

Classificação espectro-temporal de culturas agrícolas tropicais: tolerância de dois modelos de redes neurais a dados falhos

José Marinaldo Gleriani¹
José Carlos Neves Epiphanyo²
José Demísio Simões da Silva²

¹ Universidade Federal de Viçosa
36570-000 - Viçosa - MG, Brasil
gleriani@ufv.br

² Instituto Nacional de Pesquisas Espaciais - INPE
Caixa Postal 515 - 12201-970 - São José dos Campos - SP, Brasil
epiphanyo@dsr.inpe.br, demisio@lac.inpe.br

Abstract. This paper aims to evaluate the tolerance of a backpropagation error-based Multilayer Perceptron Network (MLP) and a Radial Basis Function in face of missing optical remote sensing data. The spectral-temporal pattern analysis allows a better characterization of agricultural crops and improves the discrimination and classification of agricultural scenes. However, due to unfavorable climatic conditions during the summer season the acquisition of the required optical data throughout the entire agricultural cycle is not always possible. To overcome this problem, a simulation of missing data for the data set obtained in the winter period was conducted through interpolation operations, in which images from every other date have been suppressed and replaced by the arithmetic average between the immediately preceding and posterior images in relation to the considered date. The Kappa values of the resulting thematic maps presented a non-significant difference in comparison with the classified maps derived from the complete set of scenes, but the classification process based on simulated data ended up in noisy results and in the loss of the sorghum class.

Palavras-chave: espectro-temporalidade, rede neurais, função de base radial, sensoriamento remoto

1. Introdução

A agricultura é uma das áreas de aplicação com maior demanda de dados de sensores orbitais. Entre as aplicações destacam-se o monitoramento da produção, monitoramento do estresse e o mapeamento (Steven e Jagard, 1995).

O mapeamento de culturas agrícolas é um desafio, uma vez que uma mesma cultura pode existir em diferentes talhões em fases fenológicas distintas (Hill e Sturm, 1991). Nesse caso, a resposta espectral de uma mesma classe tem uma variabilidade indesejada, causada pelos valores diferentes de índice de área foliar (IAF) e pelas variadas frações de solo exposto no campo de visada do sensor. Outro problema é que mesmo na fase de dossel com cobertura total do solo, diferentes culturas podem parecer espectralmente semelhantes devido à largura das bandas dos atuais sensores orbitais (Hall e Badhwar, 1987).

Esse problema pode ser minimizado pela análise temporal, uma vez que com uma única imagem é difícil a caracterização e a discriminação das culturas. A análise temporal permite analisar a fenologia, que é típica a cada cultura, e cuja descrição temporal pode ser feita por índices de vegetação (IVs) (Badhwar et al., 1982; Odenweller e Johnson, 1984; Hall e Badhwar, 1987) ou com a combinação de bandas e de IVs (Gleriani, 2004). A análise temporal melhora a discriminação entre classes (Hall e Badhwar, 1987; Murthy et al., 2003) permitindo, com a análise gráfica da resposta espectro-temporal, até a identificação das culturas (Odenweller e Johnson, 1984; Gleriani, 2004).

No entanto a aplicação dessa metodologia, principalmente na safra de verão, está limitada à aquisição de dados ópticos, cuja probabilidade de aquisição de imagens úteis é próxima de 30% (Ippoliti-Ramilo et al., 2003).

Com o objetivo de solucionar esse problema, a utilização das redes neurais como classificadores é um caminho promissor. Esses classificadores têm a vantagem de serem não-paramétricos, necessitarem de pequenas amostras para treinamento (Paola e Schowengerdt, 1995; Kavzoglu e Mather, 2003) e serem tolerantes a dados falhos (Bishop, 1995).

O objetivo deste trabalho é verificar a performance de classificação de um Perceptron de Múltiplas Camadas (PMC) de retropropagação do erro e de uma Função de Base Radial (FBR), quando apresentados aos mesmos padrões falhos em relação aos padrões completos de treinamento.

2. Materiais e Métodos

A área de estudo está localizada ao norte do Estado de São Paulo, entre as coordenadas 47 54'8'' e 48 16'31,7'' de longitude oeste e 20 5'14,2'' e 20 23'16,8'' de latitude sul. A maior porção está contida no município de Miguelópolis, o qual pertence ao EDR (Escritório de Desenvolvimento Rural) de Orlandia. Na área existe o cultivo de cana-de-açúcar e cultivo feijão, milho e sorgo durante o inverno em sistemas de irrigação do tipo pivô central.

Neste estudo, foram utilizadas dez cenas do sensor ETM+ (Enhanced Thematic Mapper Plus) do Landsat-7, da órbita/ponto 220/74 do ano de 2002. Essas cenas foram registradas com um erro menor que 0,5 pixels em ambiente SPRING 3.06.3. A cena de 10 de março, utilizada como referência no processo de retificação, foi corrigida para efeitos atmosféricos com o modelo DOS 3 (Dark Object Subtraction) (Song et al., 2001). As outras nove cenas utilizadas foram de: 11 de abril, 27 de abril, 13 de maio, 29 de maio, 14 de junho, 30 de junho, 16 de julho, 17 de agosto e 02 de setembro. Essas nove cenas foram retificadas para uniformização radiométrica pelo procedimento descrito por Hall et al. (1991):

$$T(i) = m_i x_i + b_i \quad (2.1)$$

$$m_i = (B_{Ri} - D_{Ri}) / (B_{Si} - D_{Ri}) \quad (2.2)$$

$$b_i = (D_{Ri} B_{Si} - D_{Si} B_{Ri}) / (B_{Si} - D_{Si}) \quad (2.3)$$

onde $T(i)$ é a transformação de retificação aplicada à $i^{\text{ésima}}$ banda; m_i e b_i são coeficientes dessa transformação, e D e B são as médias das áreas de controle radiométrico escuras e claras, respectivamente, da $i^{\text{ésima}}$ banda das cenas a serem transformadas (s) e das cenas de referência (r). A imagem de 01 de agosto foi simulada pela média das imagens precedente e subsequente, após a retificação. A área de estudo representa uma área de 1087x1281 pixels recortada ao norte da cena 220/74.

Com os valores de reflectância gerou-se o NDVI (Índice de Vegetação por Diferença Normalizada). A análise temporal dos gráficos permitiu a definição de seis classes agrícolas: cana-de-açúcar colhida no ano, cana-de-açúcar de ano e meio, feijão 1, feijão 2, milho, e sorgo. Duas classes adicionais foram água e não-agrícola/não-cultivado. O NDVI foi calculado pela seguinte equação:

$$NDVI = \frac{\rho_4 - \rho_3}{\rho_4 + \rho_3} \quad (2.4)$$

onde ρ_4 e ρ_3 são as reflectâncias das bandas 4 e 3, respectivamente.

O NDVI foi utilizado como parâmetro de entrada pois é um indicador das mudanças de IAF e, conseqüentemente, da fenologia.

A) Redes Neurais

Com o objetivo de que todos os dados de entrada tivessem o mesmo peso na saída das redes neurais, procedeu-se à normalização dos valores digitais (DN_i) dos dados pela equação abaixo:

$$x_i = \frac{DN_i - DN_{\text{MIN}}}{DN_{\text{MAX}} - DN_{\text{MIN}}} \quad (2.5)$$

onde DN_{MIN} e DN_{MAX} são, respectivamente, os valores máximos e mínimos encontrados no conjunto das dez cenas, uma vez que o pixel é analisado de maneira contínua no tempo.

A rede de PMC treinada com o algoritmo de retropropagação do erro foi estruturada com a arquitetura 40-70-8. A entrada de 40 neurônios deu-se pelo tamanho do padrão espectral-temporal composto de quatro componentes espectrais: NDVI, e bandas 3, 4 e 5 em dez datas. Um total de 100 vetores de cada classe foi extraído e organizado através de um aplicativo desenvolvido de acordo com o padrão do SNNS (Stuttgart Neural Network Simulator) (Zell et al., 1998). A equação (2.5) normalizou os dados para o intervalo de 0 a 1, uma vez que a função sigmóide logística foi utilizada na camada oculta de saída da rede de retropropagação. A rede FBR, de mesma arquitetura, tinha, na camada oculta, a função gaussiana e, na camada de saída, a função logística (**Figura 2.1**).

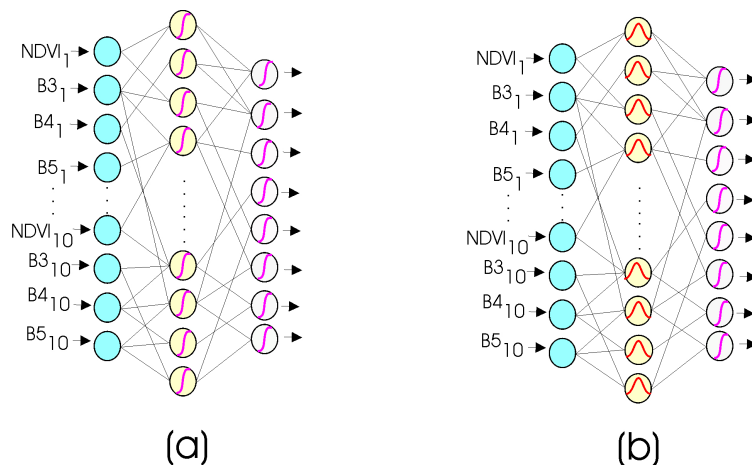


Figura 2.1 – (a) Rede de Perceptrons de Múltiplas Camadas (PMC). (b) Função de Base Radial (FBR).

Os valores utilizados para os parâmetros da rede de retropropagação do erro foram de 0,2 para taxa de aprendizagem (η) e de 0,1 para diferença máxima (d_{MAX}) entre os valores de saída e de aprendizagem.

Os parâmetros de aprendizagem para a rede FBR foram de 0,01. A função de inicialização escolhida foi a “FBR_Weights”, a qual distribui uniformemente os vetores como centro das classes. O desvio inicial do centro da função Gaussiana foi determinado pela equação (2.6),

$$\sigma = \frac{d_{\text{MAX}}}{\sqrt{2m_1}} \quad (2.6)$$

onde σ é o desvio padrão, m_1 é o número de centro de classes, e d_{max} é o maior valor resultante das diferenças pareadas entre os 40 valores do vetor médio. Esse vetor foi calculado a partir da média dos 100 vetores amostrais utilizados no treinamento.

Após o treinamento da rede, utilizou-se para a classificação o padrão completo de imagens. O resultado dessa classificação foi utilizado como padrão na comparação de falhas simuladas. As falhas simuladas seguiram duas seqüências diferentes de eliminação alternada. As imagens eliminadas foram substituídas pela média da imagem antecedente e precedente. Apenas na seqüência (b) da Figura 2.2 a eliminação não foi alternada, pois a oitava imagem já é simulada por média, e é necessário que em ambos os conjuntos sejam apresentados às redes quatro ruídos ou “falhas de dados” (Figura 2.2).




Figura 2.2 – Duas simulações de perda de dados por nebulosidade em datas alternadas. Situação (a) perda das imagens 3, 5, 7 e 9. Situação (b) perda das imagens 2, 4, 6, 9 (A imagem 8 já é simulada no conjunto original).

Após a classificação, sortearam-se 2415 pontos, que foram rotulados de acordo com o mapa de referência obtido em dois levantamentos de campo. Do cruzamento dos dados de referência com os resultados das classificações gerou-se a matriz de confusão. O kappa (\hat{k}) e a variância do kappa ($\hat{v}ar(k)$) derivados das matrizes de confusão foram utilizados no teste Z, para verificar se as duas matrizes eram independentes.

3. Resultados e Discussões

Apesar de a rede receber como padrão de entrada os dados temporais de NDVI e as bandas 3, 4 e 5, exibe-se, por praticidade, apenas o perfil temporal do NDVI. Todos os gráficos exibem cinco amostras obtidas dos 100 vetores utilizados no treinamento.

a) Feijão 1

Na área de estudo cultivam-se duas safras irrigadas por ano, que podem ser: milho/feijão, feijão/feijão, feijão/pousio e qualquer outra combinação. A primeira safra de feijão foi denominada de feijão 1. Essa denominação foi escolhida porque se cultivam variedades de feijão que possuem três diferentes hábitos de crescimento e cujo ciclo vegetativo pode variar de 75 a 100 dias.

Em adição a esse padrão temporal, o padrão temporal de uma cultura de ciclo curto tem uma desvantagem representativa em relação ao de uma cultura de ciclo longo. Dez cenas podem ser necessárias para definir o padrão temporal milho. No entanto, no máximo seis seriam necessárias para representar o padrão temporal feijão (Figura 3.1A), porém, dez datas adicionam um ruído (Figura 3.1 B) ao seu padrão temporal. Esse ruído poderia ser parte de um período de pousio ou de outra cultura.




Fig. 3.1- Comportamento temporal do NDVI para a classe Feijão 1; na porção A da curva apresenta-se a temporalidade propriamente dita da cultura; na parte B, o período de pousio.

b) Feijão 2

O comportamento da classe feijão 2 é oposto ao da classe feijão 1. Primeiramente, existe um ruído (cultura ou pousio) e, em seguida, o padrão temporal propriamente dito da cultura de feijão (**Figura 3.2**). O IAF (m^2/m^2) tem a sua dinâmica determinada pela fenologia da cultura e pela prática cultural. O feijoeiro é cultivado com média de 12 plantas por metro linear e 0,5 m de espaçamento entre fileiras.




Fig. 3.2 – Comportamento temporal do NDVI para a classe Feijão 2. O padrão temporal propriamente dito da cultura inicia-se após o dia 140 do ano.

c) Sorgo

O sorgo é cultivado com um espaçamento de 0,45 m entre linhas e até 14 plantas por metro linear. Como resultado, observa-se o rápido incremento do NDVI e, pelo ciclo fenológico, um patamar de vigor mais longo que o feijão (**Figura 3.3**).




Fig. 3.3 – Comportamento temporal do NDVI para a classe sorgo.

d) Milho

A curva temporal do NDVI para cultura do milho tem uma ascensão mais suave que a do sorgo (**Figura 3.4**). O milho é cultivado com espaçamento de 0,9 m entre linhas e com 5 a 7 plantas por metro linear.




Fig. 3.4 – Comportamento temporal do NDVI para a classe milho

e) Cana de ano e meio e Cana colhida no ano.

Conceitua-se cana-planta como aquela cana cuja origem está em mudas plantadas e que, posteriormente, sofrerão o primeiro corte. Após o primeiro corte, a cana brota e, nos ciclos sucessivos de corte/brotação, é denominada de cana-soca. O primeiro corte para as canas plantadas de janeiro a março ocorre aproximadamente após 18 meses, ou seja, no inverno do ano seguinte. A cana de ano é aquela cujo plantio dá-se de setembro a outubro e a colheita ocorre aproximadamente 12 meses após o plantio. O comportamento temporal da cana de ano e meio é ilustrado na **Figura 3.5A**. A classe cana colhida no ano agrupa os talhões de cana soca, cana de ano e meio e cana de ano colhidos no ano anterior. O comportamento é ilustrado na **Figura 3.5B**.




Fig. 3.5 – Comportamento temporal do NDVI para a classe cana de ano e meio (A) e cana colhida no ano (B).

As **Tabelas 3.1** e **3.2** ilustram a comparação do índice kappa para classificação com padrões temporais completos e o resultado para as duas simulações de falhas, respectivamente. Observa-se que nem para a rede de repropropagação do erro (PMC, Tabela 3.1) nem para a rede FBR (Tabela 3.2) existiu queda significativa do kappa. Porém, pela análise da **Figura 3.6 A** (rede PMC) com padrão completo e da **Figura 3.6 B**, resultado da primeira falha simulada, observa-se que o mapa temático ficou mais ruidoso e a classe sorgo desapareceu. O mesmo resultado foi observado com a rede FBR para um padrão completo (**Figura 3.6 C**) e com a primeira falha (**Figura 3.6 D**).

Tabela 3.1 – Avaliação estatística do índice kappa resultante da classificação da rede de PMC em duas situações: com dados completos e duas falhas simuladas.

Classificador	Arquitetura	\hat{k}	$\text{vâr}(\hat{k})$	Análise	Z	p
1 – 1ª falha	40-70-8	0,49644	0,01666	3 vs 1	0,723NS	0,2348
2 – 2ª falha	40-70-8	0,52323	0,01673	3 vs 2	0,444NS	0,2833
3 – RPE	40-70-8	0,62607	0,01548			

NS – Não significativo, * p<0,05, **p<0,01

Tabela 3.2 - Avaliação estatística do índice kappa resultante da classificação da rede FBR em duas situações: com dados completos e duas falhas simuladas.

Classificador	Arquitetura	\hat{k}	$\text{vâr}(\hat{k})$	Análise	Z	p
1 – 1ª falha	40-70-8	0,46605	0,01557	3 vs 1	0,5927NS	0,2766
2 – 2ª falha	40-70-8	0,54123	0,0173	3 vs 2	0,6170NS	0,4326
3 – FBR	40-70-8	0,57252	0,01669			

NS – Não significativo, * p<0,05, **p<0,01




Fig 3.6 – Resultados das classificações da rede PMC de retropropagação do erro com padrão completo (A) e primeira falha (B). Rede FBR com padrão completo (C) e primeira falha (D).

4. Conclusões

A classificação espectro-temporal das culturas agrícolas mostrou-se como uma abordagem promissora para esses alvos dinâmicos. Diante da falha de dados, ambos os modelos de redes tiveram queda no valor de kappa, embora não significativo. Apesar de não existir queda acentuada do kappa, a análise visual permitiu verificar que o mapa final ficou mais ruidoso e a classe sorgo desapareceu. Essa metodologia teve como foco principal a safra de verão, em que o início de plantio é determinado pelas chuvas, e cujos polígonos têm idade fenológica mais homogênea, mas com grande limitação de dados ópticos por causa das nuvens.

5. Referências

- Badhwar, G.D.; Carnes, J.G.; Austin, W.W. Use of Landsat-derived temporal profiles for corn-soybean feature extraction and classification. **Remote Sensing of Environment**, v.12, n.1, p.57-79, 1982.
- Bishop, C.M. **Neural networks for pattern recognition**. 1ed., Oxford, New York, Oxford University Press, 1995, 482p.
- Gleriani, J.M. **Redes neurais na classificação espectro-temporal de culturas agrícolas**. 2004. 198 p.(no prelo). Tese (Doutorado em Sensoriamento Remoto) – INPE, São José dos Campos.
- Hall, F.G.; Badwar, G.D. Signature-extendable technology: global space-based crop recognition. **IEEE Transactions on Geoscience and Remote Sensing**, v.25, n.1. p.11-27, 1987.
- Hall, F.G.; Strebel, D.E.; Nickeson, J.E.; Goetz, S.J. Radiometric rectification: toward a common radiometric response among multitemporal, multisensor images. **Remote Sensing of Environment**, v.35, n.1, p.11-27, 1991.
- Ippoliti-Ramilo, G.A.; Epiphanyo, J.C.N.; Shimabukuro, Y.E. Landsat-5 Thematic Mapper data for pre-planting crop area evaluation in tropical countries. **International Journal of Remote Sensing**, v.24, n.7, p.1521-1534, 2003.
- 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.
- Murthy, C.S.; Raju, P.V.; Badrinath, V.S. Classification of wheat crop with multi-temporal images: performance of maximum likelihood and artificial neural networks. **International Journal of Remote Sensing**, v.24, n.23, p.4871-4890, 2003.
- Odenweller, J.B.; Johnson, K.I. Crop identification using Landsat temporal-spectral profiles. **Remote Sensing of Environment**, v.14, n.1, p.39-54, 1984.
- Paola, J.D.; Schowengerdt, R.A. A review and analysis of backpropagation neural networks for classification of remotely-sensed multispectral imagery. **International Journal of Remote Sensing**, v.16, n.16, p.3033-3058, 1995.
- Song, C.; Woodcock, C.E.; Seto, K.C.; Pax-Lenney, M.; 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.
- Zell, A.; Mamier, G.; Mache, M.V.N.; et al. **SNNS – Stuttgart Neural Network Simulator v.4.2, User Manual**, University of Stuttgart/ University of Tübingen, 338p. 1998.