



VII Workshop de Visão Computacional

Anais do Evento

www.wvc2011.ufpr.br

22 a 25 de maio de 2011 - UFPR - Curitiba

ISSN - 2175-6120

WVC 2011

Anais do VII Workshop de Visão Computacional

Universidade Federal do Paraná

ISSN 2175-6120

Editores:

Luiz Antônio Pereira Neves

Lucas Ferrari de Oliveira

Hugo Vieira Neto

Curitiba, 22 a 25 de Maio de 2011

Diferenciação da *Greening* do citros de outras doenças foliares a partir de descritores de cor e forma

Patricia Pedroso Estevam Ribeiro¹; Lúcio André de Castro Jorge²; Maria Stela Veludo de Paiva³.

1- Mestrando, Escola de Engenharia de São Carlos - Universidade de São Paulo - USP, Depto. de Engenharia Elétrica, São Carlos-SP, patriciapedrosoestevam@hotmail.com

2- Pesquisador, Embrapa Instrumentação Agropecuária, São Carlos – SP, lucio@cnpdia.embrapa.br

3- Professora, Escola de Engenharia de São Carlos - Universidade de São Paulo - USP, Depto. de Engenharia Elétrica, São Carlos-SP, mstela@sc.usp.br

Abstract

The citrus culture since the beginning of the twentieth century has been subjected to several attacks of pests and diseases, among these diseases, *Greening* or *Huanglongbing (HLB)*, is currently considered the most serious disease of citrus worldwide. Until now there isn't cure or treatment, and disease control is currently carried out by visual inspection method. In order to help the visual inspection method, this work test image processing techniques to help in differentiating the *Greening* from other diseases, by color image segmentation of leaves and classification based on shape descriptors. The results show that only the yellow stain is not a strong differentiator of this disease.

1. Introdução

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, apesar do crescimento da produção de laranja, (cerca de 318,6 milhões de caixas em 2010, segundo os dados do Instituto de Economia Agrícola), ocasionando uma perda de 10% da produção média nos últimos anos [1], [9].

Dentre essas doenças, a *Greening*, também conhecida como *Huanglongbing (HLB)*, é considerada 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 [3].

Por não possuir cura ou tratamento e por não existir variedade comercial de copa ou porta-enxerto resistente à doença, o controle da *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*) [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 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 [23].



Figura 1. Inspeções visuais realizadas em pomares de citros, em a) realizada a pé, b) realizada por plataformas movidas por tratores [3].

O sintoma característico da *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 da *Greening* [3] como por exemplo, as doenças CVC (Clorose Variegado dos Citros), Rubelose e as deficiências de Magnésio, Manganês e Zinco, confundindo os inspetores na identificação destas doenças pelo método visual. Nos experimentos apresentados por [11], [12], [13] 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., [5], utilizam técnicas de visão computacional para inspeção da qualidade de produtos. Yohekawa et al., [7], verificam que os fatores de forma são uteis para a identificação de plantas por meio de suas folhas.

Este trabalho tem como objetivo desenvolver uma ferramenta baseada em descritores de cor e forma, para auxiliar na diferenciação da *Greening* e outras doenças em citros, possibilitando um diagnóstico mais rápido e preciso.

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

2. Extração de atributos

2.1. 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, encontram-se, na literatura, inúmeras aplicações com o uso de redes neurais artificiais (RNA), com bons resultados [16], [17]. Em Cavani et al., [19] e Simões et al., [18] é utilizada segmentação por cor em imagens de frutas, utilizando de uma RNA do tipo *Perceptron* multicamada (PMC) [22].

2.2. Descritores de forma

Em processamento de imagens, a aplicação de descritores de forma, permite analisar e extrair características e parâmetros dos objetos da imagem.

2.2.1. Razão de aspecto

Razão de aspecto é a razão entre o eixo maior e eixo menor do objeto selecionado [20], como por exemplo, 4:3 ou 16:9, podendo ser observado na Figura 2, e implementado pela Equação 1 [8].



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

$$\text{Razão de Aspecto} = \frac{\text{Diâmetro Máximo}}{\text{Diâmetro Mínimo}} \quad (1)$$

2.2.2. 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 [20].



Figura 3. Ilustração da região representada pelo diâmetro médio.

2.2.3. Razão do raio (*Radius ratio*)

E a razão entre o raio máximo e o raio mínimo, em relação aos pontos centrais do objeto [20]. Podendo ser observado na Figura 4.



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

2.2.4. Aspecto arredondado (*Roundness*)

Redondeza mede o a espessura média do objeto selecionado [20]. Podendo ser observado na Figura 5, Equação 2.



Figura 5. Ilustração da região representada redondeza.

$$\text{Aspecto Arredondado} = \frac{\text{Perímetro}^2}{4\pi \cdot \text{Área}} \quad (2)$$

2.2.5. *Feret* médio

O diâmetro *feret* é à medida que caracteriza o tamanho do objeto selecionado [8]. O *feret* médio é a média dos *ferets* em várias direções.



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

3. Materiais e métodos

A Figura 7 apresenta as etapas de processamentos aplicadas nas imagens foliares, sendo estas: aquisição, segmentação por cor, extração dos descritores de forma e classificação. A classificação visava a obtenção de um

classificador para diferenciar espacialmente as manchas amarelas das amostras das doenças e deficiências cujos sintomas mais se assemelham ao *Greening*.

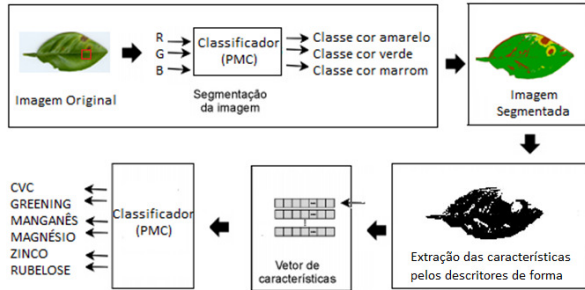


Figura 7. Etapas de processamento: aquisição, segmentação por cor, extração de atributos e classificação das doenças.

3.1. Aquisição dos dados

Foram fornecidas pela empresa FISHER seis tipos de folhas de citros com sintomas de doenças e deficiência nutricional, conforme a Figura 8. Estas amostras foram selecionadas por um técnico agrônomo denominado pragueiro, que identificou os sintomas, apenas por meio da inspeção visual, segundo instruções do manual técnico do *Greening*, fornecido pela FUNDECITRUS [3].

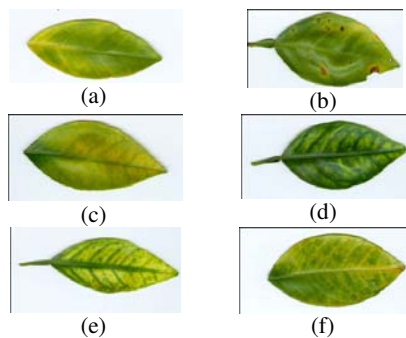


Figura 8. Amostras foliares com a) *Greening*, b) CVC, (c) Deficiência de Manganês, (d) Deficiência de Magnésio, (e) Deficiência de zinco, (f) Rubelose.

Conforme apresentado na Figura 8, 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 Variado 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; 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 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 sigmóidal.

Os parâmetros de entrada da RNA foram às 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 observada na Figura 9 (a).




Figura 9. Apresenta as imagens das folhas segmentada por cor, em 3 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 Figuras 9(b), 9(c), 9(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 2.2. Os valores médio, máximo e mínimo são demonstrados pelas Equações 3, 4 e 5, como segue:

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

Na Equação 3, n corresponde ao número de objetos ou manchas da imagem binarizada $f(x)$.

$$Máximo = \text{Max } f(x_i) \quad (4)$$

Na Equação 4, o valor Máximo representa o maior valor dentre os objetos ou manchas encontrados na imagem binarizada $f(x)$.

$$Mínimo = \text{Min } f(x_i) \quad (5)$$

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. Tabela com a descrição de cada vetor.

Vetor	Cor	Atributos	Instâncias
1°	Amarelo	15	60
2°	Verde	15	60
3°	Marrom	15	60
4°	Amarelo+verde	30	60
5°	Amarelo+verde+marrom	45	60
6°	Amarelo+verde+marrom	45	50
7°	Amarelo+verde+marrom	45	40
8°	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. Classificação

Para a classificação de padrões foi utilizada a API (*Application Programming Interface*) do *toolbox* WEKA [14], para construção do classificador foi utilizado uma

RNA do tipo *Perceptron* multicamada (PMC) com o algoritmo *backpropagation* [15].

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 da *Greening* que apresenta as manchas amarelas assimétricas nas folhas, foi aplicada uma RNA e os parâmetros da mesma foram ajustados com base nos testes realizados previamente. Dessa forma, para a RNA foi utilizado uma camada de entrada, três camadas neurais escondidas 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, desse total, o classificador conseguiu classificar corretamente trinta e duas instâncias para o 1° vetor, representando um percentual de 53,33%, vinte e seis para o 2° vetor, representando 43,33%, dezesseis para o 3° vetor, representando 26,67%, trinta e três para o 4° vetor, representando 55% e trinta e oito para o 5° vetor, representando 63,33%. Dessa forma é possível observar que apenas a distribuição de uma única cor na folha não é o suficiente para diferenciar a *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.

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%
5°	Amarelo+verde+marrom	31,59%	14,84%	63,33%

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 a *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 a *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.

Tabela 3. Valores de Precisão obtidos na classificação por RNA para cada classe de cor em relação às doenças do 1° ao 5° vetor.

Vetor	Cor	Precisão					
		CVC	Magnésio	Manganês	Zinco	Greening	Rubelose
1°	Amarelo	50,00%	70,00%	58,30%	50,00%	41,70%	50,00%
2°	Verde	25,00%	44,40%	41,70%	60,00%	36,40%	50,00%
3°	Marrom	37,50%	0	30,00%	30,00%	31,30%	28,60%
4°	Amarelo+verde	71,40%	42,90%	60,00%	58,30%	57,10%	50,00%
5°	Amarelo+verde+marrom	63,60%	57,10%	63,60%	69,20%	50,00%	70,00%

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 trinta instâncias analisadas do 8° vetor, vinte e cinco 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%.

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%

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 o sétimo vetor 87,50% e para o oitavo vetor foi de 80%.

Para a *Greening* a precisão do sexto vetor foi de 63,60%, para o sétimo vetor 66,70% e para o oitavo vetor 72,70%.

Dessa forma, é possível observar que o menor número de doenças melhora os resultados obtidos com o classificador.

Tabela 5. Valores de Precisão obtidos na classificação por RNA para cada classe de cor em relação às doenças do 6° ao 8° vetor.

Vetor	Cor	Precisão					
		CVC	Magnésio	Manganês	Zinco	Greening	Rubelose
6°	Amarelo+verde+marrom	66,70%	60,00%	63,60%	57,10%	63,60%	Não Usada
7°	Amarelo+verde+marrom	75,00%	Não Usada	58,30%	87,50%	66,70%	Não Usada
8°	Amarelo+verde+marrom	Não Usada	100,00%	Não Usada	80,00%	72,70%	Não Usada

5. Conclusão

A aplicação da RNA apresenta um melhor resultado na classificação das classes quando utilizada para as classes que mais se assemelham ao *Greening*, neste caso 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 espacial, indicada pelos descritores de forma não consegue diferenciar totalmente a *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 aumentar o número de amostras foliares e o número de atributos extraídos, verificando assim o descritor de forma que melhor auxilia na diferenciação das doenças.

6. Agradecimentos

Agradecemos o apoio financeiro do CNPq (processo 578627/2008-6) e o fornecimento das amostras de foliares pela empresa FISHER.

7. Referência bibliográfica

- [1] 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.
- [2] BOVÉ, J. M. Huanglongbing: a destructive, newly-emerging, century-old disease of citrus. **Journal of Plant Pathology**, Pisa, v. 88, p.7-37, 2006.
- [3] FUNDECITRUS. Manual Técnico do Greening 2009. Disponível em:

- <http://www.fundecitrus.com.br/ImageBank/PageFlip/pag_eflip.aspx?idPage=143>. Acesso em: 29 abr. 2010.
- [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] BASSET, O.; BUQUET, B.; ABOUELKARAM, S.; DELACHARTRE, P.; CULIOLI, J. Application of texture image analysis for the classification of bovine meat. **Food Chemistry**, v. 69, n. 4, p. 437 - 445, 2000.
- [6] GONZALEZ, R.; WOODS, R. **Processamento Digital de Imagens**, Pearson Education do Brasil, 2010.
- [7] YONEKAWA, S.; SAKAI, N.; KITANI, O. Identification of idealized leaf type using simple dimensionless shape factors by image analysis. **Transactions of the ASAE**. v. 39, n.4, p. 1525-1533, 1996.
- [8] RUSS, J. C. **The Image Processing Handbook**. 3ed. CRC Press LLC, 1998.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] MARTINS, M.C.; GUERZONI, R.A.; CÂMARA, G.M.S., MATTIAZZI, P., LOURENÇO, S.A. & AMORIM, L. Escala diagramática para a quantificação o complexo de doenças foliares de final de ciclo em soja. **Fitopatologia Brasileira** vol.29, p.179-184, 2004.
- [13] KOWATA, L. S.; MAY-DE-MIO, L. L.; DALLA-PRIA, M.; SANTOS H. A. Escala Diagramática para avaliar severidade de míldio na soja. **Scientia Agraria**, Curitiba, v.9, n.1, p.105-110, 2008.
- [14] WEKA. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Acesso em: 29 abr. 2010.
- [15] WITTEN, I. H.; FRANK, E. Data mining: practical machine learning tools and techniques. 2 ed. San Francisco, 2005.
- [16] SIMÕES, A. S. Segmentação de imagens por classificação de cores: uma abordagem neural. DISSERTAÇÃO DE MESTRADO. ESCOLA POLITÉCNICA DA USP. São Paulo. 2000.
- [17] SIMÕES, A. S.; REALI COSTA, A. H. Using Neural Color Classification in Robotic Soccer Domain. INTERNATIONAL JOINT CONFERENCE IBERAMIA'2000 and SBIA'2000, Workshop Proceedings, Meeting on Multi-Agent Collaborative and Adversarial Perception, Planning, Execution, and Learning. L. N. Barros, R. M. Cesar Jr., F. G. Cozman, A. H. Reali Costa (eds.). São Paulo, ISBN 85-901664-1-4, November 2.000, Atibaia, SP, Brazil, p.208-213.
- [18] SIMÕES, A. S.; REALI COSTA, A. H.; ANDRADE M. T. C. Utilizando um classificador fuzzy para seleção visual de laranjas. **Workshop de Computação - WORKCOMP'2001**. Carlos H. C. Ribeiro and Milton T. S. Sakude. p. 113-117. ITA, 2001.
- [19] 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.
- [20] IMAGE PRO PLUS. Disponível em: <<http://www.mediacy.com/>>. Acessado em: 18 Fev. 2011.
- [21] THEODORIDIS, S. **Pattern Recognition**. Academic Press, USA, 1st edition, 1999.
- [22] SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. Redes Neurais Artificiais para engenharia e e ciências aplicadas curso pratico. Ed. Artliber. 2010.
- [23] A INSTRUÇÃO NORMATIVA Nº53 E A NECESSIDADE DE UM CONTROLE EFETIVO DO GREENING NO BRASIL, 2009, Disponível em <http://www.fundecitrus.com.br/ImageBank/FCKEditor/file/pdf/artigo_controle_greening.pdf>. Acessado em : 18 Fev. 2011.