

Aplicação de lógica *fuzzy* para estimativa de área plantada da cultura de soja utilizando imagens AVHRR-NOAA

João Francisco Gonçalves Antunes ¹
Jurandir Zullo Júnior ²

¹Embrapa Informática Agropecuária
Caixa Postal 6041 - 13083-886 - Campinas - SP, Brasil
joaof@cnpia.embrapa.br

²Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura
CEPAGRI/UNICAMP
Cidade Universitária “Zeferino Vaz” - 13083-970 - Campinas - SP, Brasil
jurandir@cpa.unicamp.br

Abstract. An early accurate estimation of soybean crop areas is fundamental for the Brazilian economy. Recent technological progress of data acquisition from remote sensing makes possible to improve harvest forecast, reducing the subjectivity. The AVHRR-NOAA images of high temporal resolution, have been used for the crop monitoring. However, its low spatial resolution might cause the spectral mixture within the same pixel. The objective of the work is to develop an automatic classification methodology based on fuzzy logic using AVHRR-NOAA vegetation indices to estimate the soybean crop areas at sub-pixel level. For eight counties in the West region of the Paraná State, it was possible to obtain the crop area estimation prior to the harvest, on the contrary of the official surveys that extend until the end of the harvest, besides using subjective data. The soybean crop area estimation based on fuzzy classification showed to be highly correlated with the official and reference area estimations obtained by direct expansion, with good accuracy and the level of relative error acceptable.

Palavras-chave: harvest forecast, remote sensing, image classification, previsão de safra, sensoriamento remoto, classificação de imagens.

1. Introdução

A soja vem se consolidando como a principal cultura do agronegócio brasileiro, assumindo grande importância econômica nas exportações. O Paraná é o segundo maior produtor com 10,03 milhões de toneladas e área plantada estimada em 3,5 milhões de hectares, atrás apenas do Mato Grosso, dados referentes a safra 2003/2004 (CONAB, 2004).

A estimativa de área plantada é de fundamental importância para a previsão de safras. No Brasil é realizada por métodos subjetivos de coleta de informações por meio de questionários aplicados junto ao setor agrícola e, por isso, possuem um custo elevado, execução demorada e estão sujeitos a imprecisões (Fontana et al., 2000).

As imagens do satélite meteorológico AVHRR-NOAA de elevada repetitividade temporal, com garantia de cobertura diária e de aquisição gratuita, têm sido utilizadas no monitoramento agrícola realizado através da avaliação dos índices de vegetação que descrevem a variação do vigor vegetativo de uma cultura ao longo do seu ciclo de desenvolvimento (Liu e Kogan, 2002).

Porém, a baixa resolução espacial dessas imagens faz com que possa ocorrer a mistura espectral das classes de cobertura do solo dentro de um mesmo pixel e isso pode acarretar problemas de imprecisão na estimativa de área plantada de uma cultura agrícola. A aplicação de técnicas como a lógica *fuzzy* (Zadeh, 1965) é bastante promissora para a solução da mistura espectral a partir da classificação automática de imagens de satélites, pois permite a análise sub-pixel para estimar as proporções de cada superfície dentro dos pixels (Foody, 1998).

Nesse contexto, o objetivo do trabalho é desenvolver uma metodologia de classificação automática baseada em lógica *fuzzy* utilizando índices de vegetação de imagens AVHRR-NOAA para estimar a área plantada de soja no nível sub-pixel.

2. Material e Métodos

A área de estudo é compreendida por oito municípios da região oeste do Paraná que corresponde a mais de 25% do total da área plantada de soja no Estado, na safra 2003/2004. Os municípios monitorados são cobertos pela cena Landsat 5/TM, órbita/ponto 223/77, a ser utilizada na determinação das áreas com plantios de soja, conforme ilustrado pela **Figura 1**.

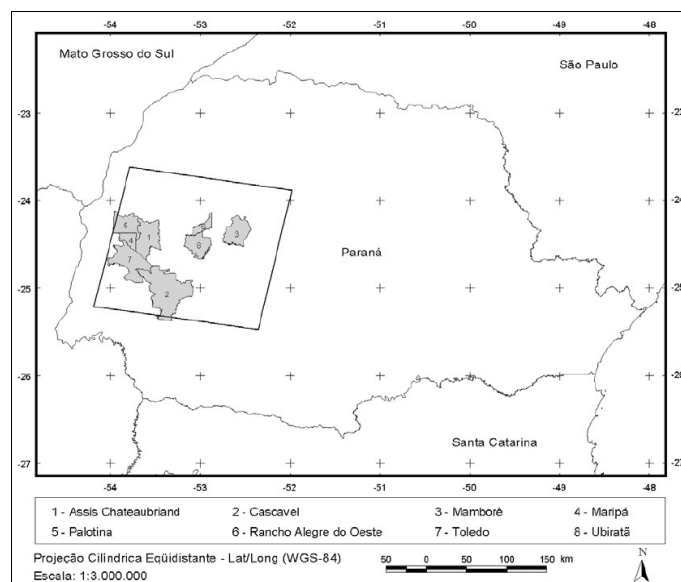


Figura 1: Oito municípios do oeste do Paraná cobertos pela cena Landsat 5/TM, 223/77.

Para determinar as áreas de referência de soja foram utilizadas seis imagens Landsat 5/TM, adquiridas em 21/11/2003, 07/12/2003, 23/12/2003, 24/01/2004, 09/02/2004 e 25/02/2004, de forma a abranger todo o ciclo de desenvolvimento da cultura na região. Ganan et al. (2005) procederam a classificação dessas imagens pelos métodos Paralelepípedo e Máxima Verossimilhança dando origem ao que foi denominado “máscara de soja”.

Segundo Epiphanyo et al. (2002), uma estimativa de área pode ser obtida utilizando-se os dados coletados em imagens de satélite ou por levantamento de campo a partir de um painel amostral, a respeito das diferentes coberturas vegetais para os pontos amostrais de referência terrestre, permitindo rápida avaliação da área de uma classe de uso do solo. A proporção com que uma classe ocorre na amostra passa a equivaler à proporção de área amostral ocupada por essa classe. Então, pressupõe-se que a mesma proporção dos pontos da classe encontrada no painel amostral vá se reproduzir na área total do município, numa expansão direta.

De forma resumida, a estimativa por expansão direta baseada na máscara de soja consiste na multiplicação da proporção de pontos identificados como soja a partir da referência terrestre pela área municipal, calculada pela Equação (1):

$$A_{\text{Soja}} = (p_{\text{Soja}} / p_m) * A_m \quad (1)$$

onde,

A_{Soja} = área estimada da cultura de soja no município (ha);

p_{Soja} = número de pontos amostrais identificados como soja no município;

p_m = número total de pontos amostrais no município, igual a 100 pontos neste estudo;

A_m = área total do município (ha).

As imagens AVHRR-NOAA foram obtidas do acervo histórico do Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura (CEPAGRI) da Universidade Estadual de Campinas (UNICAMP). Foram utilizadas imagens diurnas do satélite NOAA-17 com

passagem próxima às 13h30 GMT, em seu estado bruto. As datas de aquisição das imagens englobaram a época do ciclo de desenvolvimento da soja na região em estudo, desde o início do plantio em novembro de 2003 até ao final da colheita em março 2004.

Para o processamento das imagens AVHRR-NOAA foi utilizado o sistema desenvolvido por Esquerdo et al. (2006), compatível com a plataforma Linux, que consiste de um procedimento automático em script *c-shell* composto por um conjunto de comandos que acionam os módulos para conversão do formato bruto, calibração radiométrica, georreferenciamento preciso e geração de produtos.

A **Figura 2** ilustra o fluxograma resumido com as principais etapas do processamento das imagens. A primeira parte do sistema é composta por um conjunto de comandos que executam os programas do pacote NAV (*NAVigation*), desenvolvido pelo Colorado Center for Astrodynamics Research (CCAR) da Universidade do Colorado, Boulder, EUA.

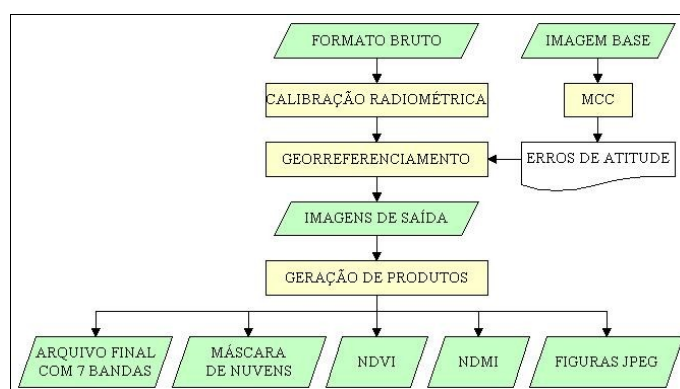


Figura 2: Fluxograma do sistema de processamento das imagens AVHRR-NOAA.

O processo inicia-se com a conversão do formato bruto para um formato compatível com os módulos subsequentes. Após isso é feita a calibração radiométrica das imagens, transformando os valores de nível de cinza para reflectância aparente (no topo da atmosfera) para as bandas 1, 2 e 3A e temperatura de brilho, para as bandas 3B, 4 e 5, seguindo as metodologias descritas por Rao e Chen (1996) e Goodrum et al. (2004).

Em seguida é executado o módulo de georreferenciamento das imagens, segundo a metodologia de navegação indireta descrita por Rosborough et al. (1994) que baseia-se no fato de que a maior fonte de erros de deslocamentos no processo é devida à imprecisão no ângulo dos três eixos de atitude do satélite no momento de sua passagem. Tais erros são determinados por meio de dois pontos de controle coletados a partir de malhas digitais ou imagens geometricamente precisas. Após isso, a imagem é georreferenciada novamente considerando-se os erros de atitude, garantindo a precisão geométrica dentro de um pixel.

Para automatizar o processo de coleta de pontos de controle, o módulo utiliza a técnica da Máxima Correlação Cruzada (MCC) de Emery et al. (2003) que busca feições entre a imagem alvo que se pretende corrigir e uma imagem base, cartograficamente precisa. Uma vez reconhecidas as feições semelhantes entre essas imagens, o programa coleta automaticamente os pontos de controle, que por sua vez são utilizados pelo módulo para determinar os erros de atitude e realizar a navegação indireta, gerando imagens com erro de georreferenciamento dentro de um pixel.

Como resultado deste processo obtêm-se cinco arquivos referentes as bandas espectrais calibradas e corrigidas geometricamente, contendo somente a região de interesse, previamente informada na navegação indireta. Neste trabalho, a região monitorada foi o Paraná, centrada nas coordenadas geográficas 24°30' S e 51°20' W, gerando-se imagens com 750 colunas e 512 linhas. Também são gerados mais dois arquivos com o ângulo de elevação do satélite e o ângulo zenital solar para cada pixel da imagem, totalizando sete arquivos.

A segunda parte do sistema foi desenvolvida em linguagem IDL (*Interactive Data Language*) do software ENVI (*The Environment for Visualizing Images*) que é responsável pela leitura dos sete arquivos produzidos e pela geração de produtos.

O primeiro produto é um arquivo contendo sete bandas, reunindo as sete imagens geradas num único arquivo. O segundo produto é um arquivo contendo a máscara de nuvens e dois índices de vegetação.

A máscara de nuvens foi gerada seguindo os critérios descritos por França e Cracknell (1995) e Chen et al. (2002) como forma de evitar a contaminação da análise espectral, levando-se em consideração as características da região do Pantanal.

O primeiro índice de vegetação é o NDVI (*Normalized Difference Vegetation Index*) - razão de bandas do infravermelho próximo e do vermelho - que pode ser utilizado na avaliação das mudanças do vigor vegetal das plantas (Rouse et al., 1973).

O segundo índice de vegetação é o NDMI (*Normalized Difference Moisture Index*) - razão de bandas do infravermelho próximo e infravermelho médio - que é mais sensível à água obtendo um maior contraste entre diferentes tipos de vegetação (Wilson e Sader, 2002).

Também são geradas figuras JPEG de uma composição colorida RGB-321, bem como para todos os produtos do sistema, sobrepostas com uma malha política do Instituto Brasileiro de Geografia e Estatística (IBGE) e com informações cartográficas.

Uma última rotina gera automaticamente composições de máximo valor dos índices de vegetação durante um determinado período, como forma de atenuar os efeitos atmosféricos numa análise multitemporal (Holben, 1986).

Para proceder a classificação não-supervisionada *fuzzy* das composições máximas de AVHRR-NOAA de NDVI e NDMI foi adaptado o programa em IDL/ENVI desenvolvido por Canty (2005) que combina o método de agrupamento por partição *fuzzy* K-means (FKM), proposto por Bezdek et al. (1984), com a medida de similaridade adaptativa conhecida como *Expectation Maximization* (EM), definida por Gath e Geva (1989).

O algoritmo trabalha a partir de um procedimento iterativo onde os pixels da imagem, inicialmente em posição aleatória, são classificados em classes de uso do solo. Dado o número de grupos desejados são calculados os centros de cada grupo com base na média dos atributos dos pontos. Num próximo passo os pontos são realocados entre os grupos de acordo com a similaridade entre eles. Ao final, o algoritmo EM gera um conjunto de imagens fração, uma para cada classe, com os graus de pertinência dos pixels medidos entre zero e um, escalonados no intervalo de zero a 255. Dessa forma, os pixels com graus de pertinência próximos a um aparecem em branco e os próximos a zero em preto, variando em tons de cinza (Duda e Canty, 2002).

As imagens fração geradas pelo algoritmo de classificação *fuzzy* permitem estimar as proporções de cobertura do solo misturadas dentro de cada pixel. As proporções de área de cada classe de uso do solo são contínuas variando num intervalo de 0% a 100%. Baseado nisso, identificando-se a imagem fração correspondente a classe Soja, pode-se estimar a proporção de área a partir dos graus de pertinência dos pixels e, conseqüentemente, a área plantada de soja em cada município, conforme a Equação (1).

$$A_{\text{Soja}} = A_{\text{pixel}} * \left(\frac{\sum_{i=1}^n \mu_{ci}}{255} \right) * 100 \quad (1)$$

onde,

A_{Soja} = área de soja em hectares (ha);

A_{pixel} = área do pixel AVHRR-NOAA igual a 1,21 km² (1,1 x 1,1 km);

μ_{ci} = graus de pertinência dos pixels da imagem fração referente a classe c, no caso, Soja.

3. Resultados e Discussões

A estimativa da área de soja de cada um dos oito municípios por expansão direta foi calculada a partir dos 100 pontos de referência terrestre do painel amostral da Companhia Nacional de Abastecimento (CONAB), coletados na máscara de soja, com base na área total do município obtida do IBGE, conforme apresentado na **Tabela 1**.

Tabela 1: Área de soja estimada por expansão direta.

Município	Pontos de Soja	Área Municipal IBGE (ha)	Área de Soja por Expansão Direta (ha)
Assis Chateaubriand	73	97.000,00	70.810,00
Cascavel	37	210.000,00	77.700,00
Mamborê	74	77.900,00	57.646,00
Maripá	42	28.400,00	11.928,00
Palotina	54	65.100,00	35.154,00
Rancho Alegre do Oeste	86	24.100,00	20.726,00
Toledo	58	119.700,00	69.426,00
Ubiratã	76	65.300,00	49.628,00

Das 75 imagens AVHRR-NOAA processadas de outubro de 2003 a março de 2004, 55 deram origem a produtos com precisão geométrica dentro de um pixel, com erro médio de deslocamento de 0,76 pixel. Nas imagens em que o processamento falhou observou-se uma grande presença de nuvens na região em estudo durante o período analisado, prejudicando o processo de busca automática por feições geográficas realizada pelo sistema.

As composições máximas dos índices de vegetação foram geradas em períodos quinzenais para se obter uma boa atenuação dos efeitos atmosféricos. A análise do perfis espectrais temporais do NDVI e NDMI mostraram que o período de maior vigor vegetativo da soja nos oito municípios ocorreu de 15 a 31 de janeiro de 2004, exemplificado pela composição máxima de NDVI da **Figura 3**. Logo, essa é a época em que a planta teve o maior índice de área foliar e assim estava cobrindo a maior área de superfície do solo. Portanto, foi nesse momento em que a classificação *fuzzy* deveria ser executada para estimar a área plantada da cultura. A partir da identificação da imagem fração da classe Soja com base no resultado da classificação *fuzzy*, conforme mostrado na **Figura 4**, foi obtida a proporção de soja em cada pixel a partir dos graus de pertinência.

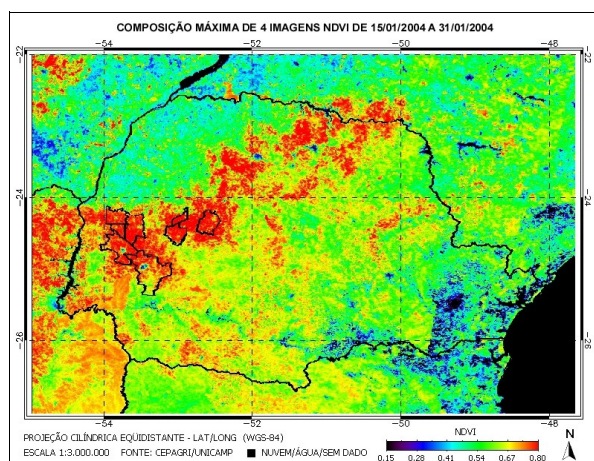


Figura 3: Composição Máxima de NDVI.

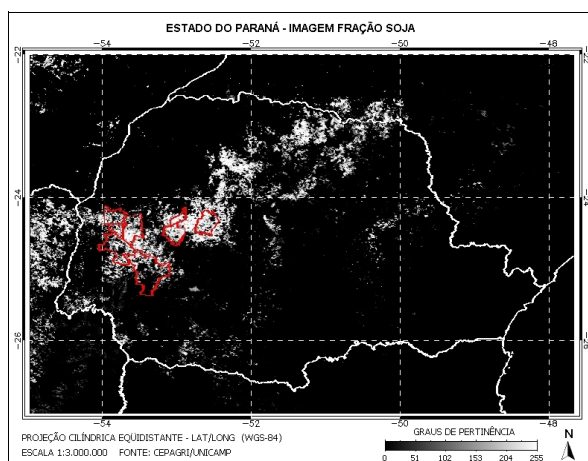


Figura 4: Imagem fração da classe Soja.

A **Tabela 2** apresenta a estimativa de área de soja oficial realizada pela Secretaria da Agricultura e Abastecimento do Paraná/Departamento de Economia Rural (SEAB/DERAL, 2005), a obtida por expansão direta e, por último, a baseada em classificação *fuzzy* que utilizou índices de vegetação de imagens AVHRR-NOAA, dos oito municípios da região oeste do Paraná, referente a safra 2003/2004.

Tabela 2: Estimativas de área de soja.

Município	Área de Soja (ha)		
	SEAB/DERAL	Expansão Direta	Classificação <i>fuzzy</i>
Assis Chateaubriand	72.000,00	70.810,00	74.500,41
Cascavel	82.000,00	77.700,00	82.793,00
Mamborê	54.000,00	57.646,00	57.512,01
Maripá	21.500,00	11.928,00	18.553,24
Palotina	43.300,00	35.154,00	37.680,35
Rancho Alegre do Oeste	15.400,00	20.726,00	20.620,44
Toledo	68.600,00	69.426,00	69.253,47
Ubiratã	51.200,00	49.628,00	47.525,15

O coeficiente de correlação estatística representa o resultado da comparação pareada das estimativas de área de soja e o *p-value* o nível de significância. O erro relativo pode ser utilizado para medir a precisão entre duas estimativas e é calculado pela subtração da segunda e a primeira, dividindo-se pelo valor da primeira estimativa, multiplicado por 100 para ser expresso em porcentagem. A **Tabela 3** apresenta os valores de correlação com seu respectivo *p-value* e o erro relativo na comparação duas a duas entre as estimativas de área de soja.

Tabela 3: Correlação e erro relativo entre as estimativas de área de soja.

Município	Erro Relativo (%)		
	SEAB	SEAB	ED
	x ED	x <i>Fuzzy</i>	x <i>Fuzzy</i>
Assis Chateaubriand	-1,65	3,47	5,21
Cascavel	-5,24	0,97	6,55
Mamborê	6,75	6,50	-0,23
Maripá	-44,52	-13,71	55,54
Palotina	-18,81	-12,98	7,19
Rancho Alegre do Oeste	34,58	33,90	-0,51
Toledo	1,20	0,95	-0,25
Ubiratã	-3,07	-7,18	-4,24
Correlação	0,976	0,988	0,992
<i>P-value</i>	0,000	0,000	0,000

Os valores do coeficiente de correlação entre as estimativas de área de soja foram extremamente altos, superiores a 0,975. Como o *p-value* foi menor que 0,05, a associação entre as estimativas foi considerada estatisticamente significativa, com um nível de confiança de 95%. Isso indica que as estimativas são fortemente correlacionadas e possuem a mesma tendência, movendo-se em perfeita proporção na mesma direção.

Como a análise foi realizada de forma pareada entre duas estimativas de área, então o erro relativo é equivalente ao coeficiente de variação. Baseado nisso, para avaliação dos resultados das comparações foi adotada a classificação de Pimentel-Gomes (2000), em que o erro

relativo é considerado baixo quando for menor que 10%, médio de 10% a 20%, alto de 20% a 30% e muito alto quando for maior que 30%.

A estimativa de área de soja de referência por expansão direta obtida para os municípios de Maripá e Palotina subestimou a estimativa oficial em torno de 44% e 19%, respectivamente. Já para o município de Rancho Alegre do Oeste, a estimativa de área superestimou por volta de 34% a estimativa oficial. Para os demais municípios o erro relativo foi baixo, sendo o menor de 1,20% para o município de Toledo.

As estimativas de área de soja baseada em classificação *fuzzy* para os municípios de Maripá e Palotina subestimaram a estimativa oficial em torno de 13%. A estimativa do município de Rancho Alegre do Oeste superestimou em torno de 34% a estimativa oficial. Para os outros municípios, o erro relativo foi baixo, sendo que o menor foi de 0,95% para o município de Toledo.

Na comparação com as estimativas de área de soja de referência por expansão direta, a estimativa de área baseada em classificação *fuzzy* obtida para o município de Maripá foi superestimada em torno de 55%. Para os demais municípios o erro relativo também foi baixo, sendo que o menor foi de -0,23% para o município de Mamborê.

A estimativa de área de soja baseada em classificação *fuzzy* se aproximou mais da estimativa de referência por expansão direta, com exceção do município de Maripá, com coeficiente de correlação de 0,992. Essas estimativas são obtidas por métodos objetivos porém, a baseada em classificação *fuzzy* utiliza imagens AVHRR-NOAA, onde o tamanho do pixel de 1,1 x 1,1 km diminui o detalhamento da superfície terrestre.

4. Conclusões

A estimativa de área baseada em classificação *fuzzy* utilizou índices de vegetação gerados a partir das imagens diárias e gratuitas AVHRR-NOAA.

No caso da cultura de soja no oeste do Paraná, foi possível estimar as áreas plantadas nos oito municípios até o final de janeiro de 2004, período de maior vigor vegetativo da soja na região em estudo, com antecedência em relação à época da colheita, ao contrário do levantamento oficial que se estende até o final da safra, além de utilizar dados subjetivos vindos do campo. As estimativas de área de soja baseadas em classificação *fuzzy* mostraram-se altamente correlacionadas com as estimativas oficiais e com a de referência obtidas por expansão direta, sendo um indicativo de boa precisão, com um nível de erro relativo aceitável.

A metodologia mostrou ser viável, uma vez que é realizada de forma objetiva, possui menor custo e pode ser realizada com antecedência à estimativa oficial. Portanto, pode ser empregada com o objetivo de auxiliar os métodos convencionais.

O sistema utilizado se mostrou uma ferramenta importante por garantir precisão geométrica dentro de um pixel e automatizar o processamento do grande número de imagens utilizadas. O georreferenciamento é a etapa fundamental de todo o processo e em conjunto com o mascaramento de nuvens propicia a geração de produtos precisos e com qualidade, para obtenção de estimativas de área de soja municipais confiáveis.

5. Agradecimentos

Os autores agradecem ao Dr. Daniel G. Baldwin e ao Dr. William Emery do CCAR por repassarem gratuitamente a tecnologia de software que possibilitou o desenvolvimento de grande parte do sistema de processamento das imagens AVHRR-NOAA.

Referências

Bezdek, J.; Ehrlich, R.; Full, W. FCM: the fuzzy c-means clustering algorithm. **Computers and Geosciences**, v. 10, n. 2, p. 191-203, 1984.

Canty, M. **Image analysis and pattern recognition for remote sensing with examples in ENVI/IDL.**

Disponível em: <<http://www.fz-juelich.de/stc/datapool/page/210/zfl.html>>. Acesso em: 28. mar. 2005.

Chen, P. Y., Srinivasan, R., Fedosejevs, G., Narasimhan, B. An automated cloud detection method for daily NOAA-14 AVHRR data for Texas, USA. **International Journal of Remote Sensing**, v. 23, n. 15, p. 2939-2950, 2002.

Companhia Nacional de Abastecimento (CONAB). **Safras**. Disponível em: <<http://www.conab.gov.br>>. Acesso em 10. fev. 2004.

Duda, T.; Canty, M. J. Unsupervised classification of satellite imagery: choosing a good algorithm, **International Journal of Remote Sensing**, v. 23, n. 11, p. 2193-2212, 2002.

Emery, W. J.; Baldwin, D.; Matthews, D. Maximum Cross Correlation Automatic Satellite Image Navigation and Attitude Corrections for Open Ocean Image Navigation, **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 1, p. 33-42, 2003.

Epiphânio, J. C. N.; Luiz, A. J. B.; Formaggio, A. R. Estimativa de Áreas Agrícolas Municipais utilizando Sistema de Amostragem Simples sobre Imagens de Satélite. **Bragantia**, Campinas, v. 61, n. 2, p. 187-197, 2002.

Esquerdo, J. C. D. M.; Antunes, J. F. G.; Baldwin, D. G.; Emery, W. J.; Zullo Jr, J. An automatic system for AVHRR land surface product generation. **International Journal of Remote Sensing**, v. 27, n. 18, p. 3925-3942, 2006.

Fontana, D. C.; Weber, E.; Ducati, J.; Figueiredo, D. C.; Berlato, M. A.; Bergamaschi, H. A case study for crop monitoring and harvest forecast in south Brazil. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 28. Cape Town. **Proceedings...** p. 91-94, 2000.

Foody, G. M. Sharpening fuzzy classification output to refine the representation of sub-pixel land cover distribution. **International Journal of Remote Sensing**, v. 19, n. 13, p. 2593-2599, 1998.

França, G. B.; Cracknell, A.P. A simple cloud masking approach using NOAA AVHRR daytime data for tropical areas. **International Journal of Remote Sensing**, v. 16, p. 1697-1705, 1995.

Ganan, J. R.; Rocha, J. V.; Mercante, E.; Antunes, J. F. G. Mapeamento da cultura da soja com imagens Landsat 5/TM utilizando algoritmos de classificação supervisionada. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XII., **Anais...** Goiânia, 2005.

Gath, I; Geva, A. B. Unsupervised optimal fuzzy clustering. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 3, n. 3, p. 773-781, 1989.

Goodrum, G.; Kidwell, K.; Winston, W. (Editors) **NOAA KLM User's guide. September 2000 Revision.** Disponível em <<http://www2.ncdc.noaa.gov/docs/klm>>. Acesso em: 15 mar. 2004.

Holben, B. N. Characteristics of maximum value composite images from temporal AVHRR data. **International Journal of Remote Sensing**, v. 7, n. 11, p. 1417-1435, 1986.

Liu, W.T.; Kogan, F. Monitoring Brazilian soybean production using NOAA/AVHRR based vegetation condition indices. **International Journal of Remote Sensing**, v. 23, n. 6, p. 1161-1179, 2002.

Pimentel-Gomes, F. **Curso de estatística experimental**. 14 Edição. Piracicaba: ESALQ, 477 p., 2000.

Rao, C. R. N.; Chen, J. Post-launch calibration of the visible and near-infrared channels of the Advanced Very High Resolution Radiometer on the NOAA-14 spacecraft. **International Journal of Remote Sensing**, v. 17, p. 2743-2747, 1996.

Rosborough, G. W.; Baldwin, D. G.; Emery, W. J. Precise AVHRR image navigation. **IEEE Transactions on Geoscience and Remote Sensing**, v. 32, n. 3, p. 644-657, 1994.

Rouse, J. W.; Haas, R. H.; Schell, J. A.; Deering, D. W. Monitoring vegetation systems in the great plains with ERTS. In: Earth Resources TechnologySatellite-1 Symposium, 3., Washington, D. C., 1973. **Proceedings...** Washington, D. C.: NASA. Goddard Space Flight Center, 1973. v. 1, p. 309-317. (NASA SP-351).

SEAB/DERAL. **Secretaria da Agricultura e do Abastecimento do Paraná/Departamento de Economia Rural**. Disponível em: <<http://www.pr.gov.br/seab/ativi2.shtml>>. Acesso em 27. abr. 2005.

Zadeh, L. A. fuzzy sets. **Information and Control**, v. 8, p. 338-353, 1965.

Wilson, E. H.; Sader, S. A. Detection of forest harvest type using multiple dates of Landsat TM imagery. **Remote Sensing of Environment**, v. 80, p. 385-396, 2002.