

Geografia Computacional: Um Experimento em Inferência Geográfica com Redes Neurais Artificiais

Marcos A.S. da Silva^{1,2}, Antônio M.V. Monteiro¹, José S. de Medeiros¹

¹*Instituto Nacional de Pesquisas Espaciais
Divisão de Processamento de Imagens
São José dos Campos, SP*

²*Embrapa Tabuleiros Costeiros, Aracaju, SE
{aurelio,miguel,simeao}@dpi.inpe.br*

Resumo

Dentro do contexto da Geografia Computacional, este trabalho tem como propósito investigar o uso de redes neurais de base radial (RBF) e mapas auto-organizáveis (SOM), como ferramentas de inferência espacial. Para isto propusemos um modelo híbrido de rede neural cujo objetivo é que, após o processo de aprendizagem de máquina, o mesmo seja capaz de inferir sobre a favorabilidade de áreas quanto ao deslizamento de massa. Neste trabalho é apresentada uma arquitetura de software, baseada na biblioteca Terralib, desenvolvida pelo INPE, no auxílio ao uso do modelo neural proposto em aplicações sócio-ambientais. O experimento piloto está sendo montado e apresentamos aqui os resultados preliminares para o modelo.

Abstract

In the context of Computational Geography, this work had an objective to investigate the use of radial basis function neural network (RBF) and a self-organizing map (SOM), as a spatial inference tool. Hence, we proposed a hybrid neural network model for make inference about the landslide hazard, after a learning machine process. We are proposing a software architecture based on a free library developed at INPE, called Terralib, for aid the use of neural model presented in socioenvironmental applications. We will show the experiment and the first results for the model.

1. Introdução

A Geografia computacional é uma nova área de pesquisa que visa a utilização do potencial de processamento e dos novos paradigmas computacionais

na solução dos problemas de análise e modelagem geográficas que até então não possuíam solução por falta de modelos ou capacidade de processamento. Ehlen et al., 2002, apresenta algumas definições de Geografia Computacional que ilustram o quão nova é esta disciplina e sua importância para a análise espacial. Openshaw & Abrahart, 2000, um dos idealizadores da Geografia Computacional, afirma que esta disciplina trata do desenvolvimento de ferramentas computacionais de alto desempenho para manipulação e tratamento de dados geográficos ou espaciais numa abordagem científica para solução de problemas até então insolúveis ou desconhecidos; Couclelis, 1998, define Geografia Computacional como a aplicação eclética dos métodos e técnicas computacionais para representação de propriedades espaciais na busca de explicação dos fenômenos e solução dos problemas geográficos; Gahegan, 1999, vê a Geografia Computacional como um conjunto de ferramentas e métodos para modelagem e análise de um espectro de problemas altamente complexos e frequentemente não determinísticos na geografia.

O surgimento da Geografia Computacional foi motivado por fatores como o crescimento quantitativo de dados georreferenciados disponíveis em meio digital, pela evolução dos Sistemas de Informação Geográficos (SIG) e pelo sucesso e demandas originadas das técnicas de estatísticas que incluem em seus modelos o atributo espacial, Câmara & Monteiro, 2001. Várias técnicas computacionais, principalmente da área de Inteligência Artificial, têm sido estudadas na análise e modelagem dos fenômenos espaciais, podemos citar os automatas celulares, a lógica nebulosa, a teoria dos conjuntos aproximativos, a teoria da evidência e as redes neurais artificiais, Openshaw & Openshaw, 1997; Hewtson & Crane, 1994; Openshaw & Abrahart, 2000. Em

particular, as Redes Neurais Artificiais (RNA) têm sido bastante exploradas neste contexto e receberão uma atenção especial na seção 3 deste trabalho.

As técnicas de inferência espacial são indispensáveis quando do desenvolvimento de sistemas geográficos de apoio a decisão. Pois, deseja-se dispor de ferramentas computacionais que nos ajudem a avaliar cenários de comportamento espacial sob diversas condições. Podemos citar como iniciativas no desenvolvimento de sistemas nesta direção os projetos GeoVista, Gahegan et al., 2002; e MEDALUS, Openshaw & Turner, 2002.

Neste trabalho trataremos do problema de predição de áreas susceptíveis a deslizamento de massa através de redes neurais artificiais a partir de uma coleção de dados amostrais. Compreendem estes dados os mapas temáticos de declividade, uso da terra e geologia (Figura 1). Também proporemos o desenvolvimento de um software baseado na biblioteca Terralib, Câmara et al., 2001; Câmara et al., 2002; para auxiliar, futuramente, a aplicação do modelo proposto.

Na seção 2 apresentamos o problema de inferência espacial, na seção 3 falamos brevemente sobre o uso das redes neurais na análise espacial. A seção 4 apresenta a arquitetura do modelo proposto. Na seção 5 mostramos o tratamento dos dados e o processo de treinamento das redes neurais. Finalmente, nas seções 6 e 7 apresentamos, respectivamente, os resultados, discussões, trabalhos futuros, além de nossas conclusões.

2. Inferência Espacial

Uma situação comum quando tratamos computacionalmente de dados geográficos é a classificação do espaço em áreas adequadas, segundo algum critério, para uma determinada função, Câmara et al., 2001. Este problema é tratado através de técnicas de inferência geográfica. Estas técnicas podem ser divididas em modelos teóricos e empíricos, os modelos empíricos estão estruturados com base nos dados observados. Estes modelos estão divididos em modelos baseados em conhecimento e em dados. Os modelos baseados em redes neurais são modelos empíricos baseados em dados, pois usam as amostras disponíveis para aprendizagem e posterior inferência, Câmara et al., 2001.

Neste trabalho apresentamos um modelo híbrido baseado em duas redes neurais artificiais. As redes são do tipo mapa auto-organizável de Kohonen (SOM) e rede de função de base radial (RBF), Haykin, 2001. Estes modelos de rede têm sido usados, com relativo sucesso, como técnicas de inferência espacial como podemos verificar em Openshaw & Turton, 1996; Openshaw & Openshaw, 1997; Winter & Hewitson, 1994; Foody, 1999.




Figura 1. Mapas de risco, declividade, geológico e de uso.

3. Redes Neurais na Análise Espacial

O uso de redes neurais artificiais na análise espacial se intensificou a partir dos anos 90, Openshaw & Openshaw, 1997; Hewitson & Crane, 1994. Desde então muitos trabalhos começaram a surgir na literatura tratando de temas diversos como classificação de imagens de sensores remotos Ji, 2000; predição dos níveis de pluviosidade, Lee et al., 1998; Bollivier et al., 1997; determinação dos índices de vulnerabilidade à erosão, Medeiros, 1999; Cai, 1995; produção de mapas potenciais para diversos bens minerais, Nobrega, 2001; e para avaliação de erosão em áreas agrícolas, Rosa et al., 1999.

Fischer, 1998, apresenta uma introdução das redes neurais aos especialistas em análise espacial. Também apresenta uma taxonomia para as redes neurais e ilustra o potencial das mesmas comparando modelos convencionais com as RNA na modelagem de interações espaciais.

Hilbert et al., 2001, trata do uso de redes neurais artificiais para estudo da sensibilidade das florestas tropicais, do norte de Queensland, às mudanças climáticas.

O autor criou um modelo de RNA para estudo de cenários onde pôde-se fazer algumas previsões sobre o comportamento florestal, sobre várias condições climáticas de temperatura e precipitação pluviométrica.

Cereghino et al., 2001, analisou a distribuição espacial de invertebrados de quatro tipos, numa área chamada Adour-Garonne, França. Uma rede neural do tipo SOM foi usada para classificação baseada nas características dos insetos. O autor espera que, uma vez estável teoricamente, o modelo possa ser usado para indicar modificações no meio ambiente através da observação da distribuição dos invertebrados.

Rodrigue, 1997, faz uma análise do uso de redes neurais na modelagem e análise espaciais através do estudo de modelagem de transporte. Segundo o autor as

RNAs trazem consigo dois paradigmas importantes para a análise espacial. A simulação de processo e a associação de padrões.

Murnion, 1997, usa a rede Hopfield como um otimizador combinatorial espacial. O objetivo é determinar as melhores áreas para instalação de estabelecimentos comerciais onde um competirá com o outro por consumidores. Este artigo ilustra o uso das redes neurais na modelagem dos processos espaciais.

Sung et al., 2001, analisa o problema de estimação e predição de áreas de habitação em regiões montanhosas através de SIGs e RNA. O autor usou os elementos de paisagem como entradas para a RNA e comparou os resultados com a predição de áreas realizada por um grupo de especialistas. Os resultados mostraram que é possível estimar áreas de ocupação em regiões montanhosas a partir, somente, dos elementos de paisagem.

A partir deste breve levantamento dos trabalhos mais recentes sobre a aplicação das redes neurais na análise espacial observamos que os modelos de rede propostos são concebidos empiricamente. Identificamos que a simplicidade da abordagem permite várias iniciativas em diversas áreas da análise espacial. Constatamos que não existe uma ferramenta totalmente operacional de suporte a decisão que permita que o profissional possa realizar simulações usando vários modelos de inferência espacial, incluindo os modelos tradicionais estatísticos. Percebemos também que há um grande número de modelos de redes neurais a serem avaliadas para este fim.

4. A arquitetura proposta

A arquitetura do modelo híbrido é apresentada no esquema da figura 2. As redes SOM e RBF foram escolhidas em função da boa capacidade de agrupamento dos dados da SOM e da velocidade de convergência da RBF quando combinada com a SOM.

Estamos assumindo que os mapas a serem inseridos no modelo foram elaborados num SIG qualquer e que foram exportados para um formato conveniente.




Figura 2. Arquitetura geral do modelo.

Escolhemos os conjuntos de dados amostrais através de um sistema de informação geográfica. Transformamos os dados dos mapas temáticos em vetores $X = \{x_1, x_2, x_3\}$, onde x_i representa o valor numérico representativo de cada classe dos mapas de declividade, uso da terra e geologia, respectivamente. Os valores de X são então normalizados entre 0 e 1 para posterior apresentação à rede SOM.

Na rede SOM os dados são redimensionados segundo a topologia e dimensão desta rede. Os pesos w da rede SOM, cujos neurônios se especializaram, serão usados como os centros de classe na rede RBF.

A rede RBF é então treinada com os mesmos dados amostrais. Após o treinamento a rede estará apta a mapear qualquer vetor de característica X num vetor de classe d . Esse vetor d é transformado num valor numérico representativo da classe correspondente para geração do mapa de risco, que é o produto final desejado.

4.1. A rede de função de base radial

A RBF consiste de uma camada de entrada, uma camada oculta conectada a primeira, sem pesos sinápticos, e uma camada de saída, com três neurônios bipolares, conectada a segunda com pesos sinápticos (figura 3).




Figura 3. Modelo da rede RBF proposta.

As funções de base radial são gaussianas isotrópicas com centros de classes definidos a partir da RNA SOM. O desvio padrão σ , largura das funções gaussianas, será igual para todas as funções radiais.

A saída da rede possui três neurônios com funções de ativação lineares onde os padrões são os seguintes: (1, -1, -1) para risco muito alto; (1, 1, -1) para risco médio; (1, 1, 1) para risco baixo; (-1, 1, -1) para alto risco; (-1, -1, -1) para a ausência de risco. Qualquer outra saída será considerada como área não classificada.

Os parâmetros livres desta rede são o conjunto $\{t_i\}$, $i=1, \dots, m$ dos centros de classe, onde m é número de neurônios na camada oculta e a matriz w dos pesos da camada de saída. Escolhemos a função gaussiana isotrópica (1) como a função de base radial.

$$\varphi_j = \exp(-m/d_{max}^2 * ||x_i - t_j||^2), i=1, \dots, N \text{ e } j=1, \dots, m \quad (1)$$

Onde,
 m : número de neurônios na camada oculta;
 d_{max} : distância máxima entre os centros escolhidos (espalhamento)

x_i : padrão de entrada

t_j : vetor de centro

A largura (σ) de todas as funções é a mesma e igual a:

$$\sigma = d_{max}/(2m)^{1/2} \quad (2)$$

O treinamento da rede RBF possui duas fases. A primeira consiste na determinação dos centros de classe. A segunda fase consiste na descoberta dos pesos sinápticos que conectam a camada oculta à camada de saída. Usaremos a regra Delta para descoberta dos pesos w da camada de saída.

4.2. Mapa auto-organizável

O principal objetivo dos mapas auto-organizáveis é transformar um padrão de dimensão arbitrária em um mapa discreto uni- ou bidimensional, realizando esta transformação adaptativamente de maneira ordenada, Haykin, 2001.

A rede SOM tem como entrada o vetor $X = \{x_1, x_2, x_3\}$ e topologia bidimensional 5X5 (figura 4). Esta topologia deve ser parametrizada de acordo com a aplicação. O objetivo do algoritmo de treinamento é gerar um mapa auto-organizado através da atualização dos pesos $W = \{w_i\}_{25 \times 3}$.

O algoritmo de clusterização é o padrão definido por Kohonen e exposto por Haykin, 2001.




Figura 4. Modelo da Rede SOM proposta.

5. Tratamento dos dados e treinamento das redes

Para treinamento das redes usamos, neste experimento piloto, dados amostrais provenientes de um mapa de risco de deslizamento de massa (figura 5). A partir deste mapa, gerado através da álgebra de mapas, definimos as

unidades amostrais. A tabela 1 mostra a quantidade de dados amostrais de treinamento e controle (teste).

Amostras	Treinamento	Teste
Risco muito alto	4520	1366
Risco médio	4557	2734
Risco baixo	4000	2100
Risco alto	2747	2275
Total	16824	8575

Tabela 1. Quantitativo das amostras.

Após a seleção dos dados de entrada procedemos com a sua normalização, transformando os valores para o intervalo $[0,1]$. Os padrões de treinamento foram apresentados à rede de maneira sequencial.




Figura 5. Mapa de risco à esquerda determinará os unidades amostrais nos mapas à direita.

6. Resultados e Discussões

Após 459 épocas a rede SOM agrupou os dados da forma exposta na figura 6. A observação do agrupamento dos dados revela que as classes obedecem a um padrão relativamente complexo uma vez que a especialização dos neurônios se fez de maneira relativamente esparsa. Neste caso o especialista na área de aplicação do modelo deverá atentar para este fato e fazer as inferências empíricas cabíveis, como, por exemplo, verificar se seus dados amostrais são representativos.




Figura 6. Mapa auto-organizável gerado.

Uma vez definidos os centros de classe pela rede SOM por meio de treinamento não-supervisionado apresentamos os dados amostrais para a rede RBF. Após

o treinamento supervisionado a rede RBF obteve 95,73% de acerto para as amostras de treinamento e 92,15% para as amostras de teste. Obviamente os resultados dependerão mais da qualidade das amostras do que do modelo proposto.

Na figura 7 ilustramos todos os passos do processo para realização deste trabalho. Observamos que como não existe uma interface direta entre o banco de dados geográfico do SIG e o ambiente de implementação do modelo, Matlab, uma série de conversões de arquivos e importação/exportação de dados é necessária. Ademais, o processo de tratamento dos dados como normalização e seleção de amostras exigem esforços de programação consideráveis.

7. Trabalhos futuros e conclusões

Uma vez comprovada a aplicabilidade do modelo de inferência neural proposto se faz necessária a construção de uma ferramenta computacional que facilite ao usuário final do modelo a sua operacionalização, permitindo que os passos descritos na figura 7 sejam realizados semi-automaticamente.

Na figura 8 apresentamos uma proposta de arquitetura de software para solucionar este problema. Sucintamente, a idéia é desenvolver um sistema de inferência espacial baseado no modelo proposto com acesso direto ao banco de dados geográfico através da biblioteca Terralib, Câmara et al., 2002. O objetivo é criar um protótipo de sistema que possa implementar o método de inferência proposto e que possa agregar outros métodos, sejam baseados em abordagens conexionista ou não.

A arquitetura de software consiste na modularização do sistema em duas partes. A primeira seria a construção do modelo de inferência espacial e sua implementação usando a biblioteca Terralib. A segunda seria o desenvolvimento de um sistema de interface com o usuário para pré-processamento/tratamento dos dados geográficos antes de apresentá-los ao modelo. Através deste módulo que o usuário definiria seus cenários, quais atributos seriam utilizados, quais as funções de normalização e a parametrização global do modelo.

Após a aplicação do modelo de inferência o sistema geraria mapas temáticos, ou valores numéricos como resposta. Estas informações devem, então, ser apresentadas ao usuário através de recursos de visualização de objetos espaciais.

Podemos afirmar que o modelo proposto atingiu resultados relativamente satisfatórios para o experimento piloto considerando que não houve preocupação exaustiva quanto à calibração do modelo. Novos testes deverão ser conduzidos a fim de se avaliar o modelo sobre outras massas de dados para avaliação.




Figura 7. Fluxo de atividades no processo estudado.




Figura 8. Arquitetura de software proposta.

8. Referências

- [1] Bollivier, M.; Dubois, G.; Maignan, M.; Kanevsky, M., "Multilayer perceptron with local constraint as an emerging method in spatial data analysis", *Nuclear Instruments & Methods in Physics Research Section A – Accelerators Spectrometers Detectors and Associated Equipment*, 1997, 389, 1-2, 226-229.
- [2] Cai, Y., "Artificial neural-network method for soil-erosion forecasting", *Bodenkultur*, 1995, 46, 1, 19-24.
- [3] Câmara, G.; Davis, C.; Monteiro, A.M.V. & D'Alge, J.C. (eds), *Introdução à Ciência da Geoinformação*, São José dos Campos, INPE, 2001. URL: <http://www.dpi.inpe.br/gilberto/livro/introd>.
- [4] Câmara, G. et al., "Design Patterns in GIS Development: The Terralib Experience", *III Workshop Brasileiro de Geoinformática, GeoInfo2001. Rio de Janeiro, 2001*.

- [5] Câmara, G. & Monteiro, A.M.V., "Geocomputation Techniques for Spatial Analysis: Is it the Case for Health data Sets?", *Cadernos de Saúde Pública*, 2001, 17, 5, 1059-1081.
- [6] Câmara, G. et al., "SPRING and TerraLib: Integrating Spatial Analysis and GIS", *Center for Spatially Integrated Social Science. Specialist Meeting on Spatial Data Analysis Software Tools*. Santa Barbara, CA. 2002, Maio.
- [7] Couclelis, H., "Geocomputation in context", In Longley, P.A.; Brooks, S.M.; McDonnell, R. & Macmillan, B. (Eds), *Geocomputation, a primer*. Chichester: John Wiley and Sons, 1998.
- [8] Crepani, E.; Medeiros, J.S. de; Hernadez Filho, P. et al, Sensoriamento remoto e geoprocessamento aplicados ao zoneamento ecológico-econômico e ao ordenamento territorial. 2001. INPE-8454-RPQ/722.
- [9] Cereghino, R.; Giraudel, J.L.; Compin, A. , "Spatial analysis of stream invertebrates distribution in the Adour-Garonne drainage basin (France), using Kohonen self organizing maps", *Ecological Modelling*, 2001, 146, 1-3, 167-180.
- [10] Ehlen, J.; Caldwell, R. & Harding, S., "GeoComputation: what is it", *Computers, Environment and Urban Systems*, 2002, 26, 257-265.
- [11] Fischer, M.M., "Computational neural networks: a new paradigm for spatial analysis", *Environment and Planning A*, 1998, 30, 10, 1873-1891.
- [12] Foody, G.M., "Applications of the self-organising feature map neural network in community data analysis", *Ecological Modelling*, 1999, 120, 97-107.
- [13] Fucks, S.D.; Carvalho, M. S.; Câmara, G. & Monteiro, A.M.V.(ed), *Análise espacial de dados geográficos*, 2 ed., São José dos Campos, INPE, Julho, 2002. URL: <http://www.dpi.inpe.br/gilberto/livro/analise>.
- [14] Gahegan, M., "What is Geocomputation?", *Transactions in GIS*, 1999, 3, 203-206.
- [15] Gahegan, M.; Takatsuka, M.; Wheeler, M.; Hardisty, H., "Introducing GeoVISTA Studio: an integrated suite of visualization and computational methods for exploration and knowledge construction in geography", *Computers, Environment and Urban Systems*, 2002, 26, 267-292.
- [16] Haykin, S., *Redes Neurais: princípios e práticas*, Bookman, Porto Alegre, 2001.
- [17] Hewitson, B.C. & Crane, R.G., *Neural nets: applications in geography*, Kluwer, 1994.
- [18] Hilbert, D.W.; Ostendorf, B.; Hopkins, M.S., "Sensitivity of tropical forests to climate change in the humid tropics of north Queensland", *Austral Ecology*, 2001, 26, 6, 560-603.
- [19] Ji, C. Y., "Land-use classification of remotely sensed data using self-organizing feature map neural networks", *Photogrammetric Engineering & Remote Sensing*, 2000, 66, 12, 1451-1460.
- [20] Lee, S.; Cho, S. & Wong, P.M., "Rainfall Prediction Using Artificial Neural Networks", *JouRNAL of Geographic Information and Decision Analysis*, 1998, 2, 2, 233 – 242.
- [21] Medeiros, J.S., "Banco de dados geográficos e redes neurais artificiais: tecnologias de apoio à gestão do território", Tese doutorado, Departamento de Geografia – FFLCH – USP, São Paulo, Julho, 1999.
- [22] Murnion, S.D., "Spatial analysts using unsupervised neural networks", *Computers & Geosciences*, 1997, 22, 9, 1027-1031.
- [23] Nobrega, R.P., "Análise Espacial 'knowledge-driven' e 'data-driven': o Uso das Lógicas Booleana, Fuzzy e Redes Neurais para Geração de Mapas de Favorabilidade Mineral na Região Centro-Oeste da Bahia", Dissertação de Mestrado, Unicamp, 2001.
- [24] Openshaw, S. & Turton, I., "A parallel Kohonen algorithm for the classification of large spatial datasets", *Computers & Geosciences*, 1996, 22, 9, 1019-1026.
- [25] Openshaw, S. & Openshaw, C., *Artificial intelligence in geography*, John Wiley, 1997.
- [26] Openshaw, S. & Abrahart, S.J. (Eds.), "Geocomputation", Taylor & Francis, London, 2000. 436pp.
- [27] Openshaw, S. & Turner, A., MEDALUS III: Project 3: Module 9: Topic 9.1: GIS based socio-economic modelling, 2002. URL: <http://www.geog.leeds.ac.uk/staff/a.turner/projects/medalus3/home.htm>
- [28] Rodrigue, J.P., "Parallel modelling and neural networks: An overview for transportation land use systems", *Transportation Research Part C – Emerging Technologies*, 1997, 5, 5, 259-271.
- [29] Rosa, D. de la; Mayol, F.; Moreno, J. A.; Bonsón, T.; Lozano, S., "An expert system/neural network model (ImpelERO) for evaluating agricultural soil erosion in Andalusia region, southern Spain", *Agriculture, Ecosystems and Environment*, 1999, 73, 211-226.
- [30] Sung, D.G.; Lim, S.H.; Ko, J.W.; Cho, G.S., "Scenic evaluation of landscape for urban design purposes using GIS and ANN", *LANDSCAPE AND URBAN PLANNING*, 2001, 56, 1-2, 75-85.
- [31] Winter, K. & Hewitson, B.C., "Self organizing maps – applications to census data", In: Hewitson, B.C. & Crane, R.G., *Neural nets: applications in geography*, Kluwer, 1994.