

UM SISTEMA NEURAL MODULAR PARA CLASSIFICAÇÃO DE IMAGENS UTILIZANDO MAPAS DE KOHONEN

Márcio L. Gonçalves¹
Márcio L. de Andrade Netto²
Jurandir Zullo Júnior³

¹DCA/FEE/UNICAMP - Cidade Universitária "Zeferino Vaz" C.P. 6101 13081-970
Campinas - SP - Brasil

Email: mleandro@dca.fee.unicamp.br

² DCA/FEE/UNICAMP Email: marcio@dca.fee.unicamp.br

³ CEPAGRI/UNICAMP Email: jurandir@cpa.unicamp.br

Resumo: Este trabalho apresenta um sistema modular para classificação de imagens multiespectrais de Sensoriamento Remoto (SR) utilizando Redes Neurais Artificiais (RNA) como paradigma básico de processamento da imagem, visando explorar o potencial do Mapa Auto-Organizável de Kohonen (SOM) para extração não-supervisionada de atributos. Os resultados experimentais mostram a aplicação do sistema neural proposto em uma imagem TM-Landsat.

Abstract: This work presents a modular system for Remote Sensing (RS) image classification using Artificial Neural Networks (ANN) as the basic processing paradigm, aiming at exploring the potential of the Kohonen's Self-Organizing Map (SOM) for unsupervised feature extraction. Experimental results show the application of the proposed neural system on a TM-Landsat image.

1. INTRODUÇÃO

Nos últimos anos as RNA têm sido aplicadas com sucesso nas áreas de processamento de imagens e reconhecimento de padrões. No caso particular de aplicações em classificação de imagens de SR, diversos trabalhos (Hepner 1990, Benediktsson et al. 1990, Liu et al. 1991, Kanellopoulos et al. 1992, Schlünzen 1993, Civco 1993) fizeram uso de RNA, aplicando uma rede de perceptrons multicamadas (MLP) única para resolver o problema de classificação. Embora os resultados tenham sido satisfatórios, esta abordagem pode não apresentar o melhor desempenho, quando etapas mais complexas de processamento das informações, divididas em diferentes módulos, podem ser necessárias. Uma das vantagens da modularização é que a representação dos dados desenvolvida tende a ser mais facilmente entendida do que no caso de uma rede MLP comum, em virtude da habilidade de uma arquitetura modular decompor uma tarefa complexa em um número de tarefas mais simples (Jacobs et al. 1991).

Nesse sentido, propõe-se nesse trabalho um sistema neural modular para classificação de imagens de SR. O sistema apresenta-se dividido em duas fases: *extração de atributos* não-supervisionada empregando o SOM e *classificação* por uma rede MLP.

2. EXTRAÇÃO DE ATRIBUTOS UTILIZANDO MAPAS DE KOHONEN

O objetivo da fase de extração de atributos é identificar as classes espectrais presentes na imagem e definir um conjunto de amostras correspondentes para serem utilizadas na fase de classificação.

Não há uma teoria bem desenvolvida para extração de atributos; a maioria dos atributos são bastante orientados à aplicação, sendo normalmente encontrados por métodos heurísticos e/ou por uma análise de dados interativa.

Um princípio básico importante é que os atributos não devem depender de pertencer às classes porque, por definição, na fase de extração de atributos a pertinência às classes ainda não é conhecida. Isso implica que qualquer método de aprendizagem usado para extração de atributos deve ser *não-supervisionado* no sentido de que a classe alvo para cada objeto é desconhecida (Oja et al. 1994).

Uma das abordagens é o uso de aprendizagem competitiva, resultando no *clustering* dos dados. Um exemplo é o Mapa Auto-Organizável de Kohonen (SOM) (Kohonen 1989).

É bem conhecida a propriedade do SOM de dividir o espaço de entrada em regiões convexas, onde um conjunto de vetores de referência associa códigos de vetores com o espaço de entrada. A classificação de uma imagem pode então se basear nos códigos dos *clusters* encontrados para a imagem através do SOM.

Em nossa abordagem construímos a partir do SOM uma ferramenta de auxílio visual, denominada Mapa de Clusters de Kohonen, permitindo identificar as classes espectrais presentes na imagem através dos códigos dos *clusters* gerados pelo SOM.

2.1 DESCRIÇÃO DO SOM

O SOM pertence a classe de redes neurais não-supervisionadas que se baseiam no processo de aprendizagem competitiva, onde somente um neurônio de saída ou grupo local de neurônios fornece uma resposta ativa a um sinal de entrada corrente. O nível de ativação indica a similaridade entre o vetor de dados de entrada e o vetor de pesos do neurônio. Uma forma usual de expressar a similaridade é através da distância euclidiana entre esses vetores. Uma vez que a distância entre o vetor de pesos de um determinado neurônio e o vetor de dados de entrada é a mínima para todos os neurônios da rede, esse neurônio juntamente com um conjunto pré-definido de neurônios vizinhos terá seus pesos automaticamente reajustados pelo algoritmo de aprendizagem da rede. A vizinhança de cada neurônio pode ser definida de acordo com a forma geométrica usada para representar os neurônios da rede. A figura 1 mostra dois exemplos de representação propostos por (Kohonen 1989): um na forma de um *array* retangular e o outro na forma de um *array* hexagonal.

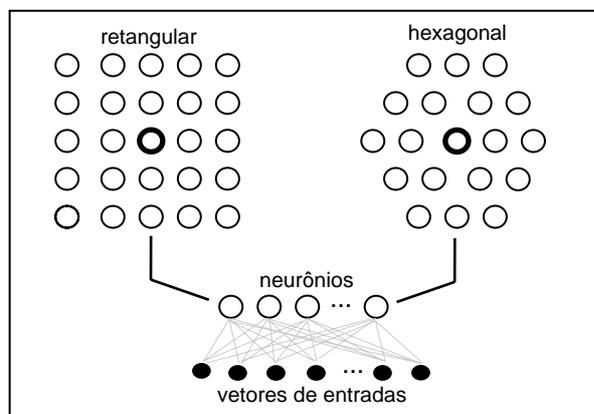


Figura 1: Exemplos de representação geométrica dos neurônios do SOM.

A seguir é dada uma breve descrição do algoritmo de aprendizagem do SOM:

Passo 1: Selecione uma padrão de treinamento $X = (x_1, x_2, \dots, x_N)$ e forneça como entrada à rede.

Passo 2: Calcule as distâncias d_i entre o vetor de entradas e o vetor de pesos de cada neurônio j da rede:

$$d_i = \sum_{j=1}^N (x_j(t) - w_{i,j}(t))^2$$

onde $x_j(t)$ é a j -ésima entrada em uma dada iteração e $w_{i,j}(t)$ é o peso do neurônio j da camada de entrada conectado ao neurônio i da camada de saída.

Passo 3: Selecione um neurônio i^* com a distância mínima entre todos os outros neurônios, e ajuste o vetor de pesos de i^* e de seus vizinhos pela seguinte regra:

$$w_{i,j}(t+1) = w_{i,j}(t) + \alpha(t) * (x_j(t) - w_{i,j}(t))$$

para $i \in N_{i^*}, j = 1, 2, \dots, N$

onde N_{i^*} é o conjunto que contém i^* e seus vizinhos, e $\alpha(t)$ é a razão de aprendizagem que é usualmente menor do que 1. O procedimento continua até que o ajuste dos pesos não seja mais significativo.

No final do processo de aprendizagem cada neurônio ou grupo de neurônios vizinhos representará um padrão distinto dentro do conjunto de padrões fornecidos como entrada para a rede.

Uma das vantagens de se utilizar o SOM é que ele possui duas propriedades que não são encontradas em outros métodos não-supervisionados de *clustering*. Tais propriedades são:

- Preservar as relações topológicas (métricas) entre os vetores de dados de entrada;
- Produzir uma aproximação da função densidade de probabilidade dos vetores de dados de entrada.

2.2 MAPA DE CLUSTERS DE KOHONEN (MCK)

Na abordagem proposta, utilizamos como padrões de treinamento para o SOM janelas 3x3 de *pixels* da imagem original. Esses padrões são coletados de maneira aleatória e uniforme sobre toda a região da imagem e fornecidos como vetores de entrada ao SOM. Uma vez que o SOM possui a particularidade de distribuir os vetores pesos na forma de um *array* retangular ou hexagonal e, levando-se em conta que os vetores pesos possuem as mesmas dimensões que os vetores de entrada, torna-se possível gerar uma imagem do *array* de pesos do SOM.

A imagem do *array* resultante, após o treinamento não-supervisionado pelo SOM, foi denominada *Mapa de Clusters de Kohonen* (MCK). A figura 4 (no anexo) mostra um MCK retangular obtido a partir da imagem da figura 3.

O MCK constitui-se numa ferramenta de auxílio visual tornando possível identificar e selecionar as

classes espectrais da imagem e suas respectivas amostras de treinamento, que serão utilizadas na fase de classificação. Ele possui algumas características importantes que facilitam a realização dessas tarefas:

- Como o SOM efetua um *clustering* dos padrões de treinamento, é possível visualizar no MCK as classes espectrais presentes na imagem original através dos *clusters* obtidos;

- A propriedade do SOM, de preservar as relações topológicas (métricas) entre os vetores de dados de entrada, reflete-se na propriedade do MCK de preservar estas relações em termos da distância entre os *clusters*; i.e., *clusters* que são vizinhos no MCK representam classes de cobertura terrestre que possuem características espectrais semelhantes;

- Outra propriedade importante do SOM é preservar as distribuições de probabilidade encontradas nos dados de entrada. Esta propriedade pode ser verificada no MCK, onde classes espectrais com maior frequência de ocorrência nos dados de entrada serão mapeadas em regiões maiores no MCK.

Portanto, na abordagem proposta, as classes espectrais e suas amostras, que serão utilizadas na fase de classificação, são selecionadas a partir do próprio MCK e não através da imagem original, como é feito usualmente.

3. MLP PARA CLASSIFICAÇÃO

Tendo definido as classes desejadas e suas respectivas amostras através do MCK, o objetivo da segunda fase do sistema proposto é realizar a classificação final da imagem empregando uma rede MLP.

A rede MLP utilizada em nosso sistema possui uma camada escondida (veja figura 2). O número de neurônios por camada varia de acordo com o número de classes e com o número de amostras selecionadas para realizar o treinamento da rede.

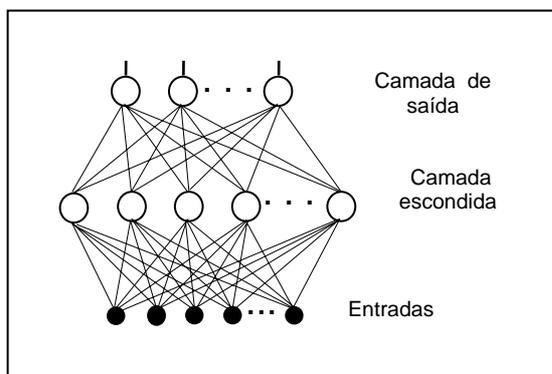


Figura 2: Configuração da rede MLP.

O algoritmo de aprendizagem utilizado para o treinamento da rede MLP é o *backpropagation* padrão (Rumelhart 1986).

4. RESULTADOS EXPERIMENTAIS

Para testar a aplicabilidade do sistema neural proposto foi utilizada uma imagem TM/LANDSAT composta pelas bandas 7, 5 e 4 associadas, respectivamente, as cores vermelho, verde e azul (figura 3). A imagem possui 512x512 *pixels*, corresponde a região de cruzamento dos rios Pardo e Mogi (longitude de 48° oeste e 21° sul) e foi registrada no dia 8 de agosto de 1990.

A rede de Kohonen (ou SOM) utilizada na primeira fase do sistema foi composta por 600 neurônios, representados geometricamente por um *array* retangular de 20 linhas por 30 colunas. O MCK obtido após o treinamento do SOM é mostrado na figura 4.

Com a ajuda de um especialista foram facilmente identificadas 5 classes de cobertura terrestre, a partir do MCK, para realizar a classificação da imagem: solo nu, água, solo úmido, pastagem e plantação de cana. Foram selecionadas 5 amostras, próximas dos vértices e no centro do MCK correspondentes a cada uma das classes. Cada amostra corresponde a uma janela 3x3 de *pixels*.

Essas amostras foram apresentadas no treinamento da rede MLP. A rede utilizou 14 neurônios na camada escondida e 5 neurônios na camada de saída, referentes as classes de cobertura terrestre escolhidas para essa classificação teste.

A figura 5 mostra o próprio MCK classificado pela rede MLP treinada, onde pode-se verificar a separação das classes, construindo *regiões de decisão* para a classificação. As regiões não classificadas, em preto, podem indicar a presença de classes distintas, que podem ser iterativamente incorporadas em seleções mais abrangentes e refinadas de classes. Isso pode levar a classificações melhores ou mais específicas.

Finalmente, a figura 6 mostra a imagem teste classificada para as 5 classes de cobertura terrestres.

5. CONCLUSÕES E TRABALHOS FUTUROS

As vantagens apresentadas pelo sistema proposto podem ser melhor entendidas levando-se em conta que a classificação em sistemas neurais normalmente é feita por uma única rede MLP, onde a extração de atributos, isto é, a seleção de classes e amostras é feita diretamente a partir da imagem original por um especialista. Com a modularização do sistema, a tarefa de extração de atributos foi realizada pelo SOM, gerando uma ferramenta prática, o MCK, que fornece informações úteis quanto à representatividade, distribuição e semelhança das classes espectrais. Isso torna possível, identificar e selecionar, por inspeção

visual, as classes espectrais e suas respectivas amostras de treinamento que serão usadas na fase de classificação posterior. Essas vantagens do MCK são enfatizadas nos casos em que a imagem apresenta uma variabilidade muito complexa de padrões espectrais, onde pode tornar-se difícil a tarefa de seleção das classes, bem como de suas amostras, diretamente da imagem original.

Como trabalhos futuros pretende-se utilizar um algoritmo de treinamento avançado para a rede MLP, que utiliza informação de segunda ordem, com o objetivo de aumentar a *performance* na classificação. O algoritmo é uma versão do algoritmo do gradiente conjugado escalonado proposto por (Moller 1993), que calcula a informação de segunda ordem de maneira exata (Pearlmutter 1994).

Pretende-se também investigar a aplicabilidade e flexibilidade das técnicas de determinação dinâmica da estrutura, propostas por (Fritzke 1995) e (Zuben 1995), para as redes SOM e MLP respectivamente. Essas técnicas consistem basicamente em deixar a estrutura da rede crescer até que critérios de *performance* específicos à aplicação sejam atingidos.

AGRADECIMENTOS

O primeiro autor agradece a Jesus Cristo, Fonte de Vida e Esperança. O primeiro autor agradece também a Nelson Hi Man Pak pelos comentários e sugestões.

6. REFERÊNCIAS

- Benediktsson, J. A., Swain, P. H., Ersoy, O. K. *Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data*. IEEE Transactions on Geoscience and Remote Sensing, vol. 28, no. 4, pp. 540-552, 1990.
- Cívco, D. L. *Artificial Neural Networks for Land-cover Classification and Mapping*. International Journal of Geographical Information Systems, vol. 7, no. 2, pp. 173-186, 1993.
- Fritzke, B., *Growing Grid - a self-organizing network with constant neighborhood range and adaptation strength*. Neural Processing Letters, vol. 2, no. 5, pp. 1-5, 1995. (to appear)
- Hepner, G. F. *Artificial Neural Networks Classification using a Minimal Training Set: Comparison to Conventional Supervised Classification*. Photogrammetric Engineering and Remote Sensing, vol. 56, no. 4, pp. 469-473, 1990.
- Jacobs, R. A., Jordan, M. I., Barto, A. G. *Task Decomposition through Competition in a Modular Connectionist Architecture: The what and where*

vision tasks. Cognitive Science, vol. 15, pp. 219-250, 1991.

Kanellopoulos, I., Varfis, A., Wilkinson, G. G. and Mégier, J. *Land-cover Discrimination in SPOT HRV Imagery using an Artificial Neural Network - a 20-class experiment*. International Journal of Remote Sensing, vol. 13, no. 5, pp. 917-924, 1992.

Kohonen, T. *Self-Organization and Associative Memory*. Springer-Verlag, Berlin, 1989.

Liu, Z. K., Xiao, J. Y. *Classification of remotely-sensed image data using artificial neural networks*. International Journal of Remote Sensing, vol. 12, no. 11, pp. 2433-2438, 1991.

Moller, M. F., "A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning", *Neural Networks*, vol. 6, no. 4, pp. 525-533, 1993.

Oja, E., Lampinen, J. *Unsupervised Learning for Feature Extraction*. Computational Intelligence: Imitating Life, IEEE Press, 1994.

Pearlmutter, B. A., "Fast Exact Multiplication by the Hessian", *Neural Computation*, vol. 6, no. 1, pp. 147-160, 1994.

Rumelhart, D. E. and McClelland, J. L. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. vol. 1, Cambridge, MA: MIT Press, 1986.

Schlünzen, E. T. M. *Perspectivas da Aplicação de Redes Neurais na Classificação de Dados Multiespectrais de Sensoriamento Remoto*. Tese de Mestrado, Departamento de Computação e Automação Industrial, Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas, 1993.

Zuben, F. J. V. Tese de Doutorado em andamento. Departamento de Computação e Automação Industrial. Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas, 1995.

Clustering dos dados de entrada pelo **Mapa Auto-Organizável de Kohonen (SOM)**



Figura 3: Imagem TM Landsat (composição colorida das bandas 4, 5 e 7).

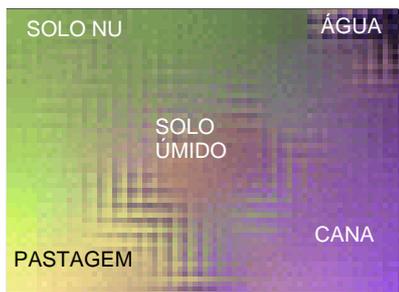


Figura 4: Mapa de Clusters de Kohonen (KCM).

Classificação pela Rede de **Perceptrons Multicamadas (MLP)**



Figura 5: Mapa de Clusters de Kohonen classificado.

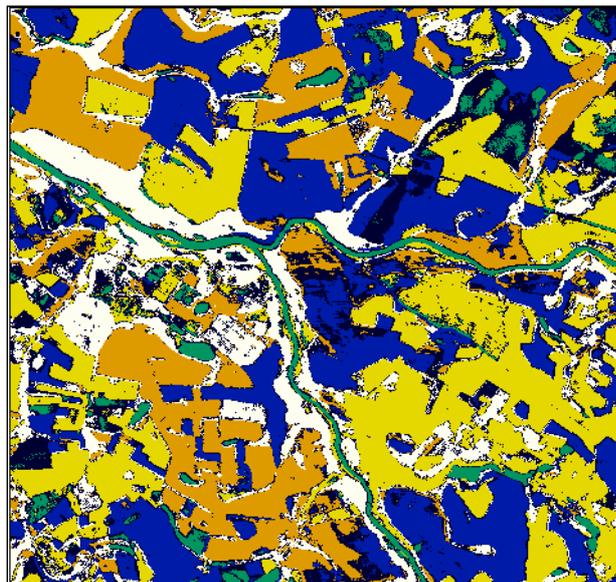


Figura 6: Imagem classificada.