

UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS NA SEPARAÇÃO DE UNIDADES FISIONÔMICAS (PAISAGEM) MEDIANTE IMAGENS ORBITAIS E DADOS COMPLEMENTARES

Ribeiro, S. R. A., Centeno, J. A. S.

Depto. de Geomática, Universidade Federal do Paraná - www.geomatica.ufpr.br - (selmar@ufpr.br, Centeno@ufpr.br)

RESUMO - Com o propósito de classificar digitalmente, automaticamente unidades fisionômicas, o presente estudo utiliza metodologia de redes neurais artificiais (RNA) para a integração de dados originários do sensoriamento remoto (SR), de imagens digitais (ID) e informações a respeito dos agentes formadores das paisagens, tais como o relevo e a rede de drenagem. O SR, por meio de ID, tem sido, nas últimas décadas, uma das técnicas utilizadas para suprir a escassez de mapeamentos temáticos, utilizando as técnicas convencionais de classificação paramétricas. Para a separação de fisionomias (unidades de paisagem) esta classificação não permite a integração de informações de diferentes origens e escalas, associação esta importante para que se possa classificar tais fisionomias, haja vista que a compreensão da estrutura, caracterização e delimitação das paisagens demandam uma abordagem interdisciplinar. Ainda pode-se salientar que a utilização de metodologias embasadas na imitação do raciocínio do comportamento humano e a integração de dados complementares associados a imagens orbitais procuram executar uma classificação digital levando em consideração os elementos de formação das paisagens, assim como o ser humano intuitivamente classifica uma cena por meio destes elementos formadores das paisagens, gerando produtos subjetivos. Sendo a separação destas unidades fisionômicas automática, pode-se minimizar a subjetividade que cada analista utiliza em sua interpretação sobre características únicas da paisagem (fisionomias). Pode-se afirmar que com a técnica das RNA foi possível a separação das unidades fisionômicas, e que esta permitiu a associação de dados de diferentes origens e escalas. Para esse estudo as informações mais relevantes, associadas às ID, foram o relevo, representado pelo modelo digital do terreno (MDT), a rede de drenagem, discriminadas por meio das micro bacias e a imagem gerada a partir do levantamento por SR passivo, do elemento radioativo Potássio (K).

ABSTRACT - The present study uses the technique of artificial neural networks for the integration of data from remote sensing, digital images and information regarding the landscape formation agents, such as relief, drainage net. Remote Sensing images have been, in the past decades, used to fulfill the lack of thematic data, through common classification parametric techniques. However, the Integration of information from different origins and scales is not possible with that technique, since an understanding of the structure, characterization and delimitation of the landscape demands an interdisciplinary. The use of a methodology based on the simulation of the reasoning of the human being behavior and the integration of data attempts to perform a digital classification considering the forming elements of landscape similarly to how a human being intuitively would classify a scene, generating subjective products. Since the detection of these physiognomic units is automatic, one can lower the subjectivity level on how an analysis would be made, based on the landscape unique characteristics (physiognomies). With the aid of the technique of artificial neural networks, the separation of the physiognomic units was possible, which allowed the association of data from different origins and scales, in these study, the most relevant information associated to the digital images was relief, represented by the digital terrain model, drainage, discriminated by the micro basins and the element Potassium image.

PALAVRAS CHAVE: Sensoriamento Remoto, Redes Neurais Artificiais, Integração de Dados.

1 INTRODUÇÃO

Nas duas últimas décadas o sensoriamento remoto (SR) tem sido a principal fonte de informação temática

para as escalas 1:70.000 à 250.000. A extração de informação baseia-se em algoritmos paramétricos, tentando suprimir a escassez do mapeamento temático,

como o do uso e ocupação do solo, da aptidão agrícola das terras, da caracterização de unidades fisionômicas ou de paisagem, dentre outras.

A utilização de metodologias embasadas na imitação do raciocínio humano utilizando dados oriundos do SR, vêm crescendo e a estes, dados complementares podem ser acrescentados. Esta integração de dados de diferentes origens, associados aos dados de imagens digitais (ID) tem obtido sucesso fornecendo indicações necessárias para se racionalizar o uso do solo, dando o suporte necessário à tomada de decisões técnicas.

A integração de dados baseada em inteligência artificial, tal como a RNA é vantajosa para o desenvolvimento de metodologias que automatizem e otimizem a produção de mapas temáticos, agilizando e melhorando a acurácia dos mesmos. A automatização e otimização da integração de dados para a separação de unidades fisionômicas são decisivas em relação aos levantamentos de campo, pois podem minimizar os custos dos mesmos.

Portanto, nesse contexto o presente estudo visa separar automaticamente unidades fisionômicas (de paisagem) utilizando a técnica de RNA para a integração de dados de SR e informações do espaço físico, que auxiliam na separação das unidades fisionômicas (de paisagem).

2 REVISÃO DE LITERATURA

2.1 Análise Fisionômica

As formas e paisagens da superfície terrestre são importantes para estudos científicos em diferentes setores das Ciências da Terra, como geomorfologia, geologia, pedologia, planejamento urbano e regional, além de outros que desejam utilizar adequadamente o espaço geográfico.

A geomorfologia estuda as formas e paisagens da superfície Terrestre, incluindo sua descrição, tipo e gênese. A forma da Terra é o produto final resultante de interações de agentes naturais da superfície e tipos de rochas. Estas interações dependem do clima, do tipo de rocha e estrutura, bem como o intervalo de tempo (Gupta, 1991).

Bigarella et al. (1994), enfatizam que a compreensão da estrutura e da origem das paisagens necessita de abordagem interdisciplinar objetiva, considerando seu desenvolvimento no espaço e no tempo.

A análise fisionômica pode ser entendida como o reconhecimento de diferentes, ou principais, tipos de formas, relevo, padrão de drenagem natural, vegetação natural, uso do solo, condições da drenagem e outros elementos como erosão, superfície do solo e estrutura

geológica. As unidades são regiões que possuem padrões que podem caracterizá-las, ou seja, são unidades “homogêneas” que apresentam características físicas similares, tais como relevo, vertentes, declividade, padrão da rede de drenagem, estrutura geológica, cobertura vegetal e ação antrópica (Mulders, 1982).

As principais características que podem ser avaliadas por meio de dados capturados por SR são os padrões associados aos tipos de rochas, formas do terreno, textura do solo, condições da rede de drenagem, suscetibilidade ao escoamento e materiais inconsolidados sobre as rochas. De acordo com Oliveira et al. (1992) a experiência tem demonstrado que nenhum componente da natureza pode ser entendido quando estudado isoladamente.

2.1.1 Interpretação Visual de Imagens

A interpretação visual de imagens é o ato de identificar objetos na cena e discernir seu significado. Esta é executada qualitativamente, observando-se e identificando-se as feições do terreno, por meio de características encontradas na cena, tais como a forma, o tamanho relativo, a sombra, a tonalidade, a textura, as localidades e as adjacências, incluindo o conhecimento do comportamento espectral de feições quando a interpretação visual é em imagens digitais (Wolf, 1983).

A análise visual de uma imagem não se restringe apenas às propriedades espectrais armazenadas sob a forma de valores digitais em cada pixel. Entre outros aspectos que podem ser explorados, encontram-se a textura e a forma dos objetos, bem como a associação espacial entre os objetos que compõem a cena (Centeno et al. 2001).

A interpretação visual demanda conhecimento e experiência. O sucesso da análise visual depende da experiência do intérprete, que identifica objetos avaliando suas características com os padrões de reconhecimento e generaliza o resultado, tornando a informação legível para os usuários. Esses processos envolvem um alto grau de subjetividade, pois a cada etapa decisões são tomadas, e estas são calcadas em critérios do intérprete. Um analista bem treinado e familiarizado com a área de estudo tem critérios definidos, enquanto um intérprete menos experiente poderá tomar decisões menos seguras em função da falta de conhecimento e prática na interpretação visual.

Portanto, processos que reduzam o grau de subjetividade da análise visual são almejados, e uma forma de alcançá-los é por meio da implementação de regras em algoritmos automáticos de processamento de imagens.

2.2 Redes neurais artificiais (RNA)

As RNA são um ramo da inteligência artificial que se baseiam no princípio de simular parte do funcionamento do cérebro humano mediante técnicas de programação. Neste modelo, se considera que o cérebro é formado por neurônios interligados, compondo uma complexa rede, onde a informação flui sob forma de impulsos. Vários impulsos podem chegar simultaneamente a um neurônio através da rede e ao recebê-los, este os processa, pondera e combina no seu corpo, ou soma. Se intensidade dos impulsos recebidos, devidamente modulada, for suficientemente grande, o neurônio repassa um novo impulso a outros neurônios.

Nas RNA, a idéia é simular o funcionamento de um neurônio usando equações matemáticas e compor uma rede de neurônios artificiais, na qual informações lógicas ou valores numéricos possam ser processados para gerar uma saída. No neurônio artificial as entradas são valores numéricos (x_1, x_2, \dots, x_n), os quais são ponderados e somados para compor um único sinal de entrada (Equação 1).

$$S = b + \sum x_i * w_i \quad (1)$$

onde b é um valor constante próprio do neurônio, conhecido como “bias” e W_i representa o fator de ponderação, peso, de cada entrada. A soma ponderada é então modulada usando uma função de transferência. Para isto existem diferentes opções, como funções binomiais, lineares ou exponenciais.

As RNA são usualmente organizadas em camadas compostas de unidades de processamento (neurônios), conectadas por canais de comunicação que fazem fluir dados numéricos. Os dados são apresentados à rede por meio de uma camada de entrada, a qual se comunica a uma ou mais camadas ocultas, onde ocorre o processamento por meio de um sistema de conexões ponderadas. A camada de saída apresenta o resultado do processamento (German e Gahegan, 1996).

A chave do uso de uma RNA para a solução de um determinado problema consiste no ajuste de seus pesos, o que é feito numa primeira fase de treinamento. Treinar uma rede significa ajustar a sua matriz de pesos (W) de forma que o vetor de saída coincida com um certo valor desejado para cada vetor de entrada. Como o treinamento supervisionado necessita de pares de entrada e saída, esses são chamados de conjunto de treinamento. No treinamento, o vetor de entrada é aplicado e a saída da rede calculada. Comparando a resposta da rede com o vetor de saída esperado o erro é calculado. Com base neste erro, os pesos são ajustados a fim de minimizar essa diferença. O processo de treinamento é repetido até

que o erro para o conjunto de treinamento alcance um valor mínimo ou limite, previamente determinado.

O algoritmo para treinamento de RNA mais conhecido é o “Backpropagation” ou da retropropagação do erro. Ele utiliza o conceito de minimização do gradiente descendente e o limiar da função “sigmóide”, considerado uma generalização da Regra Delta para RNA, “feed forward”. A Regra Delta ou do erro quadrático mínimo utiliza um conjunto de treinamento com o qual se pretende uma aproximação linear, de tal forma que se obtenha a melhor aproximação possível no sentido do erro quadrático (German e Gahegan, 1996).

A RNA pode ser treinada para diferentes finalidades. No SR, as RNA têm comprovado utilidade para resolver problemas de classificação multiespectral, considerando dados de diferentes origens e escalas (Ribeiro e Centeno, 2002).

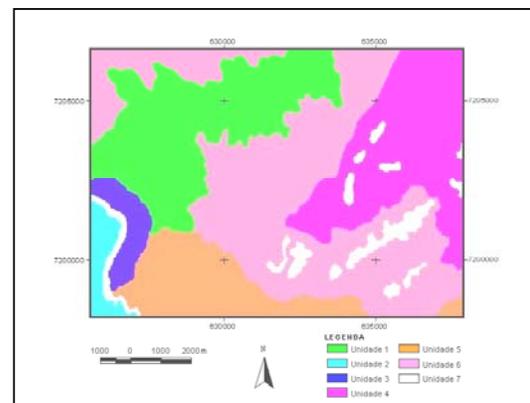
3 MATERIAIS E MÉTODOS

3.1 Área de estudo e materiais

A área de estudo está localizada na Folha Campo Largo, na escala 1:50.000 (IBGE, 1983). Encontra-se na posição limítrofe entre o primeiro e o segundo planalto, situa-se na escarpa Devoniana, que separa o Planalto de Curitiba do Planalto de Ponta Grossa, abrangendo essas duas unidades geomorfológicas (Universidade Federal do Paraná - Geologia, 1966).

A Figura 1 mostra a área fotointerpretada por meio da interpretação visual de fotografias aéreas da região na escala 1:25.000. Esta imagem é utilizada, neste estudo, como verdade de campo para a verificação (por meio do coeficiente de correlação) da separação de unidades de paisagem mediante a metodologia de RNA.

Figura 1 - Representação das sete unidades fisionômicas (de paisagem) - verdade de campo.



Os materiais utilizados foram a imagem digital do sensor Landsat ETM+ - sete bandas espectrais (221_77-1998), o MDT, a imagem das micro bacias e a imagem do elemento radioativo Potássio, sendo que esta última imagem foi adquirida mediante o levantamento gamaespectrométrico por SR passivo e é uma parte do Projeto Aerogeofísico Serra do Mar Sul (CPRM, 1978), realizado pela empresa Geofoto no período de 08/75 a 09/77.

Os programas utilizados foram o Matlab 5.3 – “tools box neural network” (processamento da RNA), o ENVI 3.6 (Processamento das Componentes Principais - CP), o Arcview 3.2a (processamento do MDT e a imagem das micro bacias) e o Geosoft (para aquisição da imagem do elemento K) e o Idrisi (Coeficiente de Correlação).

3.2 Métodos

Não existe regra única para a definição da arquitetura de RNA. A arquitetura depende do problema e do número de variáveis envolvidas, portanto define-se a melhor arquitetura por meio de experimentos. A fim de definir a arquitetura das RNA iniciam-se testes, definindo as entradas e saídas, as camadas escondidas e o número de neurônios por camada.

Definida as variáveis de entrada, o segundo estágio é encontrar a melhor arquitetura da rede, ou seja, o número de camadas escondidas e número de neurônios por camada. A quantidade de neurônios da primeira camada é igual ao número de variáveis de entrada, no caso cinco entradas, a saber: três imagens digitais - componentes principais (CP) geradas a partir da imagem Landsat ETM+, o Modelo Digital do Terreno (MDT), a imagem digital das micro bacias e a imagem oriunda do levantamento gamaespectrométrico do elemento radioativo Potássio (K). O número de nós da camada de saída é definido em função da quantidade de variáveis de saída, neste caso sete classes, definidas a partir da imagem fotointerpretada (Figura 1). As camadas escondidas, bem como o número de nós em cada camada escondida, são definidas experimentalmente, ou seja, em função da complexidade do problema. Testes foram realizados variando a arquitetura sendo que os melhores resultados foram obtidos utilizando duas camadas escondidas com 35 e 5 neurônios na primeira e segunda camada escondidas, respectivamente.

Após a definição das variáveis de entrada, da escolha das amostras de treinamento e da arquitetura da rede fixada, a RNA é treinada (aprendizado) pelo método supervisionado utilizando o treinamento “Backpropagation”. Durante o treinamento definiu-se como critério para o processo de aprendizado o erro

máximo limitado em 0,25 (erro médio quadrático - EMQ).

4 RESULTADOS

Na Tabela 1 são mostrados os resultados do treinamento da RNA. As colunas dessa tabela representam as variáveis de entrada de cada experimento, a quantidade de iterações, o EMQ. Pode-se verificar que o número de iterações variou entre 330 e 118 e o EQM de 0,0018 a 0,0019.

Tabela 1 – Treinamento da RNA.

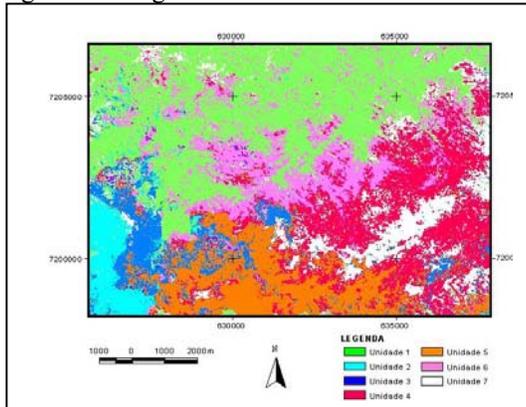
Variáveis	Iterações	EMQ
CP (3), micro bacias, MDT e K	118	0,0018
Cp (3), micro bacias, MDT e banda 7	330	0,0018
Cp (3), micro bacias e MDT	203	0,0019
Cp (3) e micro bacias	278	0,0019

Porém, somente com o resultado do treinamento da RNA, não se pôde avaliar a melhor classificação, portanto foi realizada uma tabulação cruzada (coeficientes de correlação - “Cramer’s V”) entre a imagem gerada mediante a RNA e a verdade de campo.

O coeficiente de correlação ou tabulação cruzada pode ser descrito como uma sobreposição mostrando todas as combinações da operação lógica “E”. O resultado é uma nova imagem que mostra os locais de todas as combinações das categorias das imagens originais. A tabulação cruzada também fornece o grau de consonância entre a classificação e a verdade de campo. O grau de afinidade ou correlação entre duas imagens é medido pelo coeficiente de correlação “Cramer’s V”, proposto por Kendel (1980) In: Antunes (2003). Essa medida é um coeficiente que varia na faixa de 0 até 1, indicando nenhuma ou perfeita correlação, respectivamente, utiliza-se da estatística de Qui-Quadrado e mede o grau de afinidade entre duas imagens.

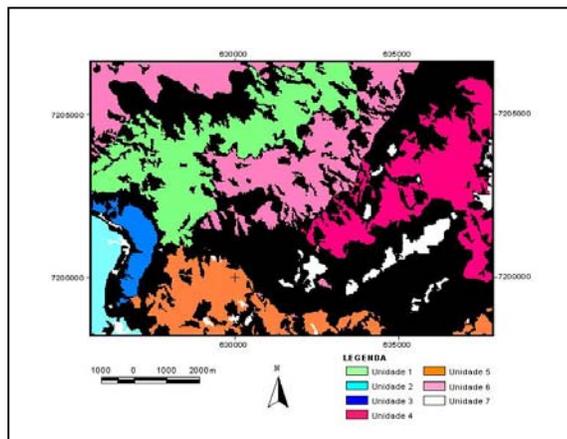
O melhor resultado, após o processamento da tabulação cruzada, foi obtido usando como dados de entrada as três CP, o MDT, as micro bacias e o elemento K, com o coeficiente de correlação igual a 0,4347. A Figura 2 mostra o resultado dessa classificação. Nota-se que nessa figura, a distribuição das classes está fragmentada, o que pode ser atribuído à adoção do pixel como unidade mínima de análise.

Figura 2 - Imagem classificada mediante RNA.



A Figura 3 ilustra a imagem gerada após o processamento do coeficiente de correlação ou tabulação cruzada realizada entre a verdade de campo (Figura 1) e a imagem gerada pelo processamento da RNA (Figura 2). Destaca-se que as regiões escuras são os erros, ou seja, onde não houve concordância entre as duas imagens.

Figura 3- Imagem da tabulação cruzada.



5 CONCLUSÕES

Com a metodologia de RNA é possível separar unidades fisionômicas (paisagem). A RNA possibilita a integração de diferentes variáveis. Essas variáveis são importantes, pois representam a cobertura do solo, podendo-se citar as imagens espectrais, o relevo, por meio do MDT e a rede de drenagem através das micro bacias. A subjetividade da fotointerpretação, gerada devido ao fato de cada analista interpretar a área de estudo visualmente utilizando seu conhecimento e intuitivamente as variáveis que representam a cobertura, o relevo dentre outros elementos, pode ser substituída pela metodologia de RNA por meio da análise

quantitativa destas variáveis, separando unidades automaticamente e sistematicamente.

A influência das microbacias está presente e quando associada ao MDT, acrescenta informações a respeito da área de estudo. Elas fornecem um agrupamento espacial de pixels representando a drenagem, esse agrupamento auxilia na separação das unidades haja vista que, as unidades não são pontuais e sim porções com características físicas similares.

O MDT na separação automática, de unidades fisionômicas é uma variável decisiva para a determinação das mesmas, pois ele delimita as regiões dos vales e topos da cena do presente estudo.

A presença das três CP e da imagem gamaespectrométrica do elemento radioativo K influenciaram na separação das unidades, pois estas delimitam algumas unidades como, por exemplo, a de número 2 e 6.

Por meio desta metodologia é possível a integração de dados de diferentes origens e escalas, o que não é possível com classificadores estatísticos convencionais.

A definição da arquitetura da RNA requer disponibilidade de tempo, ou seja, é trabalhosa, devido ao fato desta ser empírica, mas uma vez a rede treinada, para a área de estudo, pode-se alterar as variáveis de entrada. Assim como o intérprete necessita de treinamento, conhecimento e de elementos que auxiliem a interpretação da cena, a RNA também, com uma vantagem, pois o analista tem limitações para avaliar grande quantidade de variáveis e para a RNA, estando esta treinada, isso não é problema.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ANTUNES, A. F. B. 2003, **Classificação de Ambiente Ciliar Baseada em Orientação a Objeto em Imagens de Alta Resolução Espacial**. Tese de doutoramento Universidade Federal do Paraná. 147 p.

Bigarella J. J.; Becker R. D.; Santos G. F. 1994. **Estruturas e origem das paisagens tropicais e subtropicais**. Editora UFSC, Florianópolis - SC, v. I e II.

Centeno, J. A.; Tedesco, A.; Faria, A.; Maffra, C.; Augusto, E.G.G; Silva, F. R. R.. 2001. Análise da forma em imagens temáticas. **Anais do II Colóquio Brasileiro em Ciências Geodésicas**, UFPR, Curitiba. CD-ROM.

Gupta, R. P. 1991. **Remote Sensing**. Springer. Verlag. Berlin – Heidelberg. Germany, 356p.

Haykin, S.1999. **Neural networks**. A comprehensive foundation. 2 Ed. Prentice Hall. New Jersey. p. 842.

IBGE, 1983, Folha Campo Largo SG-22-X-C-III-D.

Mulders, M. A. 1982. **Introduction airphoto – interpretation for landscape analysis soil survey.** Bodemkunde em geologie. Department of Soil Science and Geology . Tropical Soils Section. Wagenigen Agricultural University. The Netherlands. 37p.

Oliveira J.B.; Jacomine, P.K.T.; Camargo, M.N. 1992. **Classes gerais de solos do Brasil : guia auxiliar de reconhecimento.** Jaboticabal, FUNEP. 201p.

Ribeiro, S.R. A.; Centeno, J. A. S. 2002. (a) **Clasificación del uso del suelo utilizando redes neurales y el algoritmo MAXVER.** Innovación, año 14, n.1, p. 55-60. Antofagasta- Chile.

Wolf, P. R. 1983. **Elements of Photogrammetry with photo interpretation and remote sensing,** 2^a Ed. McGraw – Hill Book Company. USA, 683 p.

CPRM. 1978. **Projeto Aerogeofísico Serra do Mar Sul.** CPRM/GEOFOTO (Arquivo Digital). Rio de Janeiro.