

Classificação da vegetação de áreas úmidas baseada em redes neurais artificiais: estudo de caso da planície fluvial do alto rio Paraná

Fernanda Sayuri Yoshino Watanabe ¹

Nilton Nobuhiro Imai ²

Tiago Matsuo Samizava ²

Paulo Cesar Rocha ³

Universidade Estadual Paulista – FCT/UNESP

R. Roberto Simonsen, 305 – 19060-900 – Presidente Prudente - SP, Brasil

¹ Graduação em engenharia ambiental

² Programa de Pós-Graduação em Ciências

³ Departamento de Geografia

fernandasyw@yahoo.com.br; {nnimai, pcrocha}@fct.unesp.br; tiagosamizava@yahoo.com.br

Abstract. This work attempts to contribute to the understanding of the distribution of the vegetation covering on floodplain Paraná River. Those mappings were accomplished by the multi-source data, through the multispectral images of CCD-CBERS, integrated with topography data, texture and vegetation index (NDVI) extracted from multispectral images and the DEM (Digital Elevation Model) from SRTM mission (*Shuttle Radar Topography Mission*). There was geometric correction of the multispectral images and DEM, using the Mosaic *Geocover 2000* as reference. The atmospheric correction of multispectral images was done through the model of reflectance 5S, available in *Scoradis* software, using atmospheric data gotten from the MODIS sensor, TERRA platform. The adopted approach was based on the artificial neural network supervised classification with the *Backpropagation* algorithm, available in the *Idrisi* software. It is hoped that this work can contribute to the understanding of the distribution of vegetation covering lands of floodplains. The classification will be refined through the information extracted from multispectral images taken with airborne cameras of high spatial resolution.

Palavras-chave: artificial neural network, remote sensing, floodplain, redes neurais artificiais, sensoriamento remoto, planície de inundação.

1. Introdução

Áreas úmidas são áreas que são inundadas ou saturadas pelas águas superficiais ou subterrâneas com uma frequência e durações específicas, e que em circunstâncias normais apresenta uma vegetação tipicamente adaptada à vida no solo em condições saturadas (USACE & EPA apud VILLENEUVE 2005). Em geral, tais localidades são de difícil acessibilidade, o que torna o emprego de sensoriamento remoto adequado para análise da cobertura vegetal.

Nesse sentido, o objetivo desse trabalho é obter uma representação da distribuição espacial da cobertura vegetal da planície fluvial do alto rio Paraná, região Centro-Sul do Brasil, de modo que possa contribuir na análise da dinâmica da paisagem da planície estudada. A metodologia de classificação aplicada foi baseada em redes neurais artificiais, uma vez que se pretende integrar dados de natureza não espectral, ou seja, cuja função de distribuição de probabilidade dos dados não necessite ser conhecida. Para que o procedimento de classificação, bem como os parâmetros adotados possam ser aplicados em cenas de outros anos, de mesmo período, realizou-se um tratamento prévio para estimar os valores de fator de refletância real. Dentre os dados empregados na classificação estão as bandas 2, 3 e 4, do sensor CCD/CBERS-2, o DEM (Modelo Digital de Elevação) interferométrico, da missão SRTM, o NDVI (Índice de Vegetação da Diferença Normalizada) e o índice de textura. Assim, espera-se com o resultado deste trabalho venha a contribuir para o entendimento da distribuição da cobertura vegetal dessa planície fluvial.

2. Área de estudo

A área de estudo encontra-se na planície do alto rio Paraná, que compreende a região da foz do rio Paranapanema até Porto Guáira (Figura 1), definida pelas coordenadas UTM/WGS84 aproximadas: canto superior esquerdo: 173.900 E; 7.525.700 N; canto inferior direito: 322.300 E; 7.346.300 N. Neste trabalho foi analisado uma parte dessa região.

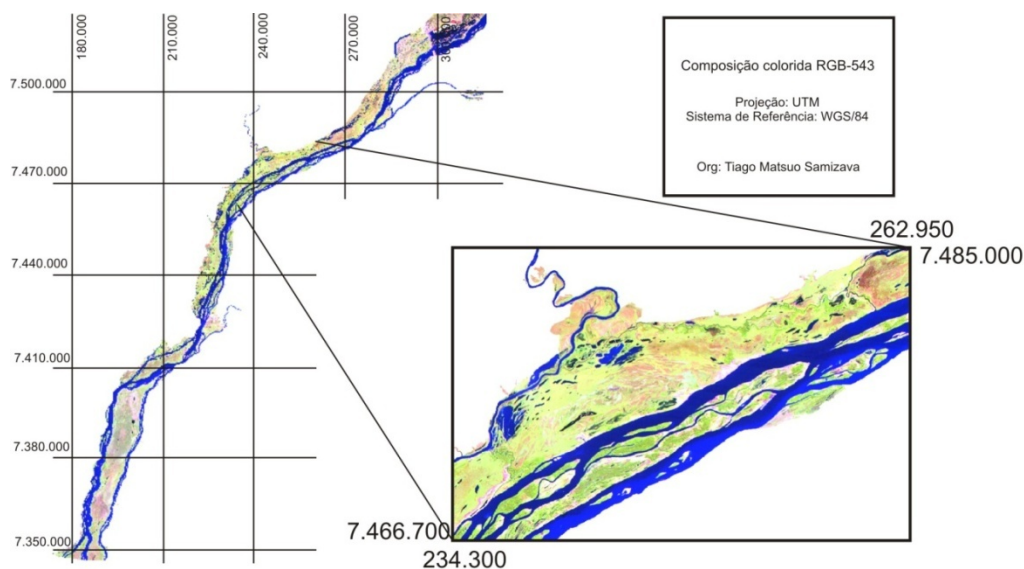


Figura 1. Área de estudo.

3. Metodologia de Trabalho

3.1 Materiais

Foram utilizados os seguintes materiais para realização desse trabalho:

- Software *Spring 4.3.3* para *Windows* (programa de domínio público, desenvolvido e distribuído pelo INPE), adquirido pelo site: www.dpi.inpe.br;
- Software *ENVI 4.4*;
- Imagens CCD/CBERS-2, adquiridas gratuitamente no site: www.dpi.inpe.br;
- Dados atmosféricos do sensor MODIS, obtidas gratuitamente no site: <http://ladsweb.nascom.nasa.gov/data/search.html>;
- DEM interferométrico gerado pelo sensor SRTM (*Shuttle Radar Topography Mission*), cujo download gratuito pode ser realizado no seguinte endereço eletrônico: <http://srtm.csi.cgiar.org/SELECTION/inputCoord.asp>;
- Mosaico *Geocover 2000*, adquiridas gratuitamente no site: <https://zulu.ssc.nasa.gov/mrsid>;
- Fotoíndice;
- Software *IDRISI 15.0*.

3.2 Metodologia

A seguir são apresentados os procedimentos adotados no presente trabalho.

3.2.1 Pré-processamento das imagens multiespectrais e do DEM/SRTM

3.2.1.1 Correção geométrica

O georreferenciamento das imagens foi realizado no software *Spring*. Como base de referência foi utilizada a imagem do mosaico *Geocover 2000*, que apresenta resolução espacial de 14,5 m e um erro médio quadrático de 50 m, considerado aceitável para os fins deste trabalho.

No processo de georreferenciamento da cena, adotou-se 8 pontos de controle, com erro médio quadrático máximo de 0,5 pixels. A transformação utilizada foi uma função de primeiro grau, com reamostragem dos pixels utilizando o interpolador vizinho mais próximo.

3.2.1.2 Correção radiométrica

O sistema computacional utilizado para a realização da correção atmosférica foi o *SCORADIS (Sistema de Correção Radiométrica de Imagens de Satélite)*, desenvolvido pelo CEPAGRI/UNICAMP (ZULLO, 1994), cuja função é realizar a correção radiométrica de imagens de satélite, apoiando-se na teoria e parâmetros atmosféricos calculados pelo Modelo de reflectância 5S (*Simulation du Signal Satellitaire dans le Spectre Solaire*) (TANRÉ *et al*, 1990).

Os dados utilizados foram adquiridos dos produtos MOD04 (dados de aerossóis) e o MOD07 (dados do perfil atmosférico, como concentração de vapor d'água e de ozônio) baseada na metodologia de Mercante (2007), ambos do sensor MODIS, plataforma TERRA.

3.2.1.3 Remoção de pixels externos à área de estudo das imagens

Foram eliminados das imagens multiespectrais e do DEM os pixels referentes aos corpos d'água e das áreas externas à planície de inundação, de modo a evitar sua classificação, muitas vezes errada, pela rede neural, a qual é ajustada para a cobertura da planície.

Para remoção das regiões não pertencentes à planície de inundação foi gerada uma máscara correspondente a essas áreas. A delimitação dessas regiões foi feita manualmente, baseada em imagem datada de 23 de fevereiro de 2007, período em que a planície se encontrava inundada, tornando possível a identificação das áreas externas a ela. Aos pixels dessa região externa foi atribuído o valor zero.

A delimitação dos corpos d'água foi obtida através de uma classificação, adotando o algoritmo não-supervisionado K-Médias. As imagens multiespectrais utilizadas são de 3 de julho de 2007, correspondentes ao período de seca na região da planície de inundação, quando o nível da água na planície se encontra baixo, de modo que somente os corpos d'água perenes são classificados, ou seja, as superfícies cobertas com água durante todos os períodos do ano, separando o que certamente não apresenta cobertura vegetal terrestre.

O produto final da classificação da água foi utilizado como máscara para remover as regiões cobertas com água das imagens, atribuindo a todos os pixels correspondentes a essas regiões o valor de brilho 255, aplicando-se um algoritmo em LEGAL. A atribuição desses valores para as regiões cobertas com água e não pertencentes à planície de inundação é feita para que o classificador por redes neurais possa discriminá-las em classes distintas.

3.2.1.4 Geração de NDVI e Índice de Textura

Buscando obter uma classificação da cobertura vegetal mais fiel foram integradas outras informações à resposta espectral das imagens CCD/CBERS.

Dessa forma, optou-se pela geração de um índice de vegetação e de textura buscando realçar as características biofísicas e captar a variabilidade espacial da cobertura vegetal na

planície, respectivamente. As informações de NDVI podem auxiliar no processo de seleção de amostras de treinamento da rede neural artificial, enquanto o índice de textura pode contribuir para melhorar a discriminação entre as classes.

O índice de vegetação utilizado foi o NDVI (Índice de Vegetação da Diferença Normalizada) (ROUSE et al, 1973 apud PONZONI, 2007), dada pela equação 5.1.

$$NDVI = (\rho_{ivp} - \rho_v) / (\rho_{ivp} + \rho_{ivp}) \quad (1)$$

onde:

ρ_{ivp} = reflectância no infravermelho-próximo;

ρ_v = reflectância no vermelho.

Para a geração do NDVI foi utilizado as bandas 3 e 4 do sensor CCD/CBERS-2, de 3 de julho de 2007, que correspondem ao vermelho e infravermelho próximo, respectivamente.

A imagem textura foi gerada a partir do cálculo do índice de fragmentação da paisagem, implementado no *IDRISI*, a partir da equação 5.2:

$$F = (n-1)/(c-1) \quad (2)$$

em que,

n = número de pixels com diferentes atributos (valores radiométricos atribuídos aos pixels) presentes em uma janela quadrada;

c = número de pixels da janela (9, 25, 49, ...).

O índice de fragmentação foi computado utilizando os mesmos critérios adotados por Galo (2000): imagem espectral referente ao infravermelho (banda 4, do sensor CCD/CBERS-2), e janela 3x3 para cálculo do operador de contexto. A imagem adotada é datada de 3 de julho de 2007, período de águas baixas dentro da planície, em que toda vegetação da planície se encontra visível.

O NDVI e a imagem textura foram normalizadas para o intervalo de 0-255. Essa normalização das entradas é necessária para a classificação por redes neurais.

3.2.1.5 Processamento do DEM/SRTM

Foram também integrados dados altimétricos do SRTM na classificação. O DEM/SRTM apresenta, originalmente, uma resolução espacial de 90m, sendo necessário compatibilizar a resolução espacial com os outros dados. Dessa forma, a superfície topográfica foi reamostrado para 20m utilizando o interpolador bilinear.

3.2.2 Classificação da vegetação por Redes Neurais Artificiais

Para a classificação foi adotado o algoritmo *Backpropagation* com inserção de termo *momentum*, que otimiza o processamento da rede, implementado no aplicativo *IDRISI*.

No treinamento da rede foi adotado uma taxa de aprendizado de 0,001 e um fator *momentum* de 0,5. A camada de entrada da rede apresenta 6 nós, referentes as 3 bandas do CCD/CBERS-2, ao NDVI, à imagem textura e ao DEM. A camada de saída foi definida com 6 nós, que correspondem as classes de informação adotadas, sendo elas: água, vegetação herbácea de solos úmidos, herbáceas de solo seco, vegetação arbórea, solo exposto e fundo da imagem (referente a nenhum tipo de cobertura da terra). Foram testadas arquiteturas com diferentes números de camadas e nós da camada escondida. A seleção da arquitetura neural mais adequada e do critério de parada do processo de treinamento foram determinados pela análise dos valores de erro médio quadrático e da acurácia do treinamento. Escolhida a melhor

estrutura e número de iterações da rede, foi feita a classificação da vegetação. Os pesos obtidos no treinamento foram salvos para serem utilizados em posteriores classificações de outras imagens.

4. Resultados e Discussão

A amostragem de treinamento foi realizada com informações de trabalhos anteriores na planície, bem como o registro fotográfico disponibilizado por Andrade (2008). Outra fonte de informações são as imagens disponibilizadas pelo software *Google Earth*, e imagens multiespectrais de alta resolução espacial que foram adquiridas de plataforma aérea recentemente.

Na etapa de seleção da arquitetura para a rede, a escolha da rede foi baseada nas seguintes características: simplicidade da arquitetura; gráfico de erro médio quadrático (EMQ) sem grandes flutuações; pouca diferença no erro médio quadrático entre os resultados das outras arquiteturas. Já como critério de parada do treinamento foi adotada uma taxa de acurácia de 95%.

Dentre as arquiteturas testadas, a que apresentou melhor desempenho foi a 6-9-6 (6 nós na camada de entrada, uma camada escondida com 9 nós, e 6 nós na camada de saída), com uma acurácia de 97,5%, um EMQ das amostras de treinamento de 0,001673 e para as de validação de 0,001555, empregando 10000 iterações.

Na Figura 2 apresenta-se o gráfico dos erros médio quadrático da amostragem de treinamento e validação.

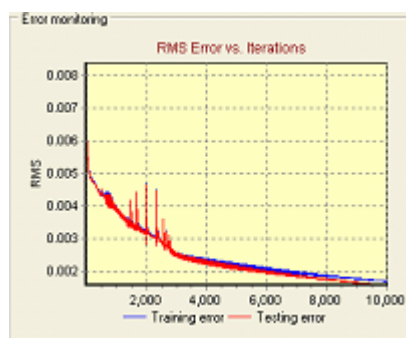


Figura 2 – Gráfico do EMQ dos padrões de treinamento e validação do treinamento.

Verifica-se, no gráfico do EMQ, que entre as amostras de treinamento (training error) e validação (testing error) ocorrem altas oscilações até, aproximadamente, a iteração 2500. Aumentando-se o número de iterações essa oscilação tende a diminuir e a curva dos erros tende a se estabilizar no final do treinamento.

A Figura 3 apresenta o resultado da classificação usando uma rede multi-layer perceptron (MLP), com seis dados de entrada, 9 nós na camada e escondida e seis classes de saída. O produto apresenta 4 classes de cobertura da terra, sendo elas vegetação arbórea, herbácea seca, herbácea úmida e solo exposto.

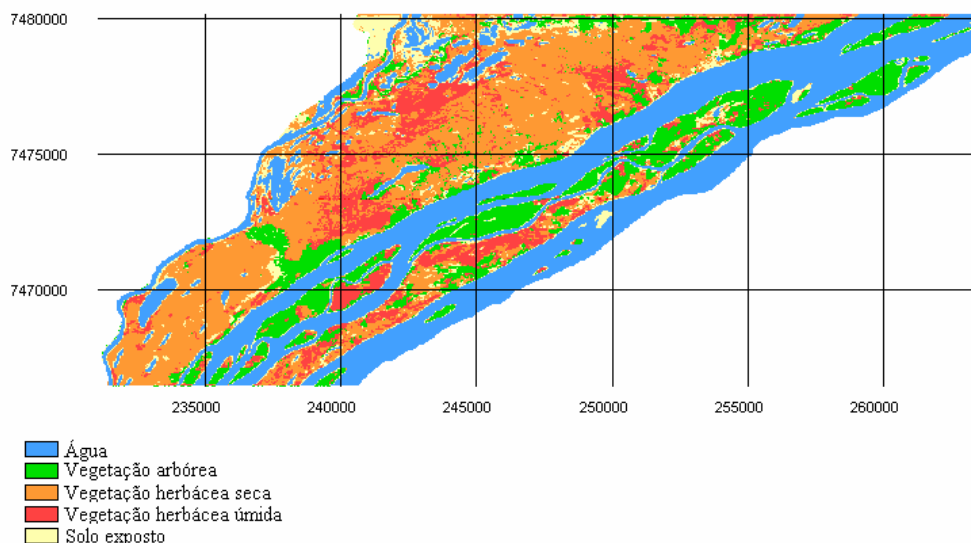


Figura 3 – Resultado da Classificação usando Redes Neurais Artificiais.

Analisando todos os dados de entrada utilizados na classificação da imagem, notou-se que a vegetação arbórea é a cobertura vegetal de mais fácil identificação, devido a sua localização espacial e a sua resposta espectral. Essas áreas normalmente ocorrem sobre os diques marginais ao longo dos canais, que possibilitam que espécies de grande porte possam se adaptar. Também se pode verificar que existe grande parte das ilhas que possuem vegetação de porte arbóreo.

Nota-se que a vegetação predominante na planície de inundação é do tipo herbáceo de áreas secas. As áreas de herbáceas de áreas úmidas estão localizadas em regiões mais baixas topograficamente, nas proximidades das lagoas e ressacos, além de algumas regiões das ilhas. O solo exposto encontra-se nas margens do rio Paraná, onde as ocupações antrópicas são mais intensas e alguns locais de leque de rompimento de dique. Os leques de rompimento de dique são locais de entrada preferencial das águas durante os pulsos de inundação. O solo exposto ainda pode ser encontrado em alguns locais das ilhas, que estão associados à ação antrópica, e nos rios, que são bancos de areia ou barras.

A estimativa de acurácia do mapeamento em relação à verdade terrestre, no entanto, ainda não foi realizada. Esse processo será realizado após os processamentos de ortorretificação das imagens aéreas de alta resolução adquiridas recentemente.

Mesmo não sendo ainda possível realizar a validação da classificação, a partir do fotoíndice foi feita uma verificação visual da classificação, como mostram as Figura 4, 5, 6 e 7. Nelas são apresentados alguns tipos de feições identificadas no fotoíndice e seu correspondente na imagem classificada.

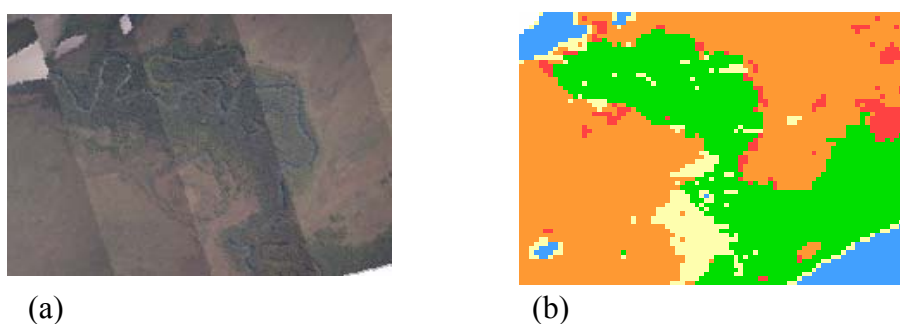


Figura 4 – Vegetação arbórea no (a) Fotoíndice; (b) Classificação.




Figura 5 – Vegetação herbácea seca no (a) Fotoíndice; (b) Imagem classificação.




Figura 6 – Vegetação herbácea úmida no (a) Fotoíndice; (b) Classificação.




Figura 7 – Solo exposto no (a) Fotoíndice; (b) Classificação.

Os tipos de cobertura que notou-se maiores problemas de classificação foram as coberturas de herbáceas de área seca (confundida com herbácea de área úmida) e o solo exposto (classificado como herbácea, tanto de área seca como de úmida). Visualmente as coberturas vegetais mais bem identificadas pela rede foram às áreas de vegetação arbórea e as herbáceas de área úmida.

5. Conclusões

A representação espacial da cobertura vegetal mapeada na planície de inundação do alto rio Paraná contribui para entender os processos de conectividade da vegetação ripária, bem como os processos ecológicos e geomorfológicos do sistema fluvial. Os relacionamentos da vegetação com os processos de inundação, recorrentes na área de estudo, podem auxiliar um melhor entendimento conceitual da distribuição espacial dos tipos de classes de cobertura vegetal. A representação da cobertura vegetal também serve como base para verificar as atuais ações antrópicas nesse trecho da planície.

Em relação aos processamentos, a partir dos resultados obtidos, verificou-se um bom potencial das redes neurais artificiais para classificação dos dados multifonte, na identificação dos padrões da vegetação, presentes na planície fluvial do alto rio Paraná. Quanto ao DEM/

SRTM, devido à baixa resolução espacial da imagem (90m) em relação à das imagens multiespectrais CCD/CBERS-2 (20m), o seu emprego teve uma baixa contribuição na classificação.

O atributo NDVI não contribuiu para melhorar a classificação, mas facilitou a seleção de elementos da amostra de treinamento.

Os dados de textura contribuíram pouco para aprimorar a classificação da vegetação. Nesse sentido, busca-se outras fontes de dados que possam ser integradas no processo de classificação, que sejam menos correlacionados com as bandas do visível, como as imagens do infravermelho médio, por exemplo, a banda 5, dos sensores TM e ETM+, dos satélites da série Landsat, sensível a variações de umidade, uma vez que é uma característica essencial na formação da vegetação característica em uma planície de inundação.

Quanto à classificação, o erro médio quadrático (EMQ) e a acurácia apresentaram consistência, entretanto, esses valores devem ser melhor avaliados uma vez que ainda não foi realizada a validação.

Por fim, verificou-se que o classificador empregado para discriminar a cobertura vegetal de planícies de inundação, baseada em redes neurais, mostrou-se adequada, uma vez que permitiu integrar dados multifonte. Essa abordagem de classificação também poderá ser realizada em imagens de outros anos, do mesmo período sazonal, utilizando os mesmos pesos do treinamento da rede neural apresentada neste trabalho.

Agradecimentos

Os autores deste trabalho agradecem ao CNPq pela concessão de uma bolsa de iniciação científica e suporte financeiro decorrente do projeto CT-Hidro “Hidrodinâmica, ritmo climático e zoneamento de áreas alagáveis na planície fluvial do alto Rio Paraná, Centro-Sul do Brasil”, processo nº 555608/2006-9.

Referências Bibliográficas

Andrade, I. R. **Dinâmica de inundação de áreas sazonalmente alagáveis na planície aluvial do alto rio Paraná**. 2008. 60 f. Dissertação (Mestrado em Ecologia de Ambientes Aquáticos) – Universidade Estadual de Maringá – Maringá.

Galo, M. L. T. **Aplicação de redes neurais artificiais e sensoriamento remoto na caracterização ambiental do parque estadual morro do diabo**. 2000. 197f. Tese (Doutorado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

Mercante, E. **Dinâmica espectral da cultura da soja ao longo do ciclo vegetativo e sua relação com a produtividade na região oeste do Paraná**. 2007. 221f. Tese (Doutorado em Engenharia Agrícola) – Universidade Estadual de Campinas, Campinas.

Ponzoni, F. J.; Shimabukuro, Y. E. **Sensoriamento no estudo da vegetação**. 1ª Edição. São José dos Campos: Parênteses, 2007.

Tanré, D. et al. Description of a computer code to simulate the satellite signal in the solar spectrum: the 5S code. **International Journal of Remote Sensing**, v.11, p.659-668, 1990.

Zullo Junior, J. **Correção atmosférica de imagens de satélite e aplicações**. 1994. 190f. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual de Campinas, Campinas.

Villeneuve, J. **Delineating wetlands using geographic information system and remote sensing technologies**. 2005. 88f. (Master of Science). Texas A&M University.