato.ac.nz/ml/weka>

Tabela 2. Resultados EQM e EAM obtidos na classificação da RNA para cada classe de cor do 1° ao 5° vetor.

Vetor	Cor	EQM	EAM	Classificação Correta (%)
1°	Amarelo	32,70%	15,43 %	53,33%
2°	Verde	37,87 %	20,46 %	43,33%
3°	Marrom	42,47%	24,70 %	26,67%
4°	Amarelo+Verde	33,74 %	15,36 %	55,00%
5°	Amarelo+Verde+Marrom	31,59 %	14,84 %	63,33%

Tabela 3. Valores de precisão obtidos na classificação por RNA para cada classe de cor em relação às doenças do 1° ao 5° vetor, onde A=CVC, B=Magnésio, C=Manganês, D=Zinco, E=*Greening*, F=Rubelose.

Vetor	Cor	Precisão					
		A	B	C	D	E	F
1°	Amarelo	50%	70%	58,30%	50%	41,70%	50%
2°	Verde	25%	44,4%	41,7%	60%	36,4%	50%
3°	Marrom	37,5%	0%	30%	30%	31,3%	28,6%
4°	Amarelo+Verde	71,4%	42,9%	60%	58,3%	57,10%	50%
5°	Amarelo+Verde+Marrom	63,6%	57,10%	63,60%	69,2%	50%	70%

o *greening* 50% e para a Rubelose 60%. Dessa forma observa-se que os melhores resultados obtidos com o classificador só foram obtidos mediante a combinação das cores distribuídas nas folhas.

4.2 Influência das doenças

Conforme mencionado na Seção 3.3, que descreve os vetores de características utilizados neste trabalho, a similaridade presente nas doenças leva a maiores erros no processo de classificação. A Tabela 4 apresenta os resultados obtidos com o classificador para os vetores 6°, 7° e 8°. O oitavo vetor apresenta o melhor resultado para a classificação, pois o mesmo utiliza apenas as classes Magnésio, Zinco e *Greening*. Das 30 instâncias analisadas do 8° vetor, 25 delas foram classificadas corretamente, representando um percentual de 83,33% de acerto. O valor do EQM e do EAM foram respectivamente 31,75% e 15,39%.

A Tabela 5 apresenta os resultados obtidos com a precisão dada pelos classificadores para cada classe de doença. Para a CVC a precisão dada no sexto vetor foi de 66,7%, para o sétimo vetor foi de 75%. Para o Magnésio a precisão para o sexto vetor foi de 60% e para o oitavo vetor 100%. Para o Manganês a precisão do sexto vetor foi de 63,60% e para o sétimo vetor foi de 58,30%. Para o Zinco a precisão do sexto vetor foi de 57,10%, para

Tabela 4. Resultados EQM e EAM obtidos na classificação da RNA para cada classe de cor do 6° ao 8° vetor.

Vetor	Cor	EQM	EAM	Classificação Correta (%)
6°	Amarelo+Verde+Marrom	32,15%	15,23 %	62%
7°	Amarelo+Verde+Marrom	35,21%	17,57 %	70%
8°	Amarelo+Verde+Marrom	31,75%	15,39 %	83,33%

Tabela 5. Valores de Precisão obtidos na classificação por RNA para cada classe de cor em relação às doenças do 6° ao 8° vetor, onde: A=CVC, B=Magnésio, C:Manganês, D=Zinco, E=*Greening*, F=Rubelose.

Vetor	Cor	Precisão					
		A	B	C	D	E	F
6°	Amarelo+Verde+Marrom	66,7%	60%	63,6%	57,1%	63,6%	-
7°	Amarelo+Verde+Marrom	75%	-	58,3%	87,50%	66,7%	-
8°	Amarelo+Verde+Marrom	-	100%	-	80%	72,7%	-

o sétimo vetor 87,50% e para o oitavo vetor foi de 80%. Para o *Greening* a precisão do sexto vetor foi de 63,60%, para o sétimo vetor 66,70% e para o oitavo vetor 72,70%. Desta forma, observa-se que o menor número de doenças melhora os resultados obtidos com o classificador.

4.3 Escala diagramática

Para calcular os níveis de severidade de uma escala diagramática serão considerados os valores de máximo e de mínimo de proporção de área foliar manchada com a cor amarela, como os limites da escala diagramática. Serão utilizados cinco níveis de severidade das doenças analisadas, conforme padrão adotado em campo pela empresa Fischer. Foi gerada manualmente uma escala diagramática para cada tipo de doença baseando-se nos resultados preliminares obtidos com a RNA PMC. Estes resultados são apresentados nas Figuras 12 a 17.

A Figura 12 apresenta a escala diagramática da doença CVC, com os seguintes níveis de severidade: 56,69%, 43,10%, 27,86%, 13,12% e 0,07%. Observa-se nas folhas a presença de pequenas manchas amareladas e irregulares, e lesões na cor marrom.

A Figura 13 apresenta a escala diagramática para a deficiência de Magnésio, com os seguintes níveis de severidade: 57,27%, 42,31%, 28,87%, 13,02% e 0,23%. Observa-se nas folhas o amarelecimento em forma de “V” invertido.

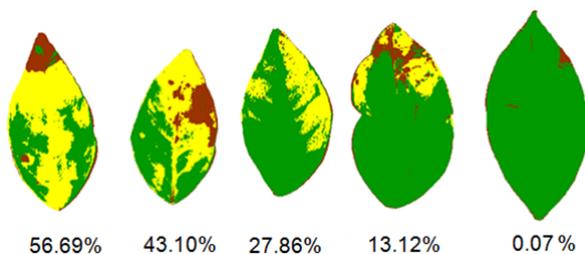


Figura 12. Escala diagramática do CVC.

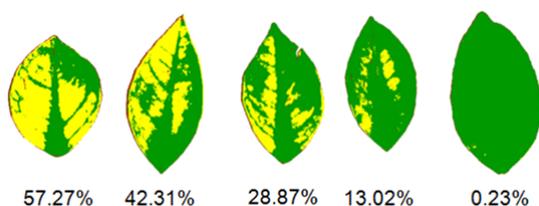


Figura 13. Escala diagramática da deficiência de Magnésio.

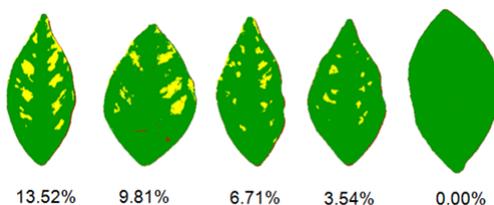


Figura 14. Escala diagramática da deficiência de Manganês.

A Figura 14 apresenta a escala diagramática para a deficiência de Manganês, com os seguintes níveis de severidade: 13,52%, 9,81%, 3,54%, 6,71% e 0,0%. Observa-se nas folhas que as manchas são menores entre as nervuras, sendo menos acentuadas que na deficiência de Magnésio, além de serem distribuídas de uma forma mais simétrica.

A Figura 15 apresenta a escala diagramática para a deficiência de Zinco, com os seguintes níveis de severidade: 74,07%, 54,24%, 35,43%, 17,56% e 3,05%. Observa-se que as folhas apresentam clorose acentuada do limbo entre as nervuras.

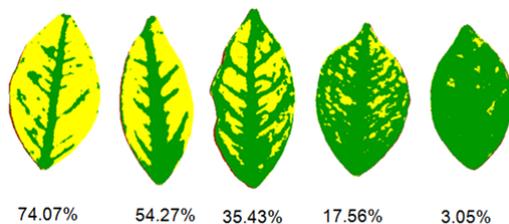


Figura 15. Escala diagramática da deficiência de Zinco.

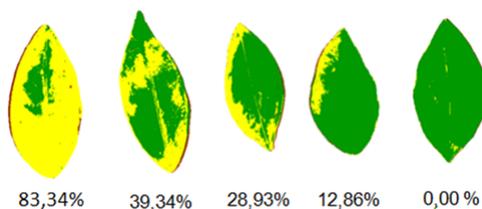


Figura 16. Escala diagramática *greening*.

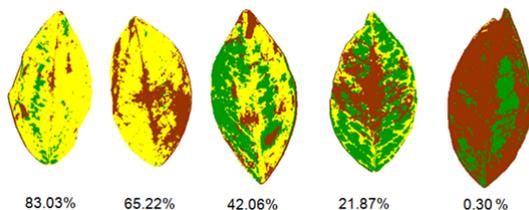


Figura 17. Escala diagramática da Rubelose.

A Figura 16 apresenta a escala diagramática para o *greening*, com os seguintes níveis de severidade: 83,34%, 39,34%, 28,93%, 12,86% e 0,00%. Observa-se nas folhas a clorose assimétrica.

A Figura 17 apresenta a escala diagramática para a Rubelose, com os seguintes níveis de severidade: 83,03%, 65,22%, 42,06%, 21,87% e 0,30%. Observa-se nas folhas manchas amarelas com lesões.

5. Conclusões

A proposta deste trabalho é aplicar técnicas de processamento de imagens em folhas de citros digitalizadas, para diferenciar o *greening* de outras pragas. A segmentação por cor usando RNA PMC, mostrou ser adequada, com acurácia de 96,04%. Em seguida, a imagem foi dividida em quadrantes para possibilitar uma análise inicial para diferenciar a variação das manchas em cada quadrante, para cada doença. A aplicação da RNA apresenta um melhor resultado na classificação das classes quando utilizada para as classes que mais se assemelham ao *greening*, isto é, as classes Manganês e Zinco. A acurácia obtida para essas instâncias foi de 83,33%. Este trabalho mostrou que apenas a cor amarela e sua distribuição, indicada pelos descritores de forma não consegue diferenciar totalmente o *greening* de outras doenças. Para uma melhor diferenciação destas doenças, faz-se necessário a combinação da distribuição das cores amarelo, verde e marrom. Para trabalhos futuros, pretende-se avaliar os resultados obtidos na análise por quadrantes juntamente com os resultados obtidos pela extração de atributos, possibilitando diferenciar o *greening* de outras pragas, e posteriormente construir a escala diagramática.

Agradecimentos

Os autores agradecem o apoio financeiro do CNPq (processo 578627/2008-6) e o fornecimento das amostras de foliares pela empresa Fischer.

Referências

- Agriannual, . *Anuário da Agricultura Brasileira*. São Paulo, SP, 2008. p. 520.
- Amorim, L., Avaliação de doenças. In: Bergamin Filho, A.; Kimati, H. & Amorim, L. (Eds.), *Manual de Fitopatologia – princípios e conceitos*. São Paulo, SP: Agronômica Ceres, v. 1, p. 647–671, 1995.
- Basset, O.; Buquet, B.; Abouelkaram, S.; Delachartre, P. & Culioli, J., Aplicación de texture image analysis for the classification of bovine meat. *Food Chemistry*, 69(4):437–445, 2000.
- Belasque, J.R.J.; Filho, A.B.; Bassanezi, R.B.; Barbosa, J.C.; Gimenes-Fernandes, N.; Yamamoto, P.; Lopes, A.S.; Machado, M.A.; Leite, J.R.P.; Ayres, A.J. & Massari, C.A.. *Greening: A instrução normativa n. 53 e a necessidade de um controle efetivo no Brasil*, 2009. p. 1–5. [Http://www.fundecitrus.com.br/ImageBank/FCKEditor/file/pdf/artigo_controle_greening.pdf](http://www.fundecitrus.com.br/ImageBank/FCKEditor/file/pdf/artigo_controle_greening.pdf).
- Bové, J.M., Huanglongbing: a destructive, newly-emerging, century-old disease of citrus. *Journal of Plant Pathology*, 88(1):7–37, 2006.

- Cavani, F.A.; de Sousa, R.V.; Porto, A.J.V. & Tronco, M.L., Segmentação e classificação de imagens de laranjeiras utilizando JSEG e perceptron multicamadas. *Revista Minerva*, 3(2):189–197, 2006.
- FUNDECITRUS, . Manual técnico *Greening* 2009. Araraquara, SP, 2009. p. 1–12. [Http://www.cda.sp.gov.br/greening/lnk_greening_ctr/downloads/greening.pdf](http://www.cda.sp.gov.br/greening/lnk_greening_ctr/downloads/greening.pdf).
- Innis, M.A.; Gelfand, D.H.; Sninsky, J.J. & White, T.J., *PCR Protocols: A guide to methods and applications*. San Diego, USA: Academic Pres, 1990.
- Jain, A.K., *Fundamentals of Digital Image Processing*. Englewood Cliffs, USA: Prentice Hall, 1989.
- 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*, 9(1):105–110, 2008.
- 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*, 29(2):179–184, 2004.
- de Moraes, S.A., Quantificação de doenças de plantas. 2007. [Http://www.infobibos.com/Artigos/2007_1/doencas/index.htm](http://www.infobibos.com/Artigos/2007_1/doencas/index.htm).
- 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*, 17(2):174–184, 1995.
- Russ, J.C., *The Image Processing Handbook*. 3a edição. Boca Raton, USA: CRC Press, 1998.
- Silva, I.N.; Spatti, D.H. & Flauzino, R.A., *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas: Um Curso Prático*. Porto Alegre, RS: Artliber, 2010.
- Simões, A.S., *Segmentação de imagens por classificação de cores: uma abordagem neural*. Dissertação de mestrado em engenharia, Escola Politécnica da Universidade de São Paulo, São Paulo, SP, 2000.
- Simões, A.S. & Reali Costa, A.H., Using neural color classification in robotic soccer domain. In: Barros, L.N.; Cesar Jr., R.M.; Cozman, F.G. & Reali Costa, A.H. (Eds.), *Proceedings of International Joint Conference IBERAMIA-SBIA – Workshop Meeting on Multi-Agent Collaborative and Adversarial Perception, Planning, Execution, and Learning*. Atibaia, SP: SBC, p. 208–213, 2000.
- Simões, A.S.; Reali Costa, A.H. & Andrade, M.T.C., Utilizando um classificador *fuzzy* para seleção visual de laranjas. In: Ribeiro, C.H.C. & Sakude, M.T.S. (Eds.), *Anais do Workshop de Computação*. São José dos Campos, SP: ITA, p. 113–117, 2001.

- Sposito, M.B., *Dinâmica temporal e espacial da mancha preta (Guignardia citricarpa) e quantificação dos danos causados à cultura dos citros*. Tese de doutorado em fisiopatologia, Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, SP, 2004.
- Witten, I.H. & Frank, E., *Data mining: practical machine learning tools and techniques*. 2a edição. San Francisco, USA: Morgan Kaufmann, 2005.
- Yonekawa, S.; Sakai, N. & Kitani, O., Identification of idealized leaf type using simple dimensionless shape factors by image analysis. *Transactions of the ASAE*, 39(4):1525–1533, 1996.

Notas Biográficas

Patricia Pedroso Estevam Ribeiro é graduado em Engenharia Elétrica com ênfase em computação (Faculdade de Engenharia de Barretos, 2006). Atualmente é mestrando em Engenharia Elétrica na USP São Carlos na área de processamento digital de imagens.

Maria Stela Veludo de Paiva possui graduação em Engenharia Elétrica/Eletrônica (Universidade de São Paulo – USP, 1979), mestrado e doutorado em Física Aplicada (USP/São Carlos, 1984 e 1990), tendo realizado Pós-Doutorado na University of Southampton (1992). Atualmente é docente no Departamento de Engenharia Elétrica da Escola de Engenharia de São Carlos (USP) e desenvolve pesquisas na área de Visão Computacional.

Lúcio André de Castro Jorge é graduado em Engenharia Elétrica (Faculdade de Engenharia de Barretos, 1987), mestre em Ciência da Computação (USP São Carlos, 2001) e doutor em Engenharia Elétrica na área de processamento digital de imagens (USP São Carlos, 2011). Atualmente é pesquisador da EMBRAPA Instrumentação em São Carlos.