

Uso de dados de sensoriamento remoto em mapeamento digital de solos por redes neurais artificiais

Helena Saraiva Koenow Pinheiro ¹

César da Silva Chagas ²

Waldir de Carvalho Júnior ²

Lúcia Helena Cunha dos Anjos ¹

¹ Universidade Federal Rural do Rio de Janeiro - UFRRJ
BR 465, km 7- 23890-000 - Seropédica - RJ, Brasil
{koenow; lanjos}@ufrj.br

² Embrapa Solos - Rua Jardim Botânico, 1024 - 22460-000
Rio de Janeiro - RJ, Brasil
{waldircj, chagas}@cnps.embrapa.br

Abstract. The current demand for spatial information and the advance in processing of the machines has changed the course of the soil survey. The digital soil mapping arises in the context of improved the pedological surveys products through the use of GIS tools, knowledge of the genesis, morphology, and classification of soils, for selection appropriate attributes to represent reality, and produce a soil survey with accuracy and efficiency (cost x time). The approach used in digital soil mapping is based on the classical concepts of soil genesis and relations with terrain attributes. The objective was evaluating the effects of using remote sensing data in digital soil mapping of the river basin Guapi-Macacu (RJ). Were analyzed five different sets of attributes, in order to assess the contribution of three indices derived from remote sensing, in the performance of the classification by neural networks. They are: (i) all variables, (ii) all except clay minerals, (iii) all except iron oxide, (iv) all except NDVI, (v) all except the three indices. Image processing was performed with ERDAS and other attributes in ArcGIS v.10. The analyzes showed statistical differences between classifiers, highlighting the contribution of data derived from remote sensing. The criteria used in the evaluation (statistical indexes and concordance with the control points) indicate the set (iv) as the most suitable to represent the soil map of the area, although better performance of statistical indices has been obtained by the set (i).

Palavras-chave: NDVI, spectral indices, supervised classification, soil survey, NDVI, índices espectrais, classificação supervisionada, levantamento de solos.

1. Introdução

O uso de técnicas computacionais modernas para análise da distribuição de dados espaciais tem contribuído para maior rapidez e menor custo de execução dos levantamentos de solos, quando comparados aos métodos tradicionais, tornando-os mais quantitativos e possibilitando avaliar as incertezas inerentes à amostragem. Dados de sensoriamento remoto orbital e atributos topográficos de modelos digitais de elevação são amplamente utilizados na compreensão das relações espaciais e temporais, entre classes de solos e componentes da paisagem (Dobos et al., 2000; McBratney et al., 2003; Minasny e McBratney, 2007).

O estudo das relações solo-paisagem através de técnicas de geoprocessamento utiliza variáveis quantitativas representadas pelos modelos numéricos contínuos das componentes da superfície. A interpretação destas informações em ambiente de sistemas de informações geográficas (SIG's) é fundamentada no agrupamento de dados com padrões semelhantes.

Os índices derivados das imagens podem aprimorar o desempenho da classificação supervisionada devido à contribuição de informações espaciais relativas à vegetação, mineralogia, regime climático, entre outras (Sabins, 1997; Yang et al., 1997).

O objetivo deste estudo compreende a avaliação dos efeitos de três índices derivados de dados de sensoriamento remoto (SR), no mapeamento digital de solos por redes neurais artificiais (RNA's), da bacia hidrográfica do rio Guapi-Macacu (RJ).

2. Metodologia de Trabalho

2.1. Caracterização da Área de Estudo

A área estudada compreende a bacia hidrográfica do rio Guapi-Macacu, que por sua vez, pertence à região hidrográfica da Baía de Guanabara, no Estado do Rio de Janeiro (Figura 1).

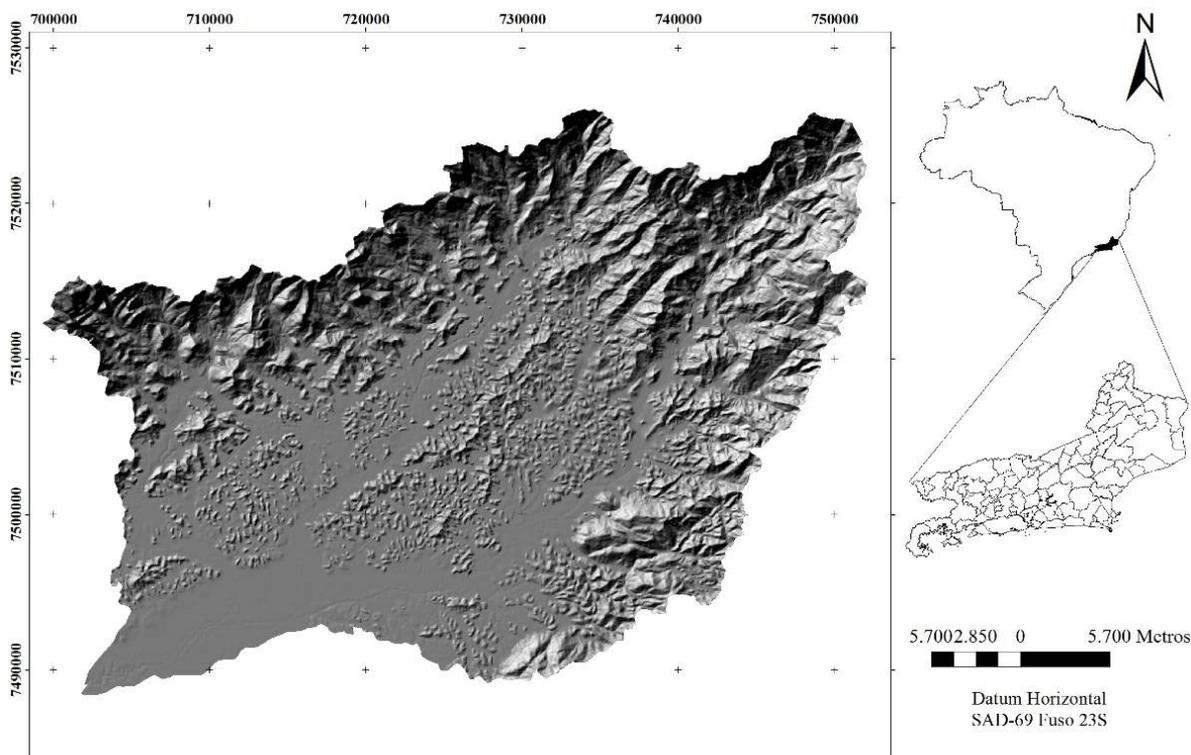


Figura 1. Localização da bacia hidrográfica do Rio Guapi-Macacu, com destaque para rugosidade do relevo.

O clima da região é caracterizado como tropical chuvoso com inverno seco (Aw) segundo Köppen (1948), com baixas temperaturas no inverno. A temperatura média da região é de 23°C, e a precipitação média anual aproximada é de 1.200 mm, embora alcance cerca de 2.000mm, nas cotas mais elevadas (Ecologus-Agrar, 2003). O bioma pertence ao domínio da Mata Atlântica com diversas fitofisionomias (campos de altitude, florestas densas, mangues, brejos, rios e estuários), conforme observado por Pedreira et al. (2009).

2.2. Obtenção das Variáveis Discriminantes

As variáveis discriminantes usadas para identificar os padrões morfométricos de ocorrência das unidades de mapeamento, assim como a importância destas pra compreensão das relações solo-paisagem através da representação espacial (quantitativa e contínua), da variabilidade dos fatores de formação dos solos, são apresentadas na Tabela 1.

Tabela 1. Fatores de formação dos solos e variáveis ambientais correspondentes.

Fatores de Formação	Variáveis Ambientais	Implicações na Pedogênese
Organismos	NDVI	Vegetação, comportamento hidrológico
Relevo	Elevação, Declividade, Curvatura, Índice Topográfico Combinado (CTI) e Distância Euclidiana	Intemperismo, variações climáticas, umidade e outras propriedades dos solos
Material de Origem e Tempo	Unidades Litológicas, <i>Clay Minerals, Iron Oxide</i>	Produtos do intemperismo, natureza mineral, susceptibilidade à erosão

* adaptado de McKenzie e Ryan (1999) e Chagas (2006).

Os modelos numéricos que representam os componentes topográficos (altimetria, declividade, curvatura, índice topográfico combinado e distância euclidiana da hidrografia), foram derivados de um modelo digital de elevação (MDE), obtido por interpolação de dados primários de elevação extraídos de cartas topográficas do IBGE, em escala de 1: 50.000 (IBGE, 1971, 1974, 1979a, 1979b, 1983 e BRASIL, 1997). A derivação das variáveis topográficas a partir do MDE foi realizada por ferramentas de cálculo do programa ArcGIS Desktop v. 10. O tema que representa a geologia foi baseado em mapas na escala 1:50.000 (DRM 1979, 1980a, 1980b, 1980c, 1981a, 1981b, 1984). Os três índices derivados dos dados do sensor remoto, objeto do presente estudo, foram derivados a partir de cálculos entre as bandas espectrais do imageamento do sensor TM do satélite Landsat 5, com resolução espacial de 30 m e resolução espectral representada pela composição de 7 bandas.

O cálculo dos índices espectrais foi efetuado no programa ERDAS Imagine v.9.1, através das sintaxes apresentadas abaixo, onde a equação (1) representa o índice de vegetação da diferença normalizada – NDVI, (2) representa o índice *clay minerals*, e (3) representa o índice *iron oxide*.

$$NDVI = \frac{\text{banda 3} - \text{banda 4}}{\text{banda 3} + \text{banda 4}} \quad (1)$$

$$\text{clay minerals} = \frac{\text{banda 5}}{\text{banda 7}} \quad (2)$$

$$\text{iron oxide} = \frac{\text{banda 3}}{\text{banda 1}} \quad (3)$$

Para identificação das classes de solos e caracterização das unidades de mapeamento, foi realizada campanha de campo com coleta de amostras e descrição morfológica de perfis, segundo as normas técnicas descritas em EMBRAPA (1997, 2006) e Santos et al (2005).

As informações obtidas *in situ* subsidiaram a compreensão da variabilidade das características das unidades, assim como a coleta de amostras para treinamento e validação da classificação supervisionada por redes neurais artificiais (RNAs).

2.3. Processamento dos Dados e Classificação por Redes Neurais Artificiais

As unidades de mapeamento definidas (classes de saída) foram: Argissolo Amarelo (PA), Argissolo Vermelho-Amarelo (PVA), Cambissolo Háplico (CX), Gleissolo Háplico + Gleissolo Melânico (GX + GM), Gleissolo Sáfico + Gleissolo Tiomórfico (GS + GJ), Latossolo Amarelo (LA), Latossolo Vermelho-Amarelo (LVA), Neossolo Flúvico e Neossolo

Litólico (RY e RL, respectivamente). Conforme descrito anteriormente, estas unidades foram definidas após vistoria em campo para identificação dos solos e das relações solo-paisagem.

Para análise conjunta das variáveis discriminantes (elevação, declividade, curvatura, índice CTI, distância euclidiana, geologia, índice *clay minerals*, índice *iron oxide* e índice NDVI), foi realizado o reescalonamento dos respectivos modelos. O procedimento consiste na padronização do intervalo de variação dos valores dos atributos (entre 0 e 1). O cálculo de algébrico foi efetuado no módulo “*Raster Calculator*”, do ArcGIS Desktop v.10.

Os conjuntos de variáveis utilizadas na classificação por RNAs correspondem aos seguintes grupos: (i) Todas (elevação, declividade, curvatura, índice topográfico combinado - CTI, distância euclidiana, geologia, índice *clay minerals*, índice *iron oxide* e índice NDVI); (ii) Todas exceto o índice *clay minerals*; (iii) Todas exceto o índice *iron oxide*; (iv) Todas exceto o índice NDVI; (v) Todas exceto os índices *clay minerals*, *iron oxide* e NDVI.

A classificação supervisionada pelo simulador de redes neurais artificiais (RNA's) foi realizada no programa JavaNNS (*Java Neural Network Simulator- Version 1.1 –University of Tubingen*, 2001). Este programa é baseado no Stuttgart Neural Network Simulator 4.2 Kernel (SNNS, 1998) que utiliza o algoritmo de aprendizado por retropropagação (*backpropagation*). As amostras de treinamento e validação utilizadas na classificação supervisionada foram coletadas em função da variabilidade das características locais de ocorrência das unidades de mapeamento. Foram coletadas 350 amostras para treinamento e 150 para validação, distintas entre si, para cada classe de solo identificada, conforme as recomendações de Zhu (2000).

A avaliação da influência dos índices de sensoriamento remoto na predição espacial da ocorrência das classes de solos compreendeu a análise do desempenho da classificação das RNAs dos distintos conjuntos de variáveis discriminantes, que compara individualmente a contribuição individual dos três índices derivados de SR, através de parâmetros estatísticos obtidos por uma matriz de confusão (exatidão global e índice Kappa) e concordância com pontos de controle desconhecidos das redes.

A avaliação do índice de concordância dos produtos da classificação e pontos de controle foi feita com amostras georreferenciadas, utilizados em outros estudos realizados na bacia, totalizando 120 pontos de controle, não utilizados no treinamento e validação das redes neurais.

3. Resultados e Discussão

O desempenho dos conjuntos de RNA's foi avaliado por meio de parâmetros estatísticos oriundos de uma matriz de confusão, conforme descrito por Congalton e Green (1999). A Tabela 2 mostra um comparativo destes índices e a contribuição de cada conjunto em relação ao conjunto (i), com todas as variáveis discriminantes.

Tabela 2. Índices obtidos nas matrizes de confusão das RNA's dos conjuntos avaliados.

Conjuntos	Exatidão Global	Índice Kappa	Contribuição
(i) <i>todas</i> ⁽¹⁾	85,2	0,833	-
(ii) exceto <i>clay minerals</i>	79,8	0,772	0,061
(iii) exceto <i>iron oxide</i>	78,7	0,761	0,072
(iv) exceto NDVI	83,0	0,809	0,024
(v) sem os três índices	77,9	0,752	0,081

⁽¹⁾ elevação, declividade, curvatura, índice CTI, distância euclidiana, geologia, índice *clay minerals*, índice *iron oxide* e índice NDVI

A rede treinada com todas as variáveis discriminantes (i), mostrou melhor desempenho estatístico, com exatidão de 85,2% e Kappa de 0,833. Em contrapartida, a rede (v), que não utilizou as variáveis derivados dos dados de sensoriamento remoto (*clay minerals*, *iron oxide*

e NDVI) mostrou pior desempenho dos índices estatísticos (exatidão global de 77,9% e 0,75 para o índice Kappa), corroborando os resultados obtidos por Chagas (2006).

A Tabela 3, a seguir, apresenta os resultados obtidos para exatidão da classificação das unidades de mapeamento (classes de saída) para os conjuntos considerados nesta análise.

Tabela 3. Índices de exatidão dos classificadores, compilados das matrizes de confusão.

RNA	PA	PVA	CX	GX	GS+GJ	LA	LVA	RY	RL	Kappa	Var. ⁽¹⁾
(i)	90,0	98,7	70,0	72,0	94,7	76,7	86,0	88,0	90,7	0,833	0,118
(ii)	97,3	96,0	59,3	47,3	87,3	58,7	93,3	85,3	93,3	0,772	0,149
(iii)	87,3	100,0	64,0	85,3	94,0	50,7	91,3	54,0	82,0	0,761	0,155
(iv)	84,7	97,3	80,7	82,7	88,0	74,7	72,7	77,3	89,3	0,809	0,132
(v)	86,7	98,7	78,7	51,3	75,3	85,3	81,3	62,0	82,0	0,752	0,161

Var. ⁽¹⁾= Variância; valores multiplicados por mil

Avaliando os resultados dos conjuntos (ii) e (iii), para as classes GX e RY, foi possível observar que apresentam comportamento inverso dos valores de exatidão do produtor. Provavelmente isso ocorre devido ao próprio comportamento inverso das variáveis em questão, ou seja, regiões com valores elevados para *clay minerals* apresentam valores reduzidos para *iron oxide*, mas principalmente porque as informações fornecidas por estes índices refletem o tipo de uso, ou cobertura da superfície. Observou-se durante as campanhas de campo, que os GX e PA são predominantemente utilizados para pastejo, em contrapartida os locais onde ocorrem os RY (entorno dos principais drenos), são preferencialmente utilizados para agricultura.

O classificador (i) teve o melhor desempenho para as classes PA (90%), PVA (98,7%), LA (76,7%), LVA (86%) e RL (90,7%). Em contrapartida ao se retirar o índice NDVI (conjunto iv), melhores desempenhos foram obtidos para as classes CX (80,7%) e GX (82,7%). É possível inferir que devido à similaridade no comportamento dos índices iron oxide e NDVI, o uso destes atributos em um mesmo conjunto cause redundância no aprendizado da rede, e depreciação no desempenho do classificador. Para as demais classes notou-se similaridade entre esta rede e o produto obtido pelo conjunto (i), onde foram utilizadas todas as variáveis. As considerações e dados obtidos indicam que este índice (NDVI) pouco contribuiu para discriminação dos solos da área de estudo.

O conjunto (v), que não utiliza nenhum dos três índices apresentou pior desempenho quando comparado aos demais, destacando a importância do uso de informações obtidas por sensoriamento remoto como variáveis discriminantes na classificação supervisionada. A exceção consistiu na classe dos LA, que inversamente ao comportamento apresentado pelos conjuntos que continham as três variáveis, mostrou redução na confusão com outras classes, principalmente com LVA, uma vez que os solos dessas ordens possuem ampla distribuição na área da bacia, e o tipo de uso consiste de forma geral em florestas secundárias em diferentes estágios de regeneração ou pastagem, com presença de plantas espontâneas da região (pasto sujo).

A Tabela 4 apresenta a matriz de significância, que contrasta o desempenho estatístico dos distintos classificadores considerados neste estudo.

Tabela 4. Matriz de significância entre as RNAs dos conjuntos testados.

RNA	(i)	(ii)	(iii)	(iv)	(v)
(i)	71,96				
(ii)	3,63*	63,25			
(iii)	4,24*	0,63	61,13		
(iv)	1,47	2,21*	2,83*	70,41	
(v)	4,72*	1,14	0,51	3,33*	59,27

Analisando a tabela é possível constatar que os classificadores (i) e (iv) não apresentaram diferença estatística entre si, porém discerniram dos demais conjuntos, que mostraram pior desempenho. Segundo Dobos et al. (2001), os dados de sensores remotos refletem as condições superficiais e características espectrais do terreno, e portanto, individualmente, são incapazes de representar com precisão a variabilidade dos solos na paisagem. Por essa razão, sugere-se que os dados de sensores remotos devam ser complementados com informações topográficas do terreno para fornecer dados adicionais na modelagem solo-paisagem.

Uma vez que a avaliação do desempenho estatístico não detectou diferenças entre os produtos dos conjuntos (iv) e (i), foi necessário o uso de critério complementar para subsidiar a seleção do conjunto de variáveis discriminantes adequado para a predição espacial das classes de solo da bacia. Sendo assim, foi realizada uma avaliação do nível de acerto dos classificadores de melhor desempenho (conjuntos i e iv), com base na concordância relativa com 120 pontos de controle, não utilizados nos procedimentos de treinamento e validação das redes neurais. Os resultados obtidos nesta avaliação são apresentados na Tabela 5.

Tabela 5. Avaliação da concordância entre os conjuntos (i), (iv) e os pontos de controle

Conjuntos Seleccionados	Pontos corretamente classificados	Concordância Relativa (%)
(i) todas as variáveis	63	52,5
(iv) sem o índice <i>NDVI</i>	71	59,2

Dos conjuntos de variáveis testados, a maior concordância com os pontos de referência foi obtida pelo conjunto (iv), quando o índice *NDVI* foi retirado da análise, que inferiu corretamente as classes de solo em 71 locais (59,2%), em detrimento da concordância do conjunto (i), com todas as variáveis, que inferiu corretamente as classes em 63 locais, o equivalente a 52,5%. Zhu (2000) obteve 77% de concordância entre classes de solos e pontos de referência. Em contrapartida, Vaz de Melo (2009) em seu estudo com RNAs na Zona da Mata Mineira obteve uma concordância de 66,6%.

4. Conclusões

O pior desempenho estatístico foi obtido pelo conjunto (v), onde os três índices derivados de sensores foram removidos, e o melhor desempenho foi constatado na classificação que utilizou todas as variáveis, o que destaca a importância dos dados de sensores remotos na predição das classes de solos.

A análise detalhada da exatidão dos classificadores revelou a importância dos atributos *clay minerals* e *iron oxide* (derivados de dados de sensores remotos), uma vez que a omissão destes interferiu negativamente no desempenho dos classificadores. O índice *NDVI* pouco contribuiu para distinção das classes de solos da bacia hidrográfica.

Os conjuntos (i) com todas as variáveis, e o conjunto (iv), sem o índice *NDVI*, não diferiram estatisticamente entre si, mas apresentaram melhor desempenho que os demais conjuntos avaliados.

A análise do nível de concordância e do desempenho dos índices estatísticos mostrou qualidade superior do conjunto (iv) onde apenas o NDVI foi retirado do conjunto de discriminantes, sendo este classificador selecionado para o mapeamento digital de solos da bacia hidrográfica do rio Guapi- Macacu (RJ).

Agradecimentos

Apoio do Curso de Pós-Graduação em Agronomia - Ciência do Solo (CPGA-CS), da UFRRJ e da Embrapa Solos- RJ, CAPES e FAPERJ

Referências Bibliográficas

- BRASIL. Diretoria de Serviço Geográfico. **Rio Bonito: folha SF-23-Z-B-V-2 MI-2746/2**. 5. ed. Rio de Janeiro, 1997. Carta topográfica na escala 1:50.000.
- Chagas, C. da S., **Mapeamento digital de solos por correlação ambiental e redes neurais em uma bacia hidrográfica de domínio de mar de morros**. 2006. 239p. Tese (Doutorado em Ciência do Solo) – Universidade Federal de Viçosa, Minas Gerais. 2006.
- Congalton, R. G. e Green. K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers. 1999. 137p.
- Dobos, E., Micheli, E., Baumgardner, M. F., Biehl, L., Helt, T. Use of combined digital elevation model and satellite radiometric data for regional soil mapping. **Geoderma**. v.97, p.367-391, 2000.
- Dobos, E., Montanarella, L., Negre, T., Micheli, E. A regional scale soil mapping approach using integrated AVHRR and DEM data. **International Journal of Applied Earth Observation and Geoinformation – JAG**, v.3, p.30-42, 2001.
- DRM. Departamento De Recursos Minerais. Projeto Carta Geológica do Estado do Rio de Janeiro. **Itaboraí: folha SF-23-Z-B-V-1**. Rio de Janeiro. Escala 1:50.000. 1981a
- DRM. Departamento De Recursos Minerais. Projeto Carta Geológica do Estado do Rio de Janeiro. **Cava: folha SF-23-Z-B-IV-1**. Rio de Janeiro. Escala 1:50.000. 1981b.
- DRM. Departamento De Recursos Minerais. Projeto Carta Geológica do Estado do Rio de Janeiro. **Itaipava: folha SF-23-Z-B-I-4**. Rio de Janeiro. Escala 1:50.000. 1984.
- DRM. Departamento De Recursos Minerais. Projeto Carta Geológica do Estado do Rio de Janeiro. **Petrópolis: folha SF-23-Z-B-IV-2**. Rio de Janeiro. Escala 1:50.000. 1979.
- DRM. Departamento De Recursos Minerais. Projeto Carta Geológica do Estado do Rio de Janeiro. **Teresópolis: folha SF-23-Z-B-11-3**. Rio de Janeiro. Escala 1:50.000. 1980^a.
- DRM. Departamento De Recursos Minerais. Projeto Carta Geológica do Estado do Rio de Janeiro. **Nova Friburgo: folha SF-23-Z-B-II-4**. Rio de Janeiro. Escala 1:50.000. 1980b.
- DRM. Departamento De Recursos Minerais. Projeto Carta Geológica do Estado do Rio de Janeiro. **Rio Bonito: folha SF-23-Z-B-IV-1**. Rio de Janeiro. 1980c. Escala 1:50.000.
- Ecologus- Agrar. **Plano Diretor dos Recursos Hídricos da Região Hidrográfica da Baía de Guanabara**. Rio de Janeiro, RJ. 2003. 3087 p. CD-ROOM.
- EMBRAPA. Centro Nacional de Pesquisa de Solos. **Manual de métodos de análise de solo**. Rio de Janeiro: Centro Nacional de Pesquisa de Solos – CNPS. 1997. 212p. (Embrapa-CNPS. Documentos. 1).
- EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação de Solos**. 2^o ed. Rio de Janeiro: Embrapa Solos. 2006. 306p.
- ERDAS Imagine versão 9.1. ERDAS Systems. Inc. Atlanta. **Programa de computação**.

IBGE. Instituto Brasileiro de Geografia e Estatística. Diretoria de Geociências. Departamento de Cartografia. **Itaboraí: folha SF-23-Z-B-V-1. 2. 8a.** Rio de Janeiro. 1979^a. Escala 1:50.000. Carta topográfica. Disponível em: <www.ibge.gov.br/home/#sub_download>. Acesso em: 15 jan. 2010.

IBGE. Instituto Brasileiro de Geografia e Estatística. Diretoria de Geociências. Departamento de Cartografia. **Itaipava:** dados digitais da carta topográfica na escala 1:50.000. Disponível em: <www.ibge.gov.br/home/#sub_download>. Acesso em: 15 jan. 2010.

IBGE. Instituto Brasileiro de Geografia e Estatística. Diretoria de Geociências. Departamento de Cartografia. **Nova Friburgo: folha SF-23-Z-B-II-4.** Rio de Janeiro. 1974. Escala 1:50.000. Carta topográfica. Disponível em: <www.ibge.gov.br/home/#sub_download>. Acesso em: 15 jan. 2010.

IBGE. Instituto Brasileiro de Geografia e Estatística. Diretoria de Geociências. Departamento de Cartografia. **Petrópolis: folha SF-23-Z-B-IV-2. 2. 8a.** Rio de Janeiro. 1979^b. Escala 1:50.000. Carta topográfica. Disponível em: <www.ibge.gov.br/home/#sub_download>. Acesso em: 15 jan. 2010.

IBGE. Instituto Brasileiro de Geografia e Estatística. Diretoria de Geociências. Departamento de Cartografia. **Teresópolis: folha SF-23-Z-B-II-3 MI-2716-3. 2. 8a.** Rio de Janeiro. 1983. Escala 1:50.000. Carta topográfica. Disponível em: <www.ibge.gov.br/home/#sub_download>. Acesso em: 15 jan. 2010.

JavaNNS. **Java Neural Network Simulator.** Version 1.1. 2001. University of Tübingen. Germany. Disponível em: http://www-ra.informatik.uni-tuebingen.de/software/JavaNNS/welcome_e.html. Acesso em: 10 out. 2011.

McKENZIE, N. J., RYAN, P. J. Spatial prediction of soil properties using environmental correlation. **Geoderma.** v. 89, p.67-94. 1999.

McBratney, A.B.; Mendonça-Santos, M.L.; Minasny, B. On digital soil mapping. **Geoderma.** v. 117, p.3-52. 2003.

Minasny, B.; McBratney, A.B. Incorporating taxonomic distance into spatial prediction and digital mapping of soil classes. **Geoderma.** v. 142, p.285-293. 2007.

Pedreira, B. da C. C. G.; Fidalgo, E, C. C.; Abreu, M, de B. Mapeamento do uso e cobertura da terra da bacia hidrográfica do rio Guapi-Macacu. RJ. In: XIV Simpósio Brasileiro de Sensoriamento Remoto (SBSR). 2009, Natal. **Anais...** Natal: INPE, 2009. p. 2111-2118. CD-ROM.

Sabins, F. F. **Remote Sensing: Principles and Interpretation.** 3rd ed. New York: W. H. Freeman and Company. 1997. 432p.

Santos, R. D. dos; Lemos, R. C. de; Santos, H. G. dos; Ker, J. C.; Anjos, L. H. C. dos. **Manual de descrição e coleta de solo no campo.** 5^{ed}. Viçosa: Sociedade Brasileira de Ciência do Solo. 2005. 100p.

SNNS. **Stuttgart Neural Network Version** 4.2. University of Stuttgart e University of Tübingen. 1998. Disponível em: <http://www-ra.informatik.uni-tuebingen.de>. Acesso em: 10 out. 2011.

Vaz de Melo, L. **Mapeamento digital de solos da bacia do rio Turvo Sujo por redes neurais artificiais.** 2009. 86p. Dissertação (Mestrado em Ciência do Solo) – Universidade Federal de Viçosa, Minas Gerais. 2009.

Yang, W.; Yang, L.; Merchant, J. W. An assessment of AVHRR/NDVI-ecoclimatological relations in Nebraska. USA. **International Journal of Remote sensing.** v. 10, p.2161-2180. 1997.

Zhu, A. X. Mapping soil landscape as spatial continua: the neural network approach. **Water Resources Research.** v. 36, p.663-677. 2000.