

Utilização de redes neurais artificiais para predição de classes de solo em uma bacia hidrográfica no Domínio de Mar de Morros

César da Silva Chagas¹
Elpídio Inácio Fernandes Filho²
Carlos Antônio Oliveira Vieira³
Waldir de Carvalho Júnior¹

¹ Embrapa Solos
Rua Jardim Botânico, 1024 - 22460-000 - Rio de Janeiro - RJ, Brasil
cschagas@uai.com.br; waldircj@cnps.embrapa.br

² Universidade Federal de Viçosa - UFV/DPS
Avenida P. H. Rolfs s/n - Campus UFV - 36570-000 - Viçosa - MG, Brasil
elpidio@ufv.br

³ Universidade Federal de Viçosa - UFV/DEC
Avenida P. H. Rolfs s/n - Campus UFV - 36570-000 - Viçosa - MG, Brasil
carlos.vieira@ufv.br

Abstract. The use of neural networks and the maximum likelihood algorithm for predictions of soil classes were evaluated for the northwest region of the state of Rio de Janeiro, Brazil. The discriminating variables used in this experiment were: geology, elevation, slope, aspect, plan curvature, topographic index (CTI) and three indexes, derived from the LANDSAT 7 image. The neural networks simulator used was the "Neural Java Network Simulator". The statistical experiments performed showed that the neural networks classifier products were significantly better to the Maximum Likelihood. The maps produced by both classifiers showed low agreement, as well as with the conventional map. A comparison using field collected independent points showed that the accuracy of the map produced by the neural networks is greater (70,83%) than classifications using either the conventional approach (52,77%) or the Maximum Likelihood classifications (50,69%).

Palavras-chave: soil survey, neural networks, maxver, levantamento de solos, redes neurais, maxver.

1. Introdução

O levantamento de solos produzido pelo método convencional é a principal fonte de informação espacial sobre solos para diferentes usos. No entanto, a abordagem qualitativa da paisagem utilizada nestes levantamentos, através da interpretação de fotografias aéreas, tem sido bastante criticada por não possibilitar o entendimento das relações quantitativas que ocorrem entre as formas do terreno e os solos e suas propriedades (McBratney et al., 2000).

Nos últimos anos, vários métodos quantitativos (Odeh et al., 1992; McKenzie e Austin, 1993; Moore et al., 1993; McKenzie e Ryan, 1999; Dobos et al. 2000; Zhu, 2000) foram desenvolvidos para descrever, classificar e estudar os padrões de distribuição espacial dos solos, de maneira mais objetiva e precisa. Estes métodos estão coletivamente enquadrados em um campo emergente da ciência do solo conhecido como pedometria (McBratney et al., 2000). As técnicas pedométricas básicas usadas na predição espacial do solo são a abordagem clássica, coletivamente referida como métodos de correlação ambiental e os métodos geoestatísticos. Estudos de correlação ambiental utilizando redes neurais estão sendo amplamente empregados na ciência do solo, principalmente para estimativa de atributos do solo (McBratney et al., 2003).

Redes neurais são uma técnica de inteligência artificial e são da mesma família dos sistemas especialistas e abordagens baseadas em conhecimento para aprendizagem (Key et al.,

1989). As principais vantagens das redes neurais são: a possibilidade de manipulação eficiente de grandes quantidades de dados e sua capacidade de generalização. Entretanto, as principais razões para seu uso são que as redes neurais não assumem nenhum tipo de distribuição dos dados *a priori*, diferentemente da abordagem estatística paramétrica tradicional, que assume que os dados possuem uma distribuição normal; e a habilidade para manipular dados adquiridos de diferentes fontes e com diferentes níveis de precisão e ruídos.

Com relação ao sensoriamento remoto, onde as redes neurais têm uma ampla possibilidade de aplicação, maior atenção tem sido dada ao reconhecimento de padrões. A habilidade para aprender por meio de exemplos e para generalizar torna as redes neurais artificiais atrativas para a classificação supervisionada de dados do sensoriamento remoto (Schalkoff, 1992).

A aplicação de redes neurais em estudos de solos pode ser encontrada em muitos trabalhos (Minasny e McBratney, 2002; Chang e Islam, 2000). Uma abordagem por redes neurais foi desenvolvida por Zhu (2000) para alimentar um modelo de similaridade, construído para representar a paisagem do solo como um contínuo espacial, para modelagem hidroecológica de bacias ao nível de média escala. Neste trabalho, os dados de entrada na rede foram representados por um conjunto de fatores ambientais formativos do solo e os dados de saída (resultados) por um conjunto de valores de similaridade a um conjunto de classes de solos prescritas. A rede foi treinada usando-se um algoritmo de gradiente conjugado em combinação com uma técnica de fortalecimento simulado para aprender as relações entre um conjunto de solos prescritos e os seus fatores ambientais. Esta abordagem foi aplicada no mapeamento de solos de uma bacia na região oeste de Montana (EUA). Os resultados deste estudo mostraram que a informação espacial derivada do uso da rede neural revelou detalhes muito maiores e tiveram uma qualidade muito maior do que aqueles derivados do mapa de solo convencional.

Relatos da utilização de redes neurais para predição de classes de solos não são muito frequentes na literatura mundial. Diante deste contexto, o presente estudo tem por objetivo utilizar redes neurais artificiais para predição de classes de solos, utilizando como fonte de dados sensores remotos orbitais e atributos do terreno derivados de um modelo digital de elevação (MDE), em uma região montanhosa no Noroeste Fluminense, visando avaliar a real possibilidade de utilização desta abordagem para tornar os levantamentos de solos mais eficientes, quantitativos e científicos.

2. Material e Métodos

O estudo foi desenvolvido na bacia hidrográfica do rio São Domingos, afluente do rio Muriaé, ambos pertencentes ao complexo hidrográfico do rio Paraíba do Sul. A bacia, que apresenta uma área aproximada de 28.000 ha, está situada entre as coordenadas UTM 7.620.700 e 7.647.200m N e 183.000 e 210.800m E, zona 24S, englobando a totalidade do município de São José de Ubá e parte do município de Itaperuna, no Noroeste do Estado do Rio de Janeiro.

O método empregado para a predição das classes de solos da bacia do Rio São Domingos utiliza uma abordagem por redes neurais, conforme Zhu (2000) e ilustrado na **Figura 1**. Esta abordagem é baseada no conceito solo-paisagem desenvolvido por Jenny (1941), segundo o qual o solo é o resultado das interações entre os fatores de formação ao longo do tempo. Visto que é muito difícil, ou quase impossível, quantificar o fator tempo, principalmente em solos tropicais poligenéticos, e como esta informação muitas vezes está implícita em outros fatores de formação, a equação foi simplificada como mostrado na **Figura 1** (Zhu, 2000).

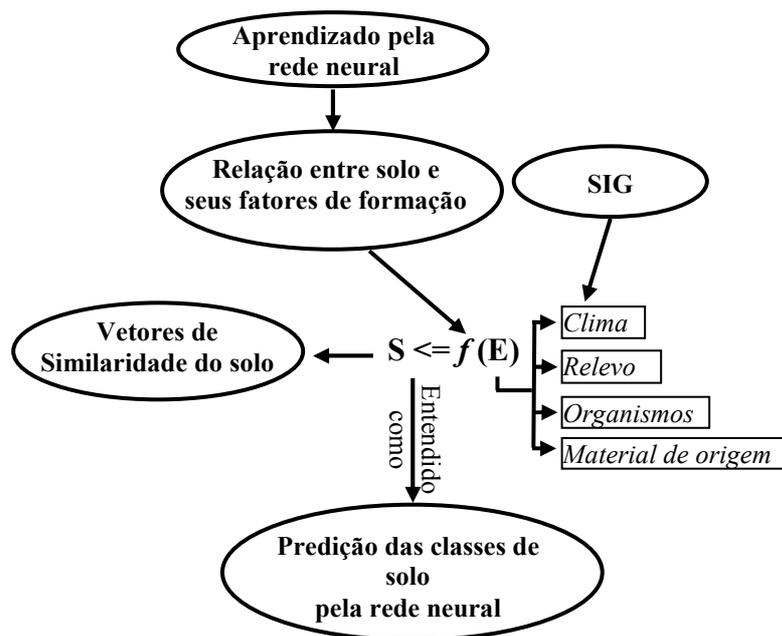


Figura 1. Predição das classes de solos baseada na abordagem por redes neurais.

As variáveis ambientais utilizadas para auxiliar na predição das classes de solo da bacia do rio São Domingos foram: elevação, declividade, aspecto, curvatura, índice topográfico combinado (índice de umidade), derivadas de um MDE (30m) obtido utilizando-se o módulo TOPOGRID do software ARC/INFO (ESRI, 1997), a partir das curvas de nível (20m), hidrografia e pontos cotados contidos nas cartas topográficas do IBGE, na escala de 1:50.000; geologia, na escala de 1:50.000 (DRM, 1980) e três índices derivados de uma imagem do sensor ETM+ do satélite LANDSAT 7, índice de vegetação (NDVI), índice “clay minerals” (C) e índice “iron oxide” (O). As variáveis foram, então, combinadas e avaliadas quanto à capacidade de discriminação dos solos da bacia, perfazendo um total de 8 combinações.

Na bacia do rio São Domingos foram identificadas 22 classes de solo, divididas entre duas unidades geológicas principais, que são: granulitos da Unidade São José de Ubá (Área 1) e migmatitos das Unidades Vista Alegre, São João do Paraíso, Catalunha e milonitos gnaisses da Unidade Santo Eduardo (Área 2). A descrição e as características de cada uma destas classes pode ser obtida em Chagas (2006).

O simulador de redes neurais utilizado foi o “Java Neural Network Simulator”, baseado no *Stuttgart Neural Network Simulator 4.2 Kernel* (Zell et al., 1996), e o algoritmo de aprendizado usado foi o “backpropagation”. Foram coletados dois conjuntos de amostras independentes, um para treinamento (300 amostras para cada classe) e outro para validação ou teste (150 amostras).

Na etapa de treinamento e validação diferentes arquiteturas foram testadas: variando o nº de neurônios na camada de entrada (nº de variáveis ambientais); variando o nº de neurônios na camada interna e/ou nº de camadas internas; e todas tendo o mesmo nº de neurônios na camada de saída (12 classes de solo para a Área 1 e 10 para a Área 2).

O treinamento das redes utilizando um aprendizado supervisionado consistiu dos seguintes procedimentos: a) alocação aleatória dos pesos interneurônios entre -0,5 e 0,5 e b) utilização de uma taxa de aprendizado de 0,2, considerando 10.000 ciclos de aprendizagem. Uma vez treinadas as redes foram submetidas à validação. Finalmente, a rede escolhida em cada área foi utilizada na predição das classes de solos da bacia do rio São Domingos. A fim

de permitir uma comparação as mesmas amostras utilizadas no treinamento e validação das redes neurais foram utilizadas no treinamento e validação pelo MAXVER.

A avaliação dos resultados constou da determinação do nível de exatidão da classificação (índice Kappa) e da exatidão global da classificação das redes neurais e do MAXVER, através da análise da matriz de confusão (Congalton and Green, 1999). Uma matriz de significância de Kappa entre as redes e o MAXVER foi também gerada para verificar a existência de diferenças significativas ou não entre os resultados obtidos. Os resultados alcançados com a abordagem pelas redes neurais e pelo MAXVER (mapas inferidos) foram comparados com o mapa de solos da bacia produzido com a metodologia convencional de levantamento de solos. Complementando os testes de validação foi realizada uma amostragem de campo em locais escolhidos aleatoriamente, para determinar a porcentagem de locais classificados corretamente nos mapas. Esta comparação foi realizada através da criação de uma matriz de confusão. Finalmente, foi gerada uma matriz de significância de Kappa entre os mapas inferidos e o mapa de solos convencional, para verificar a existência de diferenças significativas ou não entre os resultados obtidos para a comparação com os pontos de referência.

3. Resultados e Discussão

Ao todo 8 conjuntos de variáveis ambientais foram avaliados com relação ao desempenho do índice Kappa. Embora o SSE (*sum square error*) e o MSE (*mean square error*) sejam utilizados normalmente como medidas do desempenho das redes neurais, estes não se mostraram adequados para a escolha do melhor conjunto de variáveis para a discriminação dos solos da área estudada. O índice Kappa obtido pelas redes neurais avaliadas variou bastante com as variáveis ambientais utilizadas e com número de neurônios na camada interna. O melhor desempenho foi obtido quando se utilizou os atributos do terreno junto com três índices da imagem do sensor ETM⁺ do LANDSAT 7 (conjunto 1), com um valor para o índice Kappa de 0,908 para uma rede neural com 8 neurônios na camada interna (Área 1) e de 0,893 para uma rede neural com 5 neurônios na camada interna (Área 2). Estes resultados diferem significativamente, ao nível de 95%, de todos os demais conjuntos testados, tanto para a Área 1 quanto para a Área 2. Embora não apresentem uma relação direta com os fatores de formação do solo, os índices derivados da imagem do sensor ETM⁺ do LANDSAT 7, utilizados como variáveis adicionais contribuíram para melhorar a discriminação das classes de solo.

A definição do melhor conjunto de variáveis discriminantes para ser utilizado na classificação pelo MAXVER foi feita do mesmo modo como realizado para as redes neurais. Nesta avaliação, o melhor desempenho para a Área 1 também foi obtido com a utilização dos atributos do terreno e todos os índices do sensor ETM⁺ do LANDSAT 7 como variáveis ambientais (Kappa de 0,830), resultado que não é estatisticamente diferente apenas daqueles obtidos pelo conjunto 6 (atributos do terreno + índice “iron oxide”) que produziu um índice Kappa de 0,812. No entanto, para a Área 2 o melhor desempenho foi obtido com a utilização apenas dos atributos do terreno (Kappa de 0,750), que não é estatisticamente diferente daqueles obtidos para os conjuntos 5 (atributos do terreno + índice “clay minerals”) e 6 (atributos do terreno + índice “iron oxide”). A incorporação do índice NDVI piorou a classificação de quase todos os conjuntos, com exceção do conjunto 1.

Na etapa final da avaliação foi realizada a comparação entre o desempenho da classificação pela rede neural e pelo MAXVER para ambas as áreas. A análise da matriz de significância de Kappa (**Tabela 1**) indica haver diferença significativa entre estas classificações. Estes resultados concordam com aqueles obtidos por outros autores (Paola e Schowengerdt, 1995; McBratney et al, 2000), onde de modo geral, a abordagem por redes

neurais tem apresentado um desempenho superior àquele obtido pelo MAXVER, principalmente na classificação de dados de sensores remotos.

Tabela 1. Matriz de significância de Kappa para os classificadores considerados.

Classificador	Área 1		Área 2	
	Rede Neural	MAXVER	Rede Neural	MAXVER
Exatidão global	91,6	84,4	90,4	77,5
Kappa	0,908	0,830	0,893	0,750
Variância	0,000051	0,000086	0,000071	0,000142
Rede neural	127,145		105,98	
MAXVER	6,66*	89,50	9,80*	62,94

* existe diferença significativa ao nível de 95%.

A rede neural escolhida para cada área, depois de treinadas e validadas, juntamente com o MAXVER, foram utilizadas para predição das classes de solo da bacia do rio São Domingos. Para tanto, as informações sobre as variáveis ambientais, de cada pixel na imagem considerada, foram apresentadas às redes e ao classificador MAXVER. Uma vez que todos os pixels foram visitados, os classificadores computaram o resultado final. No caso da classificação pelas redes neurais, o mapa final foi obtido através da conversão da representação de similaridade (Zhu, 2000). A conversão foi feita atribuindo a cada pixel o valor correspondente à classe que apresentou a maior porcentagem de saída da rede, entre todas as classes envolvidas (Zhu, 1997). Em seguida, os mapas obtidos para cada área (1 e 2) foram unidos para formar o mapa de solos da bacia do rio São Domingos para os classificadores utilizados.

Os mapas produzidos por estes classificadores mostram-se bastante distintos, com uma concordância de apenas 49,68%, evidenciando a natureza distinta dos modelos matemáticos presentes nestes classificadores e o modo como eles dividem o espaço (Kanellopoulos e Wilkinson, 1997).

Na **Figura 2** é possível verificar que os mapas inferidos (*a* e *b*) contêm muito mais detalhes espaciais do que o mapa de solos convencional (*c*). Neste sentido, a utilização dos atributos do terreno e da geologia permitiu estabelecer com maior precisão as relações que ocorrem na área da bacia, possibilitando a obtenção de mapas espacialmente mais detalhados, utilizando-se o mesmo conjunto de perfis de solos usados pela abordagem convencional.

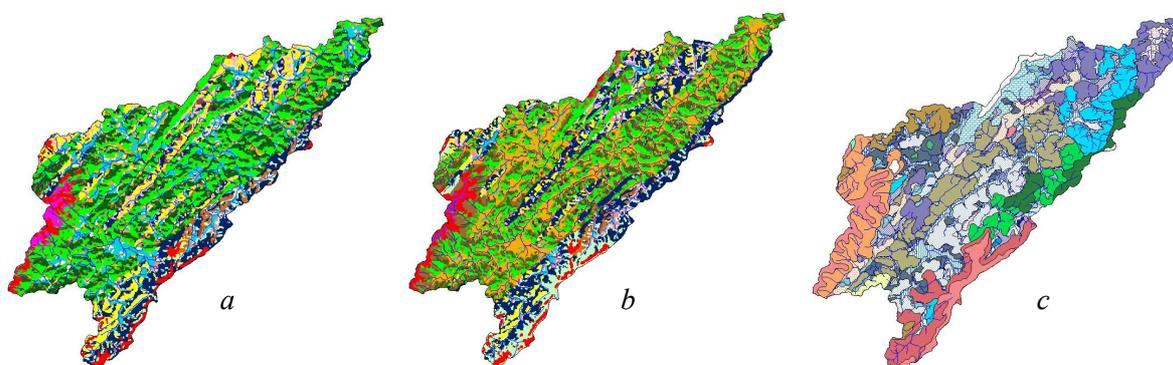


Figura 2. a) mapa de classes de solos produzido pela classificação por redes neurais; b) mapa de classes de solos produzido pela classificação pelo MAXVER; e c) mapa de solos produzido pelo método convencional.

Os resultados das comparações entre os mapas inferidos e o mapa convencional são apresentados na **Figura 3**. Os mapas inferidos não produziram uma boa concordância com o mapa de solos convencional. Esta foi de apenas 37,15% e 31,51%, para a concordância do mapa de solos convencional com a classificação pelas redes neurais e com a classificação pelo MAXVER, respectivamente.

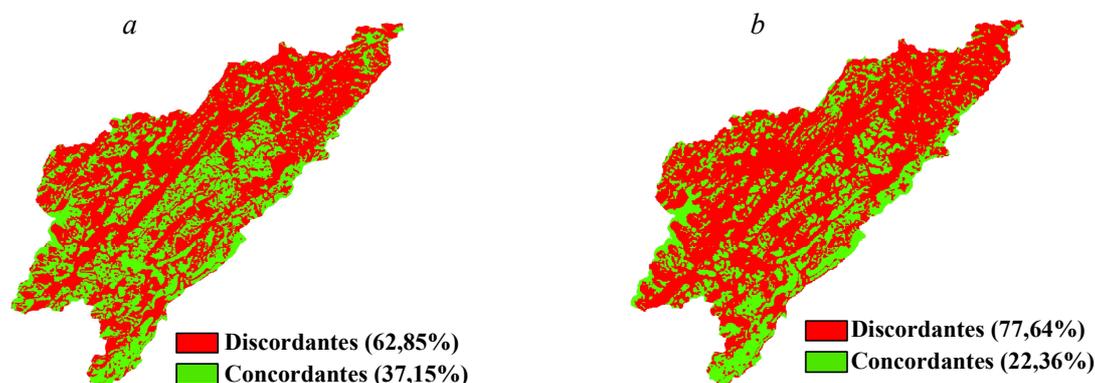


Figura 3. a) Comparação entre o mapa de solos produzido pelo classificador por redes neurais e o mapa de solos convencional; b) Comparação entre o mapa de solos produzido pelo classificador MAXVER e o mapa de solos convencional.

A elevada discordância obtida para as comparações pode ser atribuída em grande parte a natureza generalizada do mapa de solos convencional. Outra possível fonte de discordância é a natureza geológica bastante complexa da área que em algumas partes da bacia dificultou o correto estabelecimento das relações solo-paisagem, fundamentais para o perfeito desempenho da abordagem testada. Além desta complexidade, em algumas partes da bacia a profundidade de exposição das rochas tem uma importância grande na distribuição dos solos, superando muitas vezes a influência da morfometria da superfície. Pela dificuldade de obtenção, os aspectos relacionados acima não puderam ser incorporados ao modelo preditivo, o que contribuiu certamente para aumentar a discordância com o mapa de solos convencional.

288 pontos foram utilizados para verificar a concordância com os mapas produzidos. Os resultados destas comparações são mostrados nas **Tabelas 2 e 3**. No caso do mapa convencional, para as unidades compostas, foram considerados como corretos os pontos nos quais a classe observada é qualquer um dos componentes da associação. A mesma regra foi aplicada para os mapas inferidos, nos casos em que mais de uma classe de solo é observada em um determinado pixel, devido às limitações descritas anteriormente.

Tabela 2. Comparação entre os pontos de referência e os mapas produzidos.

Mapas	Total de pontos	Pontos corretamente classificados	% corretamente classificada
Redes neurais	288	204	70,83
MAXVER	288	146	50,69
Convencional	288	152	52,77

A matriz de significância de Kappa apresentada na **Tabela 3** indica haver diferença significativa entre as classificações avaliadas. Os melhores resultados foram obtidos pela abordagem por redes neurais que apresentou índice Kappa de 0,678 e variância de 0,000837,

sendo significativamente diferente dos resultados obtidos com a utilização do MAXVER e pelo mapa de solos convencional, que por sua vez, não apresentaram diferenças significativas.

Tabela 3. Matriz de significância de Kappa para as classificações consideradas.

Classificação	Rede neural	MAXVER	Mapa convencional
Exatidão global	70,83	50,69	52,77
Kappa	0,678	0,460	0,469
Variância	0,000837	0,000991	0,00099
Rede neural	23,44		
MAXVER	5,10 *	14,61	
Mapa convencional	4,89 *	0,20	14,91

* existe diferença significativa ao nível de 95%.

Na classificação pelas redes neurais uma importante causa de discordância com os pontos de referência está relacionada com os limites das unidades do mapa geológico. A maioria das observações erroneamente classificadas ocorre nos limites entre as unidades geológicas. Para exemplificar este fato, alguns solos que deveriam ser assinalados, no 4º nível do SiBCS, como abruptos ou abruptos câmbicos foram classificados pela rede neural como típicos ou vice-versa, devido às limitações do mapa geológico. Problemas relacionados com a qualidade de mapas geológicos utilizados em estudos de correlação ambiental também foram relatados por McKenzie e Ryan (1999).

No caso do mapa de solos convencional, embora muitos pontos de referência estejam localizados nos limites entre as unidades geológicas, a maioria das discordâncias está relacionada com o fato de que o mapa geológico da bacia não foi considerado para delimitação das unidades de mapeamento. No caso da classificação pelo MAXVER, embora os problemas com o mapa geológico também tenham sido constatados, as discordâncias com os pontos de referência são devidas, em sua maior parte, a ineficiência do próprio classificador.

4. Conclusões

O classificador baseado nas redes neurais produziu uma maior exatidão na classificação geral, com resultados significativamente melhores do que o classificador MAXVER. A exatidão geral da classificação para ambos os classificadores mostrou-se bastante influenciada pelo número de variáveis discriminantes utilizadas.

Os mapas inferidos contêm muito mais detalhes espaciais do que o mapa de solos convencional, pelo fato de que a variação ambiental pôde ser quantificada com grande detalhe utilizando-se um SIG. A disponibilidade de dados mais detalhados sobre as variáveis ambientais tornou possível reduzir as associações de solos e permitiu identificar pequenos componentes na paisagem que são difíceis de serem identificados pelo mapeamento convencional.

Os mapas inferidos tiveram uma baixa concordância com o mapa de solos convencional. As principais causas foram: limitação de escala do mapa convencional e maior detalhamento espacial dos mapas inferidos; dificuldade e inexatidão dos limites das unidades de mapeamento do mapa convencional; heterogeneidade geológica da área; profundidade do contato lítico; e problemas relacionados com o modelo de correlação ambiental utilizado.

A comparação com pontos de referência mostrou que o mapa produzido pela abordagem por redes neurais teve um desempenho melhor do que a abordagem convencional e do que o classificador MAXVER, sendo estatisticamente diferente destes.

O estudo mostra que a utilização de atributos do terreno e dados de sensores remotos em uma abordagem por redes neurais pode contribuir para tornar o mapeamento de solos no

Brasil mais quantitativo e confiável. A disponibilidade de dados de sensores remotos a custos mais baixos e a facilidade de obtenção dos atributos do terreno em um SIG comercial tornam a abordagem ainda mais atraente.

Referências

- ATKINSON, P. M.; TATNALL, A. R. L. Neural networks in remote sensing. **International Journal of Remote Sensing**, v.18, p.699-709, 1997.
- CHANG, D. H.; ISLAM, S. Estimation of soil physical properties using remote sensing and artificial neural network. **Remote Sensing of Environment**, v.74, p.534-544, 2000.
- CONGALTON, R. G.; GREEN, K., **Assessing the Accuracy of Remotely Sensed Data: Principles and Practices**, Lewis Publishers, New York, 1999.
- DEPARTAMENTO DE RECURSOS MINERAIS - DRM-RJ. **Projeto Carta Geológica do Estado do Rio de Janeiro na Escala 1:50.000. Folhas: Miracema e São João do Paraíso**. 1980.
- DOBOS, E.; MICHELI, E.; BAUMGARDNER, M. F.; BIEHL, L.; HELT, T. Use of combined digital elevation model and satellite data for regional soil mapping. **Geoderma**, v.97, p.367-391, 2000.
- JENNY, H. **Factors of soil formation; a system of quantitative pedology**. New York: McGraw-Hill, 1941. 281p.
- KANELLOPOULOS, I.; WILKINSON, G. G. Strategies and best practice for neural network image classification. **International Journal of Remote Sensing**, v.18, p.711-725, 1997.
- KEY, J.; MASLANIK, J. A.; SCHWEIGER, A. J. Classification of merged AVHRR and SMMR artice data with neural networks. **Photogrammetric Engineering and Remote Sensing**, v.55, p.1331-1338, 1989.
- McBRATNEY, A. B.; ODEH, I. O. A.; BISHOP, T. F. A.; DUNBAR, M. S.; SHATAR, T. M. An overview of pedometric techniques for use in soil survey. **Geoderma**, v.97, p.293-327, 2000.
- McBRATNEY, A. B.; SANTOS, M. L. M.; MINASNY, B. On digital soil mapping. **Geoderma**, v.117, p.3-52, 2003.
- MCKENZIE, N. J.; AUSTIN, M. P. A quantitative Australian approach to medium and small scale surveys based on soil stratigraphy and environmental correlation. **Geoderma**, v.57, p.329-355, 1993.
- MCKENZIE, N. J.; RYAN, P. J. Spatial prediction of soil properties using environmental correlation. **Geoderma**, v.89, p.67-94, 1999.
- MINASNY, B.; McBRATNEY, A. B. The neuro-m method for fitting neural network parametric pedotransfer functions. **Soil Science Society of America Journal**, v.66, p.352-361, 2002.
- MOORE, I. D. GESSLER, P. E.; NIELSEN, G. A.; PETERSON, G. A. Soil attribute prediction using terrain analysis. **Soil Science Society of America Journal**, v.57, p.443-452, 1993.
- ODEH, I. O. A.; McBRATNEY, A. B.; CHITTLEBOROUGH, D. J. Fuzzy-c-means and kriging for mapping soil as a continuous system. **Soil Science Society of America Journal**, v.56, p.1848-1854, 1992.
- PAOLA, J. D. & SCHOWENGERDT, R. A. A detailed comparison of backpropagation neural network and maximum-likelihood classifiers for urban land use classification. **IEEE Transactions on Geoscience and Remote Sensing**, v.33, p.981-996, 1995.
- SCHALKOFF, R. J. **Pattern Recognition: Statistical, Structural and Neural Approaches**. New York: John Wiley & Sons, 1992. 384p.
- ZELL, A.; MAMIER, G.; VOGT, M.; MACHE, N.; HUBNER, R.; DORING, S.; HERRMANN, K.; SOYEZ, T.; SCHMALZL, M.; SOMMER, T.; HATZIGEORGIOU, A.; POSSELT, D.; SCHREINER, T.; KETT, B.; CLEMENTE, G.; WIELAND, J.; GATTER, J. **Stuttgart Neural Network Simulator v4.2**. University of Stuttgart: Institute for Parallel and Distributed High Performance Systems/University of Tübingen - Wilhelm-Schickard-Institute for Computer Science - Department of Computer Architecture. 1996.
- ZHU, A. X. A similarity model for representing soil spatial information. **Geoderma**, v.77, p.217-242, 1997.
- ZHU, A. X. Mapping soil landscape as spatial continua: the neural network approach. **Water Resources Research**, v.36, p.663-677, 2000.