

Generalização temporal de redes neurais artificiais na classificação espectro-temporal de culturas agrícolas

Rafaelle Schimith¹
José Marinaldo Gleriani¹
Vicente Paulo Soares¹
Elias Silva¹
Sebastião Venâncio Martins¹
Francisco de Assis de Carvalho Pinto²

¹ Universidade Federal de Viçosa - UFV/DEF
36571-000 - Viçosa - MG, Brasil
{rafaelle, gleriani, vicente, eshamir, venancio}@ufv.br

² Universidade Federal de Viçosa - UFV/DEA
36571-000 - Viçosa - MG, Brasil
facpinto@ufv.br

Abstract. . The spectral characterization and the success in classification of agricultural scenes is a challenge that has generated good results based on spectral-temporal analysis. However, most of the studies have used only the special generalization of a classifier, leaving out the temporal generalization. In this study, three scenes of Landsat ETM+ and seven of Landst -5 TM data obtained from April to November, 2001 and 10 scenes of Landsat ETM + from the same period of 2002, were radiometrically normalized using as reference the March, 2002 ETM+ scene. Using bands 3, 4, 5 and NDVI transformation from 10 dates as input data, all scenes obtained in 2001 and 2002 were classified using a MLP network based on error backpropagation trained based on data from 2001. With the MLP network trained based on data from 2002, all scenes (2001 and 2002) were also classified. In both cases, there were significant differences ($p < 0,01$), with a reduction in the accuracy when temporal generalization classifier was performed. It was also observed that, for the scenes of 2001, simple procedures as the transformation of the raw data in apparent reflectance generated classification accuracies similar to those from the scenes radiometrically normalized.

Palavras-chav: Perceptrons de múltiplas camadas, generalização temporal, culturas agrícolas.

1. Introdução

Apesar da aparente abundância dos recursos hídricos no planeta, existe um reduzido volume de água doce disponível para o consumo. Mais de 97% de toda água encontra-se nos oceanos e, dos 3% restantes, 2% estão retidos nas geleiras, sobrando menos de 1% para a utilização (Domingues, 2004).

A utilização de água diária per capita nos setores brasileiros (em litros/hab/dia) apresenta-se da seguinte forma: abastecimento humano – 200, produção industrial – 428, produção de alimentos – 1430, para uma produção total diária – 2058 (Christofidis, 2002). Ou seja, o consumo nacional da irrigação é de 69% de toda água captada, bem próximo da média mundial de 70% estimada pela FAO. A crescente demanda por alimentos trará, como consequência, um aumento da área cultivada; o aumento da produtividade também é uma meta almejada, cuja obtenção está intrinsecamente relacionada à irrigação: apenas 18% de área agrícola mundial são irrigadas, mas essa área responde por 44% da produção de grãos. No Brasil, estima-se que exista mais 10,7 milhões de ha aptos a irrigação somente no bioma cerrado (Christofidis, 2006).

Esforços da comunidade científica tem sido direcionados para a modelagem/estimativa da demanda de água para irrigação via dados orbitais e dados de campo (El-Magd e Tanton, 2005). Um dos modelos utilizados é o SEBAL (*Surface Energy Balance Algorithm for Land*) Bastiaassen (1995) para estimativa da evapotranspiração real ETR, porém, a FAO tem utilizado para o cálculo da evapotranspiração potencial ET_0 , o modelo de Penman-Monteith

(Allen et al. 1998), cujo valor multiplicado pelo coeficiente K_c , específico de cada cultura e tabelado pela FAO, fornece a evapotranspiração da cultura ET_c (El-Magd e Tanton, 2005).

A classificação de cenas agrícolas é um desafio pelas diferenças fenológicas em que uma mesma cultura é encontrada numa dada cena, como pela reposta espectral similar quando, em pleno vigor, diferentes culturas são observadas por sensores com as atuais larguras de bandas (Steven e Jaggard, 2000). Uma das soluções tem sido a utilização a abordagem espectro-temporal aonde, o dinamismo do alvo agrícola, associado a multitemporalidade dos sensores permite uma melhor caracterização das culturas (Bauer, 1985; Hall e Badhwar, 1987, Gleriani, 2004).

Nos processos de classificação, tem sido abordado a utilização de classificadores por pixel ou regiões, supervisionados ou não, porém, sempre testando a capacidade de generalização espacial de um classificador. Nesse processo pixels ou regiões são estão na mesma cena aonde forma coletadas amostras para treinamento do classificador. A generalização temporal (e também espacial), cujos dados de treinamento e classificação são de datas diferentes, tem sido pouco testada (Pax-Lenney et al., 2001). Causas de insucesso de ambiciosa classificação, tem sido a interferência da atmosfera (Myers, 1983), cujas uniformizações e sucessos na classificação são alcançados, segundo Pax-Lenney et al. (2001), com modelos complexos como o 6S (*Radiative Transfer Code*) (Vermote et al., 1997), ou com a “Subtração do Pixel Escuro” (*DOS – Dark Object Subtration*) (Chaves, 1988).

O objetivo desse trabalho foi utilizar a abordagem espectro-temporal e classificar as cenas de 2001 com rede treinada com amostras de 2002, assim como classificar as cenas do ano de 2002 com rede treinada com amostras do ano de 2001. Para essa abordagem, testou-se a calibração absoluta das cenas assim como a uniformização radiométrica pelo método proposto por Hall et al (1991).

2. Metodologia de trabalho

A respectiva área de estudo, esta localizada entre as coordenadas de $47^{\circ} 54' 8''$, $48^{\circ} 16' 31,7''$ W e latitude $20^{\circ} 5' 14,2''$, $20^{\circ} 23' 16,8''$ S, representada no retângulo pontilhado (Figura 1). Está localizada no Norte do estado de São Paulo, possuindo maior porção no município de Miguelópolis – SP. Na área existe predomínio de Latossolos Vermelhos (LV) e Latossolos Amarelos (LA), com relevo suavemente ondulado Oliveira et al. (1999).

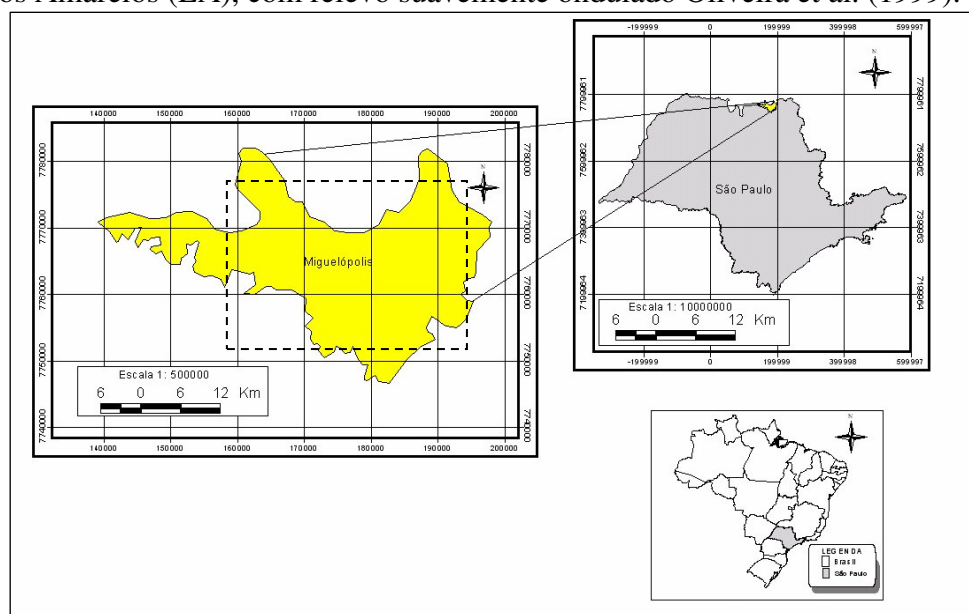


Figura 1 – Localização do município de Miguelópolis-SP e área de estudo representada pelo retângulo pontilhado.

Na área existe o cultivo de soja e milho no verão, cana de açúcar o ano todo e cultivos irrigados de feijão, milho e sorgo, no inverno. Em algumas propriedades existe o cultivo de milho “safrinha” plantado imediatamente após a colheita do milho ou soja de verão.

Em ambiente SPRING 4.3.3 foram georreferenciadas 10 cenas do satélite Landsat da órbita/ponto 220/74, sendo três delas do sensor ETM+/Landsat-7 (27/06/2001, 29/07/2001, 14/08/2001) e sete do sensor TM/Landsat-5 (16/04/2001, 02/05/2001, 18/05/2001, 03/06/2001, 05/07/2001, 07/09/2001 e 25/10/2001), tendo como cena referência a cena do dia 10 de março de 2002 na projeção UTM datum SAD-69, com RMSE menor que 0,5. A cena utilizada como referência geométrica também foi utilizada como referência radiométrica, uma vez que a mesma foi utilizada como retificação do conjunto de cenas de 2002 em Gleriani (2004). Essa cena de referência passou por processamento de correção atmosférica com o algoritmo DOS3 (Song et al., 2001).

Utilizou-se os canais 3, 4 e 5 e a retificação de cada canal T(i) retificado, é dada pela seguinte equação:

$$T(i) = m_i x_i + b_i \quad (1)$$

onde, x_i = banda espectral a ser retificada; m_i e b_i são os coeficientes de inclinação e intercepto calculados através das Equações (2) e (3) abaixo:

$$m_i = (B_{Ri} - D_{Ri}) / (B_{Si} - D_{Si}) \quad (2)$$

$$b_i = (D_{Ri} - B_{Si}) - (D_{Si} B_{Ri}) / (B_{Si} - D_{Si}) \quad (3)$$

onde, D_{Si} , D_{Ri} , B_{Si} , B_{Ri} são as médias para as áreas pseudo invariantes escuras (D) e claras (B) para as imagens a serem retificadas (S) e para as imagens de referência (R).

Após a retificação, os dados foram normalizados (Equação 4) para o intervalo 0-1, para que os dados de saída expressassem uma correta ponderação dos dados de entrada.

$$x_i = \frac{DN_i - DN_{iMIN}}{DN_{iMAX} - DN_{iMIN}} \quad (4)$$

onde, x_i é a grade numérica resultante da banda i, DN_i é o valor digital de cada pixel da banda i, DN_{iMIN} é o menor valor de DN da banda i nas 10 datas, DN_{iMAX} é o maior valor de DN nas 10 datas analisadas.

O mesmo conjunto original de cenas foi transformado em dados de reflectância aparente com base em parâmetros de calibração da radiância (L) e da irradiância (E) publicados por Chander e Markhan (2003), para o sensor TM/Landsat-5, e dos mesmos parâmetros publicados na página da NASA (NASA, 2000) para o sensor ETM+/Landsat-7

$$\rho_{ap} = \frac{\pi \cdot d^2 \cdot L}{E_0 \cdot \cos(\theta_z)} \quad (5)$$

onde, reflectância aparente, π (sr) é o parâmetro de conversão da radiância em irradiância, E_0 consiste na irradiância solar ($W \cdot m^{-2}$), θ_z é o ângulo zenital solar, e L é a radiância ($W \cdot m^{-2} \cdot sr$). Para ambos os conjuntos de cenas, retificados e não retificados, foi gerado o Índice de Vegetação Diferença Normalizada (NDVI):

$$NDVI = \frac{IVP - V}{IVP + V} \quad (6)$$

onde, IVP = energia refletida na região do ivp e V = energia refletida na região do vermelho.

Os dados foram exportado em formato ASCII (*American Standart Code Information Interchange*) e organizados para serem utilizados no simulador SNNS *Stuttgart Neural Network Simulator* – v 4.1 (Zell et al. 1998). Oito classes foram definidas de acordo com Gleriani (2004): feijão 1, feijao 2, milho, sorgo, cana de ano, cana de ano e meio, não agrícola/não cultivado, água e 100 amostras foram obtidos para cada amostra.

Nesse trabalho, o treinamento foi realizado com o algoritmo de treinamento *Std_Backpropagation*, com o parâmetro da taxa de aprendizagem (η) de 0,1. A função de ativação nos neurônios na camada oculta e de saída utilizados foi a função sigmóide logística. Utilizou-se como parâmetros de entrada as bandas 3, 4, 5 e o NDVI. Como foram utilizadas 10 cenas a camada de entrada foi composta de 40 neurônios. Oito neurônios foram utilizados na camada de saída, para expressar as oito classes com somente um neurônio ativado; assim, a melhor arquitetura encontrada foi a 40-12-8.

A seqüência de atividades está resumida nos itens abaixo e ilustrados na Figura 2:

- Classificação das com cenas de 2001 retificadas e calibradas (ρ_{ap}), com a rede neural treinada com amostras coletadas nessas cenas.
- Classificação de cenas de 2001 retificadas, com a rede treinada com amostras das cenas do ano de 2002 (generalização temporal).
- Classificação de cenas de 2002 retificadas, com a rede treinada com amostras das cenas do ano de 2001 (generalização temporal).
- Cálculo da estatística Z para verificar se as generalizações temporais com o uso das cenas/amostras 2001/2002 e 2002/2002, acarretam perdas significativas na exatidão de classificação.
- Cálculo da estatística Z, com as classificações realizadas com o conjunto 2001, para verificar se o procedimento de retificação radiométrica é necessário ou se basta calibrar as imagens (refletância aparente) para executar a classificação espectro-temporal.

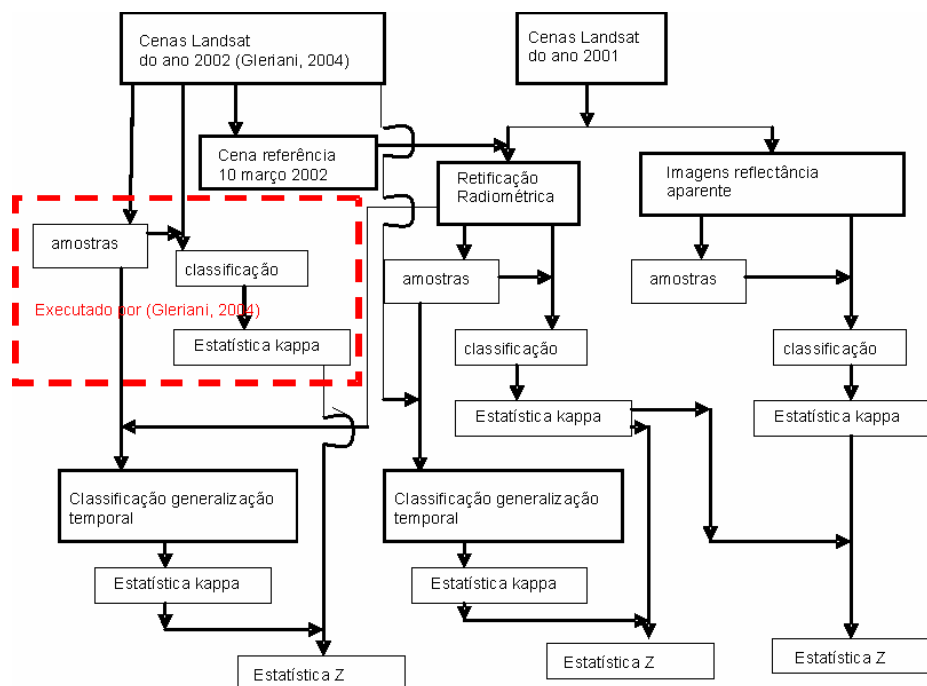


Figura 2 - Fluxograma das atividades

3. Resultados e Discussão

Apesar de atrativa, generalização temporal de um classificador tem sido pouco utilizada. Pax-Lenney et al. (2001) testaram a generalização de classificadores em área florestais, onde apenas considerou-se a características espectrais (única data). Para a generalização temporal de classificadores, dentro da abordagem espectro-temporal (múltiplas datas), outros empecilhos ao sucesso podem existir, como o deslocamento, no tempo, do padrão espectro-temporal. Mesmo analisando-se o mesmo período (abril-outubro) de Gleriani (2004), a variação existe pois a irrigação permite uma flexibilidade de cultivos, maior que a existente na safra de verão. Outro problema seria a variação de cultivos e, conseqüentemente, de classes de um ano para outro, o que inviabilizaria a generalização temporal das redes. Essa questão não seria problema já que, em trabalhos de campo na região desde 1991, Ortiz et al. (1997) verificaram que existe variação da área cultivada das culturas pelos mais diversos fatores, porém, as mesmas culturas são encontradas todos os anos, principalmente pela tradição de cultivo dos agricultores.

3.1 – Espectro-temporalidade das classes agrícolas

A resposta espectro-temporal de cada classe agrícola é ilustrado na Figura 3. A definição das classes seguiu a metodologia de Gleriani (2004). Para ilustração, utiliza-se nesse trabalho apenas a temporalidade das do NDVI; a curvas espectro-temporais das bandas 3, 4 e 5 podem ser encontradas em Gleriani (2004) e Schimith (2008).

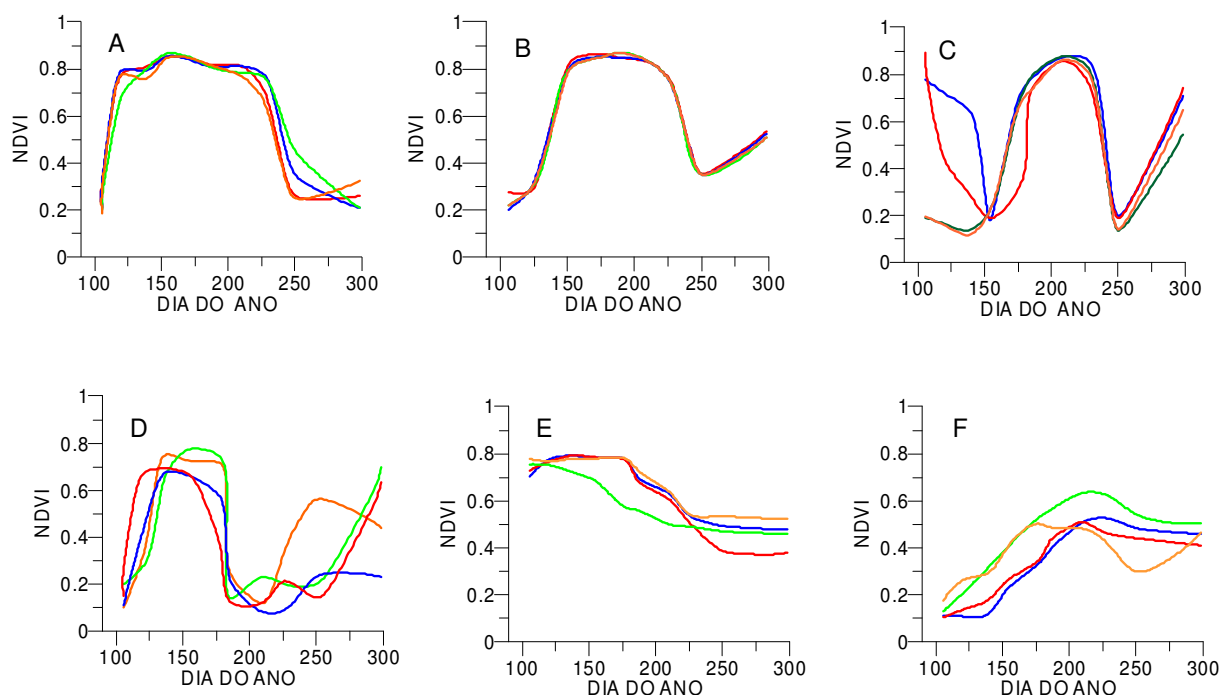


Figura 3 – Resposta temporal do NDVI coletadas nas imagens retificadas radiometricamente para as classes (A) Sorgo, (B) Milho, (C) Feijão 2, (D) Feijão 1, (E) Cana colhida no ano e (F) e Cana de ano.

Para a classe sorgo observa-se uma forte ascensão da do NDVI após o centésimo dia do ano e um longo patamar de estabilização (Figura 3 A). As curvas aqui analisadas são resultantes da fenologia de cada cultura associada às práticas de cultivo. O sorgo é cultivado com espaçamento de 0,45 m, numa densidade de 14 plantas por metro, já o milho (Figura 3 B)

é cultivado com espaçamento médio de 0,9 m com 5 a 7 plantas por metro. O feijoeiro tem m ciclo mais curto, e as classes feijão 2 e feijão 1 (Figura 3C e 3D) são resultantes de épocas de cultivo aproximadamente opostas. Antes e após a classe feijão 2 propriamente dita (Figura 3 C) - e após o ciclo feijão 1 (Figura 3 D), pode existir resíduos (palhada), outro plantio, pousio/ervas daninhas ou qualquer atividade que não expresse, espectralmente, o ciclo propriamente dito do feijoeiro. Para a classe - cana colhida no ano (Figura 3 D), inclui-se toda a cana planta de ciclo de ano-e-meio plantada no ano anterior e toda cana soca. A queda observada aproximadamente após o dia 150 deve-se ao estresse hídrico do período e a maior quantidade de palha observada no FOV do sensor. Deve também lembrar que o NDVI é um indicador de IAF-verde e muito sensível às pequenas variações na banda do vermelho (Jackson e Pinter Jr, 1986).

3.2 – Exatidão de classificação

O mapa temático resultante da classificação espectro-temporal do conjunto de cenas do ano 2001, retificadas radiometricamente, classificadas com rede a rede MLP 40-12-8, treinadas com dados da safra 2001, é apresentado na Figura 4.




Figura 4 – Mapa temático resultante da classificação espectro-temporal de cenas do ano de 2001, classificado com a rede MLP 40-12-8, treinadas com dados do ano de 2001.

O valor de kappa obtido foi de 0,35856, cuja generalização com a rede MLP, treinada com amostras colhida no conjunto de imagens do ano de 2002 apresentou uma queda significativa (Tabela 1).

Tabela 1 - Análise da estatística Z entre o kappa resultante da classificação das cenas do ano de 2001 com rede neural treinada com dados do ano de 2001, com cenas do ano de 2001 classificadas com rede treinada com dados do ano de 2002.

Cenas2001 rede 2001		Cenas2001 rede2002		Estatística Z	
k	Var(k)	k	Var(k)	Z**	p
0,35856	0,000469	0,2696	0,00039	3,34	0,00120

**p<0,01 – NS – não significativo

A Tabela 2 apresenta o kappa e a respectiva variância executados por Gleriani (2004), assim como a classificação do mesmo conjunto com dados com a rede treinada com dados do ano de 2001. Novamente observa-se uma queda na exatidão de classificação com a generalização temporal da rede neural.

Tabela 2 - Análise da estatística Z entre o kappa resultante da classificação das cenas do ano de 2002 com rede neural treinada com dados do ano de 2002, com cenas do ano de 2002 classificadas com rede treinada com dados do ano de 2001.

Cenas2002 rede 2002		Cenas2002 rede2001		Estatística Z	
k	Var(k)	k	Var(k)	Z**	p
0,62067	0,01548	0,2357	0,000207	3,11	0,0009

**p<0,01 – NS – não significativo

Por último, comparou-se a classificação do ano de 2001 com a rede treinada com dados colhidos no conjunto de cenas do próprio ano com a classificação executada com imagens que apenas tiveram a transformação para reflectância aparente. Observa-se que não existiu diferença significativa e que procedimentos metodológicos mais simples do que a retificação radiométrica pode produzir resultados similares.

Tabela 3 - Análise da estatística Z entre o kappa resultante da classificação das cenas do ano de 2001 com rede neural treinada com dados do ano de 2001, retificadas, com cenas do ano de 2001 classificadas com rede treinada com dados do ano de 2001, reflectância.

Cenas2001 rede 2001- retificada		Cenas2001 rede201- reflectância		Estatística Z	
k	Var(k)	k	Var(k)	Z (NS)	p
0,35856	0,000469	0,3464	0,000442	0,18424	0,4269

**p<0,01 – NS – Não significativo

4. Conclusões

A generalização temporal de classificadores é uma classificação bastante ambiciosa com os dados de sensoriamento - a direcionalidade da radiação, o dinamismo e a interferência da atmosfera, a degradação de detectores, estão entre os fatores desafiadores a essa metodologia. O presente estudo não confirmou o sucesso da generalização temporal observadas por Pax-Lenney et al (2001), possivelmente pelo dinamismo e complexidade do alvo agrícola, o que torna a generalização temporal, dentro da abordagem espectro-temporal, assunto de novos trabalhos.

Observou-se porém, que procedimentos simples, como a transformação para reflectância aparente, pode trazer uma uniformização dos dados.

Referências Bibliográficas

Allen, R.G., Pereira, L.S., Raes, D., Smith, M.,. **Crop evapotranspiration: guidelines for computing crop water requirements**. FAO Irrigation and Drainage Paper no. 56, Rome, Italy, 333p, 2006.

Bastiaansen, W. G. M.. SEBAL – Based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey. **Journal of Hydrology**. v. 229, n. 1, p87-100, 2000.

Bauer, M. E. Spectral inputs to crop identification and condition assessment. **Proceedings of the IEEE**., v.73, n.6, p. 1071-1085, 1985.

Chander, G.; Markham, B. Revised Landsat 5 TM radiometric calibration procedures and post-calibration dynamic ranges. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 11, p. 2674-2677, 2003.

Chavez Jr., P.S. An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data. **Remote Sensing of Environment**, v. 24, p. 459-479, 1988.

Christofidis, D. Irrigação, a fronteira hídrica na produção de alimentos. **Revista Item**, n. 54. p. 46 – 55, 2002.

Christofidis, D. Oportunidade de irrigação no cerrado - Recursos hídricos dos cerrados e seu potencial de utilização na irrigação. **Revista Item**, n. 69/70, p. 87 -97, 2006.

Congalton, R. G.; Green, K. **Assessing the accuracy of remotely sensed data: principles e practices**. New York, Lewis Publishers. 137p. 1999.

Domingues, A. F. O estado da arte da agricultura irrigada e as modernas tecnologias no uso racional da água na irrigação. **Seminário da ANA- Agência Nacional das Águas**. Brasília, 2004.

El-Magd, I.A.; Tanton, T. R. Remote sensing and GIS for estimation of irrigation crop water demand. **Internacional Journal of Remote Sensing**. v. 26, n. 11, p. 2.359-2.370, 2005.

Gleriani, J. M. **Redes Neurais na classificação espectro-temporal de culturas agrícolas**. 2004. 198p Tese (Doutorado em Sensoriamento Remoto) Instituto Nacional de Pesquisas Espaciais, São José dos Campos, São Paulo. 2004.

Hall, F.G.; Badhwar, G.D. Signature-extendable technology: global space-based crop recognition. **IEEE Transactions on Geoscience and Remote Sensing**. v.25, n.1, p.93-103. 1987.

Jackson, R.D.; Pinter Jr., Spectral response of architecturally different wheat canopies. **Remote Sensing of Environment**, v. 20, n.1, p.43-56, 1988.

NASA. Landsat 7. Disponível em: <<http://geo.arc.nasa.gov/sge/landsat/l7.html>>. Acesso em: 23 de março de 2000.

Oliveira, J.B.; Camargo, M.N.; Rossi, M.; Calderano Filho, B. **Mapa pedológico do Estado de São Paulo: legenda expandida**. IAC (Instituto Agrônomo de Campinas)/ EMBRAPA – Solos. Campinas, 1999, 64p.

Ortiz, M. J. ; Formaggio, A. R. ; Epiphanyo, J. C. N.. Classification of croplands through integration of remote sensing, GIS, and historical database. **International Journal of Remote Sensing**. v. 18, n. 1, p. 95-105, 1997.

Pax-Lenney, M.; Woodcock, C.E.; Macomber, S.A.; Gopal, S.; Song, C. Forest mapping with a generalized classifier and Landsat TM data. **Remote Sensing of Environment**, v.77, n.3, p.241-250, 2001.

Schmith, R. **Generalização temporal de classificadores MLP utilizando a abordagem espectro-temporal em cena agrícolas**. Dissertação de Mestrado. Universidade Federal de Viçosa – UFV. No prelo, 2008.

Song, C.; Woodcock, C.E.; Seto, K.C.; Lenney, M.P.; Macomber, S.C. Classification and change detection using Landsat TM data: when and how to correct atmospheric effects? **Remote Sensing of Environment**, v.75, n.2, p. 230-244, 2001.

Steven, M.D.; Jaggard, K.W. Advances in crop monitoring by remote sensing. In: Danson, F.M.; Plummer, S. E. ed. **Advances in Environmental Remote Sensing**. 1ed. Baffins Lane, England. Wiley, 1995, cap. 9, p.143-156. Vermote, E.F. Second Simulation of the Satellite Signal in the Solar Spectrum, 6S: an overview. **IEEE Transactions on Geoscience and Remote Sensing**, v.35, n.3, p.675-686, 1997.

Zell, A.; Mamier, G.; Mache, M.V.N.; Hübner, R.; Dörin, S.; Hermann, K-U; Soye, T.; Schmalzl, M.; Sommer, T.; Hatzigeorgiou, A.; Posselt, D.; Schreiner, T.; Kett, B.; Clemente, G.; Wieland, J.; Gatter, J. **SNNS – Stuttgart Neural Network Simulator v.4.2, User Manual**, University of Stuttgart/ University of Tübingen, 338p. 1998.