

Utilização de Redes Neurais Artificiais na classificação da cobertura da terra na área de influência do reservatório de Porto Colômbia em 1987 e 2009

Juliane Jussara Affonso ¹
Maria de Lourdes Bueno Trindade Galo ²

Universidade Estadual Paulista – UNESP
Faculdade de Ciências e Tecnologia – FCT

¹Bolsista PIBIC/CNPq
juliane_affonso@hotmail.com

²Departamento de Cartografia
Caixa Postal 467 - 19060-900 – Presidente Prudente - SP, Brasil
mlourdes@hotmail.com

Abstract. In past few years, infestations of aquatic plants in reservoirs have been studied as an effect of the environmental unbalance caused by pollution and damming of rivers. The excessive amount of aquatic plants and algae in the water is strongly dependent on human occupation in its surroundings, which makes navigation and the production of electricity difficult. To evaluate this condition, the technology of remote sensing could provide a valuable tool in use mapping and land cover in the surroundings in the water. So, this research aimed at verifying the influence of the spatial resolution of multispectral images in the detection and mapping of land cover in the area of the reservoir of Porto Colombia, using multitemporal analysis procedures and supervised classification by artificial neural networks (RNA). In the classification of these images, the input data was constituted by images TM /Landsat, an hypsometric image derived from SRTM data and a texture image derived from TM4/Landsat. Different architectures of neural networks were trained from samples collected at the scene TM/Landsat and network architecture that resulted in the lowest training error was adopted in the individual classification of image. Furthermore, an analysis was made comparing classified images by using cross tabulation, which permits comparing the results obtained in different times. The methodological adopted was adequate to map land cover classes, permitting a effective spectral recognition of the samples.

Palavras-chave: artificial neural networks, image classification, land cover mapping, remote sensing, redes neurais artificiais, classificação automática, mapeamento da cobertura da terra, sensoriamento remoto.

1. Introdução

No Brasil, lagos e rios são importantes no fornecimento de água e suporte a sistemas de produção agrícola e industrial, assim como para o consumo humano, navegação, irrigação, geração de energia elétrica, entre outros. No entanto, décadas de desmatamento indiscriminado e uso inadequado da terra estimularam o carregamento de material sedimentável e nutrientes para o leito dos rios e reservatórios que, aliado a grande carga de esgotos residenciais e industriais, têm levado cursos e reservatórios de água, naturais ou artificiais, a uma condição de desequilíbrio, caracterizados pela grande disponibilidade de nutrientes que acelera o crescimento de vegetação aquática indesejável (CAVENAGHI, 2003) e floração de algas.

Desse modo, a presença maciça de plantas aquáticas e algas em corpos d'água está fortemente condicionada à ocupação antrópica em seu entorno, especificamente aqueles relacionados com o lançamento de dejetos orgânicos, erosão urbana e agrícola, sedimentação que ocorre nas margens e nas áreas de ingresso de tributários nos reservatórios, entre outros. Para avaliar essa condição, a tecnologia do Sensoriamento Remoto pode se constituir numa ferramenta valiosa no mapeamento e monitoramento do uso e cobertura da terra no entorno de corpos d'água, fornecendo subsídios para o efetivo manejo dessas áreas, considerando a

variedade de tipos e graus de intervenção antrópica identificados na área de influência dos reservatórios.

Os sistemas de sensoriamento remoto têm sido amplamente utilizados no mapeamento da cobertura terrestre e no monitoramento dos recursos naturais. Isto se deve ao fato de que os dados obtidos a partir de satélites propiciam coberturas repetitivas da superfície terrestre em intervalos de tempo relativamente curtos. Destaca-se também a possibilidade de processamento rápido desses dados através de técnicas de análise possibilitadas pelos sistemas computacionais (VILELA et al., 2000).

Com vistas a avaliar o comportamento temporal da ocupação do solo no entorno do Reservatório de Porto Colômbia, caracterizado por intensa atividade agrícola e ocorrência maciça de plantas aquáticas, foram integradas informações extraídas de imagens multiespectrais orbitais com dados de elevação do terreno e realizado o mapeamento da cobertura da terra no entorno da área de interesse. Para realização desse mapeamento foram utilizadas estruturas computacionais denominadas Redes Neurais Artificiais (RNA's) na classificação de imagens tomadas em duas diferentes épocas. Na definição de uma arquitetura de pesos ajustados que permitisse a classificação das imagens multitemporais, foi usada como referência a imagem mais recente. No que se refere à classificação de imagens, a utilização de RNA's tem se apresentado com uma alternativa vantajosa em relação aos classificadores supervisionados baseados em conceitos estatísticos, uma vez que os modelos de redes neurais artificiais possibilitam a incorporação não apenas dos dados multiespectrais, mas de dados adquiridos por outras fontes, que não apresentem natureza espectral (ESPINHOSA, 2004).

O Reservatório de Porto Colômbia localiza-se na divisa entre os estados de São Paulo e Minas Gerais e caracteriza-se pela intensa ocupação agrícola no seu entorno e, conseqüentemente, alta carga de nutrientes que afeta a qualidade da água e definem um ambiente favorável para a proliferação de plantas aquáticas e fitoplâncton.

O objetivo do presente artigo é apresentar os resultados obtidos mediante a aplicação de uma RNA na classificação supervisionada de imagens de Sensoriamento Remoto tomadas em duas épocas distintas, integradas a dados de elevação, com vistas ao monitoramento da cobertura da terra na área de influência do Reservatório de Porto Colômbia.

2. Redes neurais artificiais na classificação de imagens de satélite

Classificação constitui um conjunto de métodos usados para rotular pixels ou regiões de uma cena a partir de suas características espectrais, sendo esta categorização implementada por um programa computacional habilitado a reconhecer os pixels (ou regiões) espectralmente similares (RICHARDS & JIA, 1999). Para Schowengerdt (2007), classificação é o processo de extração de informação de imagens com a finalidade de reconhecer padrões e objetos homogêneos. A discriminação e posterior reconhecimento desses padrões são possíveis pelo fato de os diferentes alvos da superfície terrestre apresentarem um comportamento espectral específico.

Para a análise de dados multiespectrais, RICHARDS & JIA (1999) destacam dois procedimentos abrangentes de classificação: não-supervisionado e supervisionado. O método supervisionado se constitui na ferramenta analítica essencial usada na extração da informação quantitativa a partir de dados multiespectrais. O processo é dito supervisionado pois implica na interação entre o intérprete humano e o sistema de análise, possibilitando o treinamento do algoritmo de classificação, a partir de amostras usadas para caracterizar ou estimar parâmetros estatísticos para cada classe. Essas amostras (que correspondem a padrões conhecidos das classes) são normalmente chamadas de padrões de treinamento, sendo que sua totalidade define o conjunto de treinamento (GONZALES & WOODS, 2000).

As RNA são baseadas em modelos abstratos do funcionamento do cérebro humano e tentam reproduzir sistemas biologicamente realísticos. Estas redes são organizadas em

camadas (Figura 1), que compõem sua topologia ou arquitetura. Podem ser definidas redes neurais de camada simples (*perceptron*), constituídas por um grupo de neurônios arranjados em apenas uma camada ou redes multicamadas, formadas por uma ou mais camadas intermediárias ou pela combinação de várias redes de camadas simples (VENTURIERI & SANTOS, 1998). Assim, a topologia de uma rede refere-se à maneira como os elementos de processamento são organizados, o que afeta o desempenho da rede, uma vez que sua estrutura está intimamente ligada ao algoritmo de aprendizado usado na fase de treinamento.




Figura 1 - Arquitetura de uma RNA multicamadas.

Conforme Lippmann (1987), os elementos de processamento da rede são conectados através de pesos e cada nó produz um somatório das várias entradas, ponderadas pelos pesos de suas respectivas conexões, passando o resultado através de uma função de decisão, cujo limiar interno e tipo de função é que caracterizam os nós.

Segundo Galo (2000), o processo de treinamento de uma rede multicamadas, realizado usualmente por um algoritmo que possibilite a retropropagação do erro (*backpropagation*), começa com a definição de um conjunto arbitrário de pesos para as conexões da rede e envolve duas fases distintas. Na primeira, um par constituído pelo vetor de entrada associado à respectiva saída desejada é apresentado à primeira camada da rede e propagado através de suas camadas para computar uma saída para cada elemento de processamento. As saídas dos nós da última camada são, então, comparadas com as saídas desejadas e, a partir disso, são calculados os termos de erro. A segunda fase envolve uma retro-propagação desse erro a partir da última camada, durante a qual parte do erro é repassado para cada elemento de processamento e os pesos correspondentes são convenientemente alterados. Em um treinamento bem sucedido, o erro diminui com o aumento do número de iterações e o procedimento converge para um conjunto estável de pesos.

A utilização de uma RNA implica em modelar adequadamente a aplicação, a partir da identificação das variáveis de entrada que melhor representam o fenômeno a ser mapeado. Assim, cada abordagem de classificação demanda diferentes arquiteturas de rede e parâmetros de treinamento, cuja definição influencia nos resultados de saídas, obtendo diferentes modelagens das classes de interesse.

3. Material e Método

3.1 Área de estudo

A área de estudo refere-se a uma região no entorno do Reservatório de Porto Colômbia, localizado na Região Sudeste, na divisa entre os estados de São Paulo e Minas Gerais.

Posiciona-se geograficamente entre as coordenadas 19° 50' 3,21'' a 20° 22' 39,47'' de latitude Sul e 48° 09' 28,55'' a 48° 47' 26,92'' de longitude Oeste. A região se caracteriza pela intensa ocupação agrícola no seu entorno e, conseqüentemente, alta carga de nutrientes que afeta a qualidade da água e define um ambiente favorável para a proliferação de plantas aquáticas e algas.

3.2 Material

Para o desenvolvimento do projeto foram utilizadas imagens multiespectrais do satélite Landsat 5, sensor Thematic Mapper (TM), georreferenciadas ao sistema UTM/WGS-84, adquiridas gratuitamente do catálogo imagens do INPE (<http://www.dgi.inpe.br/CDSR/>). As cenas selecionadas referem-se a duas datas de passagem: julho de 1987 e julho de 2009 e às bandas espectrais TM2, TM3, TM4 e TM5, de cada data.

Além das imagens multiespectrais, foram também utilizados dados do SRTM (*Shuttle Radar Topography Mission*) obtidos através do *download* das cartas 22-X-B e a carta 22-Z-D, da página <http://www.relevobr.cnpm.embrapa.br/download/index.htm>.

Para o processamento e análise das imagens e dados foram utilizados os aplicativos SPRING versão 5.0.6 e Idrisi Andes (Clark, 2006).

3.3 Metodologia

A abordagem proposta neste estudo foi aplicada a área do entorno do reservatório de Porto Colômbia, realizando-se o mapeamento da cobertura da terra, mediante a utilização de uma mesma arquitetura treinada de rede neural artificial para a classificação individual de duas cenas, uma obtida em 1987 e outra em 2009. A RNA foi treinada a partir da imagem mais recente.

Para a realização da classificação, os dados de sensoriamento remoto foram submetidos aos pré-processamentos necessários para que a rede fosse capaz de reconhecer as mesmas classes nas imagens multiespectrais e multitemporais, ou seja, normalização radiométrica e registro geométrico.

Para inserir a informação de altitude no processo de classificação pela RNA, foi gerada uma imagem hipsométrica através dos dados SRTM, produzindo uma visão pictórica de um modelo digital de elevação, ao qual se aplicou um fatiamento, onde a cota mínima corresponde a 400 metros e a cota máxima a 700 metros, num intervalo de 20 em 20 metros.

Além de uma imagem temática contendo classes altimétricas, também foi gerada uma imagem de textura. Para tal, foi usado um operador de contexto que calcula um índice numérico com base na variabilidade espacial observada em uma janela de 5x5 pixels. A operação foi aplicada à banda do infravermelho próximo (TM4/Landsat), devido a sua aparente superioridade em representar as variações espaciais na vegetação, para cada data de passagem.

Segundo as considerações de Hush e Horne (1993) citados por Galo et al. (2000), e outros autores que descreveram os aspectos teóricos ou a aplicação de redes neurais artificiais na classificação de dados de sensoriamento remoto e tendo em vista a abordagem de classificação supervisionada pretendida, foi adotado um modelo de rede neural com estrutura de múltiplas camadas, treinada com algoritmo *backpropagation*. Como a proposta do trabalho é aplicar uma rede neural artificial para discriminar os tipos de cobertura da terra identificados na área de interesse, várias arquiteturas de rede foram definidas e treinadas.

A definição de uma arquitetura de rede neural multicamadas que seja adequada para classificar um conjunto de dados específicos implica em determinar previamente a dimensionalidade dos dados de entrada e das classes de interesse, os quais especificam, respectivamente, o número de elementos de processamento das camadas de entrada e de saída da rede.

Assim, para a classificação pela RNA utilizando o aplicativo Idrisi, foi necessário definir os dados de entrada e as classes de saída a ser mapeadas. Os dados de entrada utilizados foram as bandas espectrais TM2, TM3, TM4 e TM5 das imagens TM/Landsat georreferenciadas; a imagem representando classes de hipsometria da área de estudos e as imagens de textura produzidas a partir da banda TM4. Como classes de saída foram definidas as seguintes ocorrências: Água, Mata, Pastagem, Área Impermeável, Cultura Agrícola (1 e 2, discrimináveis espectralmente em função do seu estágio de desenvolvimento) e Solo Preparado (1 e 2, diferenciados pelo maior ou menor teor de umidade).

Para dimensionar o número de camadas escondidas e o número de nós de cada camada intermediária foram realizadas simulações com diferentes arquiteturas de redes neurais, baseadas em trabalhos anteriores e em processo de tentativa e erro, sendo posteriormente selecionada e aplicada na classificação, tanto para a imagem de referência como para a cena de 1987, a arquitetura que resultou em menor erro de treinamento.

Os mapas temáticos gerados para 1987 e 2009, foram submetidos a uma operação de tabulação cruzada, possibilitando a comparação entre as mudanças temporais ocorridas na área, a partir de uma matriz de transição espaço-temporal contendo o grau de concordância entre as mesmas classes das duas datas, e permitindo inferir as principais mudanças na paisagem que ocorreram no período.

4. Resultados e Discussão

Especificados os dados de entrada e saída da rede, uma arquitetura parcial para a RNA foi definida considerando o número de elementos de processamento da camada de entrada (6 nós) e o número de unidades de processamento de saída (8 nós). As simulações foram realizadas utilizando diferentes arquiteturas de rede, de forma a identificar uma configuração adequada para representar as classes de interesse.

Para especificar cada arquitetura de rede treinada adotou-se o seguinte critério: [número de nós na camada de entrada – número de nós da primeira camada escondida – número de nós da segunda camada escondida – número de nós na camada de saída]. Os parâmetros adotados nas simulações e os resultados quanto ao erro médio quadrático (EMQ – taxa de variação adimensional) e a taxa de acurácia do treinamento são mostrados na Tabela 1.

Tabela 1 - Resumo das simulações realizadas para o treinamento da rede.

Arquitetura da RNA	Taxa de aprendizado	Iterações	Momentum	EMQ		Taxa de acurácia (%)
				Treinamento	Teste	
6-7-11-8	0.01	10000	0.5	0.001199	0.001497	93.38
6-9-21-8	0.01	10000	0.5	0.001191	0.001465	93.88
6-3-5-8	0.01	10000	0.5	0.001676	0.001701	91.38
6-7-8	0.01	10000	0.5	0.001601	0.001627	93.75

A RNA que apresentou melhor desempenho, em termos EMQ e taxa de acurácia, foi uma rede com duas camadas escondidas, nove neurônios na primeira, vinte e um na segunda camada e oito neurônios na saída. Outros parâmetros definidos foram: taxa de aprendizado da rede de 0,01; fator de *momentum* de 0,5 para agilizar na convergência da rede; e constante de sigmóide de 1. Como critério de parada do treinamento da rede foi estabelecido erro médio quadrático (EMQ) de 0,0001 ou 10.000 iterações. A parada do treinamento da RNA aconteceu pelo número de iterações do algoritmo *backpropagation*, resultando em um valor

de EMQ de 0,001191, para os dados de treinamento, e 0,001465 para os dados de teste para a arquitetura [6-9-21-8].

A Figura 2 mostra, lado a lado, uma composição colorida das bandas TM3, TM4 e TM5, associadas às cores azul, verde e vermelho, respectivamente, e a classificação obtida mediante a aplicação da arquitetura [6-9-21-8] à cena de 1987, enquanto na Figura 3, são mostradas as mesmas imagens referentes a 2009.




Figura 2 - Composição colorida RGB345, e a classificação obtida a partir da arquitetura [6-9-21-8] aplicada à imagem de 1987.




Figura 3 - Composição colorida RGB345, e a classificação obtida a partir da arquitetura [6-9-21-8] aplicada à imagem de 2009.

Na cena classificada referente à época de 2009 é possível observar que há uma predominância de culturas agrícolas quando comparado à classificação de 1987, na qual se percebe maior ocorrência dos vários tipos de solo preparado, alguns deles se confundindo com área impermeável e, infere-se, sobrepondo as áreas de pastagem nessa data. Percebe-se também que apesar da presença de pequenas áreas de pastagem em 2009, na classificação de 1987 a classe pastagem quase não aparece nessa data.

Em termos gerais, as classificações obtidas foram consideradas satisfatórias, pois possibilitaram discriminar todas as classes de saída pré-estabelecidas e obter uma imagem classificada compatível à realidade. Comparando a composição colorida e o resultado da classificação, percebe-se a consistência entre as variações espectrais na imagem e os tipos de cobertura da terra mapeados e, em termos temporais, o aumento considerável em áreas de cultura agrícola no entorno de reservatório de Porto Colômbia. Ressalta-se, porém, que o fato

das classes terem sido definidas com base na situação mais recente (imagem de 2009), a terminologia adotada para as classes e mesmo sua própria representação, pode resultar em inconsistências na classificação de 1987, como ocorre para os tipos de solo preparado e pastagem.

Na Tabela 2 é apresentada a matriz de transição espaço-temporal resultante da tabulação cruzada entre as cenas classificadas de 2009 e 1987. Nessa matriz, as colunas indicam o número de pixels inseridos em cada tipo de cobertura, a partir da classificação de 2009 e nas linhas o resultado para 1987. A diagonal principal da matriz contém o número de pixels que se mantiveram na mesma classe nas duas datas de tomada das imagens.

Tabela 2 - Tabulação Cruzada entre as imagens classificadas de 2009 e 1987.

TABULAÇÃO CRUZADA DA CLASSIFICAÇÃO DE 2009 (COLUNAS) E A CLASSIFICAÇÃO DE 1987 (LINHAS)									
Classes	Corpo d' água	Mata	Pastagem	Solo Preparado 1	Solo Preparado 2	Área Impermeável	Cultura Agrícola 1	Cultura Agrícola 2	Total
Corpo d' água	245721	16682	14493	1693	5800	21807	11793	12240	330229
Mata	16	2308	1029	505	741	619	3362	538	9118
Pastagem	175	5745	7045	1135	4233	2257	13169	3671	37430
Solo Preparado 1	0	1	138	8	47	20	219	31	464
Solo Preparado 2	3130	166679	507291	132419	377678	173265	676220	171877	2208559
Área Impermeável	12924	178688	468307	70325	131886	251796	338099	87653	1539678
Cultura Agrícola 1	52	390	3427	3442	4285	1922	16573	1144	31235
Cultura Agrícola 2	944	35230	12168	7847	11080	7917	40985	16012	132183
Total	262962	405723	1013898	217374	535750	459603	1100420	293166	4288896

De acordo com a Tabela 2 é possível observar que na classe 1 (Água), o número de pixels classificado nas duas imagens permaneceu praticamente similar, reiterando a facilidade de discriminar essa classe. No que se refere a classe Pastagem, o número de pixels da imagem referente à 2009 foi superior ao número de pixels classificado na imagem referente à 1987, diferentemente das classes 4 e 5 (Solo Preparado 1 e Solo Preparado 2), onde tiveram maior classificação na imagem de 1987 quando comparada à cena de 2009, o mesmo ocorre para classe 6 (Área Impermeável). Como já destacado, há significativo aumento na ocupação da área por culturas agrícolas.

5. Conclusões

A aplicação de redes neurais artificiais para mapeamento na cobertura da terra, utilizando como dados de entrada as bandas espectrais TM/Landsat, dados de altimetria (derivados do SRTM) e textura, apresentou resultados satisfatórios, permitindo uma boa separação espectral de todas as classes pré-definidas. Por outro lado, quando o treinamento é feito com base na imagem mais recente e são utilizadas muitas classes que apresentam similaridade na resposta espectral, é necessário um esforço considerável na definição das próprias classes e sua denominação para evitar situações contraditórias e, evidentemente, na aquisição de dados de treinamento. A classificação de 1987 mostrou a predominância de solo preparado que, eventualmente, seria melhor rotulado como solo exposto ou pastagem. Essa mesma classificação de 1987 apresentou um excesso de áreas impermeáveis, insistência que pode decorrer de amostra de treinamento pouco representativa para essa data, já que foram coletadas na cena de 2009. De qualquer modo, é inegável a intensa predominância de áreas agrícolas em 2009, comparado a 1987.

Face aos resultados obtidos, considerou-se que as imagens orbitais multiespectrais constituem uma fonte de dados útil para representar espacialmente os tipos de cobertura da terra na área de estudos, e que o uso de estruturas de Redes Neurais Artificiais treinadas com base na cena de 2009, permitiu mapear as mesmas classes em uma imagem obtida em 1987. Assim, mesmo com algumas inconsistências na classificação de 1987, verificou-se grande incremento nas áreas de cultura agrícola no entorno do reservatório, no período de tempo considerado.

Agradecimentos

Ao CNPQ pela concessão de uma bolsa de Iniciação Científica – PIBIC para desenvolvimento da pesquisa. Ao Departamento de Cartografia pela disponibilidade do software IDRISI Andes.

Referências Bibliográficas

CAVENAGHI, A. L. **Caracterização da qualidade da água e sedimento relacionados com a ocorrência de plantas aquáticas em cinco reservatórios da bacia do rio Tietê**, 2003, 73 f. Tese (Doutorado em Agronomia - Proteção de Plantas) – Faculdade de Ciências Agrônomicas, Universidade Estadual Paulista “Julio Mesquita Filho”, Botucatu.

ESPINHOSA, M. C. **Utilização do Sensoriamento Remoto Orbital e Redes Neurais Artificiais no mapeamento de macrófitas aquáticas emersas em grandes reservatórios**. 2004. Dissertação (Mestrado em Ciências Cartográficas) – Faculdade de Ciências e Tecnologia. Universidade Estadual Paulista “Júlio Mesquita Filho”, Presidente Prudente.

GALO, M. L. B. T. **Caracterização Ambiental do Parque Estadual Morro do Diabo através de dados e técnicas de Sensoriamento Remoto: Abordagens utilizando redes neurais artificiais**. 2000. 205f. Tese (Doutorado em Ciências da Engenharia Ambiental) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

GONZALEZ, R. C.; WOODS, R. E.. **Processamento Digital de Imagens**. São Paulo: Edgard Blücher, 2000. 717p.

LIPPMANN, R. **PAn introduction to computing with neural nets**. IEEE ASSP Magazine, v.4, p. 4-22, 1987.

RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis: an introduction**. 3. ed. New York: Springer-Verlag, 1999.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. 3. ed. San Diego: Elsevier, 2007.

VENTURIERI, A.; SANTOS, J. R. **Técnicas de Classificação de Imagens para Análise de Cobertura Vegetal**. In: ASSAD, E. D.; SANO, E. E., eds. Sistema de Informação Geográfica: Aplicações na Agricultura. Brasília: DF. Embrapa – SPI/Embrapa- CPAC, 1998. p 351-371.

VILELA, M. F. et al. **Avaliação de técnicas de realce e classificação digital na elaboração de um mapa de uso da terra mediante uma imagem TM/LANDSAT-5**. Revista Árvore, Viçosa, v. 24, n. 2, p. 161-173, 2000.