

Identificação de extensas áreas de culturas agrícolas empregando uma abordagem espectro-temporal utilizando imagens MODIS

Alessandra Lopes Braga¹
Carlos Antônio Oliveira Vieira²
Leonardo Campos de Assis³

Universidade Federal de Viçosa - UFV
Departamento de Engenharia - DEC
Setor de Engenharia de Agrimensura
36570-000 - Viçosa - MG, Brasil
¹ alessandralb@hotmail.com
² carlos.vieira@ufv.br
³ assis_leonardo@yahoo.com.br

Abstract. A methodology that takes into account a multitemporal multispectral analysis applied to MODIS images in order to classify croplands in a region of Limeira-SP, southeast of Brazil is presented. This paper presents a comparative study of two different classifiers (Artificial Neural Network and Maximum Likelihood), two interpolators (Collocation and Polynomial Trend Surface) and with two reference images obtained using a resampling method and using a digitizing one. The experiment was conducted by applying the Spectral Temporal Response Surface (STRS) approach. Results show that the neural networks give the best results, even with a few reference data of sample. The results also present the importance of generate a high quality reference image.

Palavras-chave: crop classification, spectral-temporal analysis, artificial neural network, classificação de culturas, análise espectro-temporal, redes neurais artificiais.

1. Introdução

Imagens oriundas do sensoriamento remoto têm sido consideradas uma importante fonte de dados nos mais diversos aspectos relacionados a aplicações agrícolas, compreendendo o monitoramento e a estimativa da produção agrícola (Vieira, 2000). Para estas aplicações são necessárias informações precisas, em tempo hábil e com baixo custo, desta forma as novas tecnologias na área do sensoriamento remoto são capazes de gerar informações que podem aperfeiçoar a nível regional e nacional a estruturação de estimativas agrícolas mais eficientes. Tais informações permitem um planejamento adequado da economia agrícola em um país, podendo até contornar o problema de escassez ou de excesso de produtos.

Na produção agrícola é necessário fazer um acompanhamento periódico, visto que as culturas levam um determinado tempo para se desenvolver. O sensoriamento remoto com o uso de imagens de satélites possui caráter global, sinóptico, multiespectral e repetitivo, sendo assim uma ferramenta indispensável para acompanhar a dinâmica agrícola principalmente em países de grandes dimensões como o Brasil (Sanchez et al., 2005).

Segundo Picoli et al. (2005), no Brasil a estimativa da área plantada é realizada predominantemente de forma subjetiva, através de questionários aplicados aos produtores e/ou às entidades relacionadas à atividade agrícola, esta estimativa pode ser subestimada ou superestimada. Para contornar este problema o sensoriamento remoto, através de imagens temáticas, tem um grande potencial na sua correta estimativa.

No procedimento de reconhecimento de padrões espectrais das imagens, gera-se o mapa temático. Este processo é também conhecido como classificação, que de acordo com Lillesand e Kiefer (1999), tem como objetivo categorizar, por meio de procedimentos computacionais, todos os *pixels* de uma determinada imagem, atribuindo a cada um deles um “rótulo” que os relaciona a uma classe informacional (Mather, 1999).

Muitos algoritmos paramétricos têm sido empregados na classificação de imagens digitais provenientes de sensores remotos, entre eles o algoritmo da Máxima Verossimilhança (MaxVer). Recentemente, as redes neurais artificiais (*Artificial Neural Network* - ANN) tem sido empregadas com sucesso na classificação de imagens, pois apresentam algumas vantagens sobre os classificadores estatísticos, como por exemplo, o treinamento com um pequeno número de amostras, não ser um método paramétrico, e com grande capacidade de generalização - capacidade de reconhecer com precisão padrões que não participaram do processo de treinamento (Tso e Mather, 2001; Kavzoglu e Mather, 2003).

Segundo Vieira (2000) a maioria dos procedimentos de classificação de imagens fundamenta-se na simples investigação da característica radiométrica do *pixel* (análise multiespectral). Este procedimento assume implicitamente que a cultura possui o mesmo estágio fenológico, o que de fato não ocorre, mesmo considerando uma área homogênea, devido aos diferentes datas de plantio, diferentes tipos de solo e condições climáticas.

Outro aspecto importante está relacionado à periodicidade de aquisição de imagens com pouca cobertura de nuvens, pois nas regiões tropicais, a época chuvosa é, em geral, coincidente com o período de desenvolvimento da maioria das culturas agrícolas (Formaggio et al., 2005).

A resposta espectral das vegetações (principalmente culturas agrícolas) muda com o desenvolvimento da planta, desta forma é apropriada à utilização da análise multitemporal considerando as características espectrais das imagens de satélite. Neste contexto, o objetivo geral deste trabalho é adaptar e utilizar a metodologia da Superfície de Resposta Espectro-Temporal (STRS - *Spectral-Temporal Response Surface*) introduzida por Vieira (2000), que leva em consideração os aspectos multitemporal e multiespectral das imagens MODIS (*Moderate Resolution Imaging Spectroradiometer*) para classificar extensas áreas de culturas agrícolas, estimando-se a área plantada.

2. Caracterização da área de estudo e dados usados

A área de estudo corresponde à abrangência do Escritório de Desenvolvimento Regional (EDR) de Limeira, uma das divisões administrativas da Coordenadoria de Assistência Técnica Integral (CATI) do Estado de São Paulo (**Figura 1**), compreendendo os seguintes municípios: Porto Ferreira, Pirassununga, Analândia, Santa Cruz da Conceição, Araras, Cordeirópolis, Corumbataí, Ipeúna, Iracemápolis, Itirapina, Leme, Limeira, Rio Claro e Santa Gertrudes. Esta área situa-se a leste no Estado de São Paulo cuja área estimada chega a 497.598,3 ha.

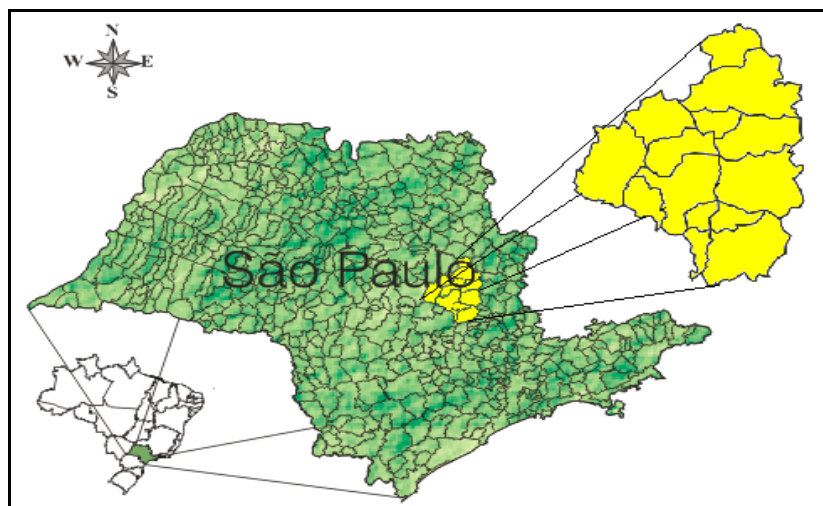


Figura 1: Localização da área de estudo.

A área está delimitada pelo seguinte retângulo envolvente (Coordenadas Geográficas):

- Canto superior direito: 22°45'33,72"S e 47°59'7,21"W;
- Canto inferior esquerdo: 21°44'47,09"S e 47°09'20,76"W.

A agricultura é a principal atividade da região, onde cultiva-se principalmente cana de açúcar, frutas cítricas, milho e soja. Outra atividade importante é a agropecuária, para a qual são destinadas áreas importantes para o desenvolvimento de pastos. Finalmente os solos nesta área têm um uso de floresta com plantações importantes de pinus e eucalipto, para industrialização da celulose (Arce, 2005).

Foram utilizadas as imagens Landsat, que ficam localizadas no encontro de duas órbitas/pontos: 220/75 e 220/76 - para a data de 08/08/2004, para derivar a imagem de referência. No processo de registro dessas imagens foram usadas imagens ortorretificadas disponibilizadas pela NASA do sensor ETM+ do satélite Landsat-7 do ano 2000.

A área teste refere-se a um recorte de imagens MODIS. Para Zhan et al. (2002), este sensor é um radiômetro-imageador com cobertura diária em resoluções espaciais de 250, 500 e 1000 m, contando com 36 bandas espectrais que se estendem do visível ao infravermelho termal. MODIS fornece uma alta resolução radiométrica (16 bits), com uma excelente resposta para cada banda. Dados MODIS já vêm corrigidos dos efeitos atmosféricos e georreferenciados.

Estes dados são disponibilizados na forma de produtos, para esta pesquisa utilizou-se o produto MOD13, com as respectivas bandas: azul, vermelho, infravermelho próximo (NIR), além de uma banda localizada na faixa do infravermelho médio (MIR). As bandas do vermelho e NIR possuem resolução de 250m, as outras duas bandas foram reamostradas de 500m para 250m. Na análise multitemporal foram utilizadas 15 imagens (**Tabela 1**), com 424x309 *pixels*, todas convertidas para 8 Bits.

Tabela 1: Imagens MODIS.

Data	Dia Juliano	Data	Dia Juliano	Data	Dia Juliano
01/01/2004	001	21/03/2004	081	09/06/2004	161
17/01/2004	017	06/04/2004	097	25/06/2004	177
02/02/2004	033	22/04/2004	113	11/07/2004	193
18/02/2004	049	08/05/2004	129	27/07/2004	209
05/03/2004	065	24/05/2004	145	12/08/2004	225

3. Análise Multitemporal

Uma única imagem de satélite pode não fornecer informações espectrais suficientes para permitir identificar todas as culturas plantadas ou até uma mesma cultura em diferentes estágios fenológicos. Entretanto, imagens multitemporais podem fornecer maiores informações sobre a área plantada e indicações sobre o crescimento e desenvolvimento de culturas, os quais podem ser elementos chaves na discriminação espectral de diferentes culturas (Apan e Potgieter, 2002). Vieira (2000) propôs uma metodologia que explora o uso da STRS, para caracterizar o comportamento de cada *pixel* em relação ao tempo de aquisição das imagens e comprimento de onda usados.

Na metodologia STRS cada *pixel* é representado como um ponto no espaço tridimensional onde os eixos X, Y e Z representam tempo, comprimento de onda e reflectância, respectivamente. Tendo essa representação tridimensional, uma superfície analítica é interpolada por esses pontos (pontos de controle), os quais podem ser irregularmente espaçados. Os pontos de controle são extraídos com o auxílio da imagem de referência. Para interpolar essas superfícies podem ser utilizados dois métodos de interpolação: o *Polinomial Trend Surface* (PTS) e o *Collocation*. O método interpolador PTS, normalmente interpola os

pontos de controle extraíndo a tendência da superfície, enquanto que o método *collocation*, tenta ajustar completamente a superfície aos pontos de controle.

Uma vez interpoladas essas superfícies (representando as culturas agrícolas) o processo de classificação fica reduzido à comparação da forma dessas superfícies, ou seja, superfícies com as mesmas formas, pertencem ao mesmo tipo de cultura agrícola.

Considerando que os coeficientes das equações, definem a forma das superfícies interpoladas, eles podem ser também usados para extrair os parâmetros das superfícies analíticas. Após essa parametrização das superfícies, os coeficientes podem ser usados como o vetor de entrada para o processo de classificação supervisionada.

4. Metodologia

4.1. Imagens de Referência

Uma das questões básicas que limitam o uso de imagens de satélite no monitoramento de culturas agrícolas é o período de aquisição, devido à interferência de nuvens. Com as características dos sensores atualmente em uso, há um conflito entre uma redução expressiva na resolução espacial em favor da ampliação da resolução temporal. Assim sendo, coexistem sensores de alta resolução espacial, como o ETM+ do Landsat 7 (30 m x 30 m) e baixa frequência de aquisição com sensores de baixa resolução espacial como o MODIS e alta frequência de re-visita. Devido à baixa resolução espacial das imagens MODIS, foram adquiridas as imagens de referência a partir de imagens Landsat.

Duas imagens de referência foram utilizadas. A primeira gerada a partir da imagem temática de Limeira (cedida pelo INPE) com resolução de 30m. Adotou-se o seguinte procedimento:

- reamostragem: 30 m para 250 m;
- filtro mediana 3 x 3;
- remoção de classes informacionais com menos de 1000 *pixels*.

Gerou-se uma imagem de referência com 7 classes informacionais, com as respectivas proporções dispostas na **Tabela 2**. A segunda imagem de referência foi gerada a partir de amostras coletadas digitalizando-se polígonos aleatoriamente sobre as classes de interesse na imagem, sempre buscando capturar amostras mais homogêneas para representar o máximo possível as características de cada classe informacional (**Tabela 2**). As imagens de referência foram rotuladas distintamente para fins de comparação das metodologias empregadas na sua obtenção como Reamostragem para a imagem de referência 1 e como Digitalização em tela para a imagem de referência 2.

Tabela 2: Classes da imagem de referência.

Classes	Imagem de Referência 1		Imagem de Referência 2	
	<i>Pixels</i>	Percentual (%)	<i>Pixels</i>	Percentual (%)
Mata	5167	7.01	824	17.70
Cana-de-açúcar	28327	38.45	1651	35.4
Milho	4406	5.98	288	6.20
Soja	3044	4.13	318	6.80
Cítrus	9365	12.71	836	18.00
Pasto	22261	30.22	410	8.80
Eucalipto	1102	1.50	329	7.10
Total	73672	100	4656	100

4.2. Classificação

Para o processo de classificação multitemporal, foram selecionadas amostras aleatórias para o treinamento e validação dos classificadores MaxVer e ANN. Cada amostra possui:

- Imagem de Referência 1: 99 *pixels*/classe para o treinamento e 33 *pixels*/classe para a validação (total 924 *pixels*);
- Imagem de Referência 2: 96 *pixels*/classe para o treinamento e 32 *pixels*/classe para a validação (total 896 *pixels*);

As imagens foram adquiridas em 15 diferentes datas (**Tabela 1**) expressas em dias Juliano (eixo x) e a componente espectral foi caracterizada pelo valor médio do comprimento de onda (eixo y). Desta forma as quatro bandas do sensor MODIS azul (0,459 - 0,479 μm), vermelho (0,620 - 0,670 μm), NIR (0,841 - 0,876 μm) e MIR (1,628 - 1,652 μm), foram representadas 0,469; 0,650; 0,859; 1,640 μm , respectivamente. A propriedade radiométrica foi expressa em reflectância (eixo z).

Foi gerado para cada *pixel*, 60 pontos de controle tridimensionalmente (15 imagens MODIS com quatro bandas espectrais). Antes da fase de interpolação das superfícies, estes pontos de controle foram re-escalados para o intervalo [0, 1], para os três eixos.

Para o interpolador PTS foram utilizados 60 pontos de controle para ajustar a superfície empregando uma função polinomial do terceiro grau (10 coeficientes), considerando as restrições matemáticas no processo de interpolação.

Os mesmos pontos de controle foram utilizados para ajustar a superfície usando o interpolador *Collocation*, gerando-se assim 60 coeficientes. Para ambos interpoladores, os coeficientes foram re-escalados novamente para o intervalo [0, 1], para utilização nas fases de treinamento e teste dos classificadores.

O modelo de arquitetura ANN utilizado foi o *feed-forward*, com múltiplas camadas, com o algoritmo de treinamento para aprendizagem supervisionada *backpropagation*.

Utilizou-se o simulador de redes neurais “*Java Neural Network Simulator*”, desenvolvido pelo Instituto Wilhem-Schickard para Ciência da Computação (WSI) em Tübingen, Alemanha. Este simulador é baseado no *Stuttgart Neural Network Simulator 4.2* (Zell et al., 1996), com uma nova interface gráfica.

Na etapa de treinamento e validação diferentes arquiteturas foram testadas: variando o nº de neurônios na camada de entrada (10 coeficientes para o PTS e 60 coeficientes para o *Collocation*); variando o nº de neurônios na camada interna e/ou nº de camadas internas; e todas tendo o mesmo nº de neurônios na camada de saída (7 classes informacionais).

Os resultados obtidos com a aplicação do método STSR foram submetidos a procedimentos de avaliação estatística com o intuito de verificar a precisão da classificação. Para tanto, gerou-se uma matriz de confusão, a partir de uma amostragem independente, com os coeficientes de exatidão global, Kappa e variância do Kappa, para cada classificador e ambos interpoladores. O coeficiente Kappa é a medida de como a classificação coincide com a imagem de referência (Congalton e Green, 1999). Os classificadores (ANN e MaxVer) foram comparados para verificar se existem diferenças estatisticamente significantes entre os classificadores. Formulações para o cálculo dessas medidas estatísticas podem ser encontrados em Congalton e Green (1999).

5. Resultados e Discussão

Todas as classificações geradas foram comparadas usando os índices kappa e de exatidão global, para cada interpolador e com os classificadores MaxVer e ANN. Observando-se a **Tabela 3**, verifica-se que a melhor classificação (Kappa = 0,583) foi obtida utilizando-se a digitalização em tela (D), com o classificador ANN e interpolador *collocation*, e a pior

classificação obtida ($Kappa = 0,197$) foi a configuração usando a reamostragem (R), com o classificador MaxVer e o interpolador *Collocation*. Consequentemente, esse resultado evidencia a importância da escolha de polígonos mais homogêneos, quando da geração da imagem de referência, como também confirma a deficiência do método MaxVer em gerar os parâmetros adequados durante a fase de treinamento, quando há limitação no tamanho das amostras de treinamento.

Na classificação pelo MaxVer, obteve-se melhores índices kappa e de exatidão global para o interpolador PTS, tanto na metodologia de reamostragem quanto na metodologia de digitalização de polígonos em tela, em relação ao interpolador *Collocation* (**Tabela 3**). A superioridade verificada pelo MaxVer utilizando o interpolador PTS deve-se ao fato de haverem menos coeficientes utilizados como variáveis discriminantes no processo de classificação. Portanto, há que se ter muito cuidado quando o número de amostras for consideravelmente reduzido em relação ao número de variáveis discriminatórias.

Notou-se um melhor desempenho do classificador ANN usando o interpolador *Collocation* em relação ao PTS, provavelmente devido às características não-paramétricas desse classificador. Uma das vantagens da ANN é justamente a possibilidade de se obter um bom resultado com poucas amostras de treinamento. Uma característica importante no desempenho deste classificador é a definição da arquitetura da rede. Redes menores generalizam melhor, o que surpreendentemente não foi verificado nesses experimentos.

Tabela 3: Índices derivados das matrizes de confusão.

Metodologia		Reamostragem (R)			Digitalização em tela (D)		
Classificador	Interpolador	Global(%)	Kappa	Var	Global(%)	Kappa	Var
MaxVer	PTS	45,5	0,354	0,00133	63,8	0,578	0,00134
	<i>Collocation</i>	31,2	0,197	0,00120	42,0	0,323	0,00129
ANN	PTS	52,2	0,443	0,00150	51,1	0,429	0,00138
	<i>Collocation</i>	52,8	0,449	0,00145	64,3	0,583	0,00139

Uma vez que o coeficiente Kappa quantifica o desempenho do classificador em relação à imagem de referência, foi empregado para avaliar os interpoladores (*Collocation* e PTS) e as metodologias de obtenção da imagem de referência (Reamostragem e Digitalização em tela). Tal comparação pôde ser feita através da elaboração de uma matriz de significância para os classificadores a um nível de confiança de 95% (valor crítico de Z igual a 1,96) com os coeficientes de exatidão global e Kappa, variando o interpolador (**Tabela 4**). Os valores da diagonal principal da matriz de significância representam a precisão do classificador comparado a uma classificação aleatória, enquanto os valores de fora da diagonal representam o desempenho relativo entre os classificadores (Vieira, 2000). Os valores em negrito indicam que não há diferença estatística significativa entre os classificadores, os outros valores representam a superioridade ou inferioridade relativas entre cada par de classificador.

Analisando a Tabela 4, a melhor performance do índice Kappa foi obtida pelo interpolador *Collocation*, utilizando o classificador ANN e a partir da imagem de referência por digitalização em tela, como descrito anteriormente. Ao interpolar as superfícies o *Collocation* possui mais variáveis discriminantes em comparação com PTS, deste modo utilizando o classificador ANN foram obtidos melhores resultados. Utilizando o classificador MaxVer, foi verificado um pior desempenho utilizando o *Collocation*, representando que esses coeficientes possivelmente não seguem a distribuição normal ou as amostras de treinamento não são suficientes para gerar os parâmetros satisfatoriamente para esse classificador obter uma razoável exatidão.

Tabela 4: Avaliação do desempenho dos classificadores por interpolador e por metodologia de obtenção da imagem de referência através dos resultados dos coeficientes Kappa, onde: C (*Collocation*), P (PTS), A (ANN), M (MaxVer), R (Reamostragem) e D (Digitalização em tela) a um nível de confiança de 95% ($Z = 1,96$).

CLASS	CAD	PMD	CAR	PAD	PAR	PMR	CMD	CMR
KAPPA	0,583	0,578	0,449	0,443	0,429	0,364	0,323	0,197
VAR	0,00139	0,00134	0,00145	0,00150	0,00138	0,00133	0,00129	0,00120
CAD	15,654							
PMD	0,096	15,802						
CAR	2,517	2,444	11,799					
PAD	2,606	2,535	0,111	11,446				
PAR	2,928	2,858	0,376	0,261	11,548			
PMR	4,202	4,144	1,613	1,486	1,249	9,985		
CMD	5,027	4,976	2,409	2,273	2,052	0,801	9,000	
CMR	7,583	7,557	4,893	4,733	4,564	3,318	2,524	5,677

Legenda: Indica haver diferença estatística significativa entre os classificadores ($>1,96$).

6. Conclusão

Uma metodologia que leva em consideração os aspectos multitemporal e multiespectral das imagens MODIS (*Moderate Resolution Imaging Spectroradiometer*) foi utilizada para classificar com sucesso extensas áreas de culturas agrícolas numa região de Limeira.

A análise dos resultados permite concluir que a metodologia de digitalização de polígonos homogêneos em tela apresentou melhor desempenho na classificação do que a metodologia de reamostragem das imagens temáticas (ETM 7) reamostradas de 30 para 250 metros, tanto para os dados interpolados pelo método *Collocation* quanto pelo método PTS e para ambos classificadores MaxVer e ANN. O classificador ANN utilizando o interpolador *Collocation* apresentou o melhor desempenho, seguido pelo classificador MaxVer utilizando o interpolador PTS. Ambas as classificações não apresentaram diferenças significativas ao nível de 95% de confiança. O classificador ANN no geral apresentou grande eficiência, proporcionando melhores resultados mesmo com uma pequena quantidade de dados de amostra para treinamento.

Considerando as dificuldades para obter um número significativo de amostras para treinamento e validação, sugere-se a repetição desses experimentos para uma amostragem compatível com o número de variáveis discriminantes (30 x número de coeficientes x número de classes informacionais).

Referências

- Apan, A.; Potgieter, A. **Using satellite imagery in determining winter crop area planted in support of regional commodity forecasting: a case study of the Darling Downs, Queensland**. Toowoomba, Australia: Faculty of Engineering and Surveying, University of Southern Queensland, 2002. 31 p. Disponível em: <http://www.usq.edu.au/users/apana/cropforecasting_finalreport.pdf>. Acesso: 20 jan. 2006.
- Arce, E. C.; Rudorff, B. F. T.; Berka, L. M. S.; Pereira, P. F. C. Imágenes Landsat y CBERS en la identificación del uso del suelo con cultivos agrícolas. In: Simpósio Brasileiro de Sensoriamento Remoto, (SBSR), 12., 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. Artigos, p. 41-48. CD-ROM, On-line. ISBN 85-17-00018-8. Disponível em: <<http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.19.18.12/doc/Ervin.pdf>>. Acesso em: 12 jul 2005.
- Congalton, R. G.; and Green, K. **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**. New York: Lewis Publishers, 1999.
- Formaggio, A. R.; Martins, S. P.; Gurtler, S.; Campos, R. C.; Fiorio, P. R.; Lemos, C. Avaliação de dados MODIS 250m para áreas de agricultura intensa. In: Simpósio Brasileiro de Sensoriamento Remoto, (SBSR), 12., 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. Artigos, p. 135-142. CD-ROM, On-line. ISBN 85-17-00018-8. Disponível em: <<http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.25.18.14/doc/135.pdf>>. Acesso em: 20 nov. 2005.
- Kavzoglu, T.; Mather, P.M. The use of backpropagation artificial neural networks in land cover classification. **International Journal of Remote Sensing**, v.24, n.13, p. 4907-4938, 2003.
- Lillesand, T. M.; Kiefer, R. W. **Remote sensing and image interpretation**. 4 Ed. New York: John Wiley & Sons, 724 p, 1999.
- Mather, P. M. **Computer processing of remotely-sensed images: An introduction**. 2 Ed. Chichester: John Wiley & Sons, 292 p, 1999.
- Picoli, M. C. A.; Anjos, C. S.; Rosa, V. G. C.; Rizzi, R.; Rudorff, B. F. Estimativa de área com cana-de-açúcar na micro-região de Ribeirão Preto - SP por meio de amostragem por segmentos quadrados. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 12., 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. Artigos, p. 213-215. CD-ROM, On-line. ISBN 85-17-00018-8. Disponível em: <<http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.22.09.20/doc/213.pdf>>. Acesso em: 15 out. 2006.
- Sanches, I. D. A.; Epiphânio, J. C.; Formaggio A. R. Culturas Agrícolas em Imagens Multitemporais do Satélite Landsat. **Agricultura em São Paulo**. v.52, n.1, p.83-96. 2005.
- Tso, B.; Mather, P. M. Crop discrimination using multi-temporal SAR imagery. **International Journal of Remote Sensing**, vol. 20, no. 12, 2443-2460, 1999.
- Vieira, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. 327p. Thesis (Doctor of Philosophy) – University of Nottingham, Nottingham. 2000.
- Zhan, X.; Sohlberg, R. A.; Townshend, J. R. G.; DiMiceli, C.; Carroll M. L.; Eastman, J. C.; Hansen, M. C.; DeFries, R. S. Detection of land cover changes using MODIS 250 m data. **Remote Sensing of Environment**, v. 83, p. 336-350, 2002.
- Zell, A.; Mamier, G.; Vogt, M.; Mache, N.; Hubner, R.; Doring, S.; Herrmann, K.; Soyoz, T.; Schmalzl, M.; Sommer, T.; Hatzigeorgiou, A.; Posselt, D.; Schreiner, T.; Kett, B.; Clemente, G.; Wieland, J.; Gatter, J. **Stuttgart Neural Network Simulator v4.2**. University of Stuttgart: Institute for Parallel and Distributed High Performance Systems/University of Tübingen - Wilhelm-Schickard-Institute for Computer Science - Department of Computer Architecture. 1996.