

**CÉSAR DA SILVA CHAGAS**

**MAPEAMENTO DIGITAL DE SOLOS POR CORRELAÇÃO  
AMBIENTAL E REDES NEURAIIS EM UMA BACIA  
HIDROGRÁFICA NO DOMÍNIO DE MAR DE MORROS**

Tese apresentada à Universidade  
Federal de Viçosa, como parte das  
exigências do Programa de Pós-  
Graduação em Solos e Nutrição de  
Plantas, para obtenção do título de  
“Doctor Scientiae”

VIÇOSA  
MINAS GERAIS - BRASIL  
2006

# **Livros Grátis**

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

**Ficha catalográfica preparada pela Seção de Catalogação e  
Classificação da Biblioteca Central da UFV**

T

C433m  
2006

Chagas, César da Silva, 1960-

Mapeamento digital de solos por correlação ambiental e redes neurais em uma bacia hidrográfica no domínio de mar de morros / César da Silva Chagas. – Viçosa : UFV, 2006.

xiii, 223f. : il. ; 29cm.

Orientador: Elpídio Inácio Fernandes Filho.  
Tese (doutorado) - Universidade Federal de Viçosa.

Inclui bibliografia.

1. Mapeamento do solo. 2. Redes neurais (Computação).  
I. Universidade Federal de Viçosa. II. Título.

CDD 22.ed. 631.47

**CÉSAR DA SILVA CHAGAS**

**MAPEAMENTO DIGITAL DE SOLOS POR CORRELAÇÃO  
AMBIENTAL E REDES NEURAIIS EM UMA BACIA  
HIDROGRÁFICA NO DOMÍNIO DE MAR DE MORROS**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Solos e Nutrição de Plantas, para obtenção do título de “Doctor Scientiae”

APROVADA: 13 de setembro de 2006

---

Prof. Carlos Ernesto G. R. Schaefer  
(Co-orientador)

---

Prof. Carlos Antônio O. Vieira  
(Co-orientador)

---

Waldir de Carvalho Júnior

---

Ricardo Seixas Brites

---

Prof. Elpídio Inácio Fernandes Filho  
(Orientador)

Às grandes paixões da minha vida, minha esposa e amiga Beatriz, a quem devo muito mais do que um dia poderei pagar. Aos meus filhos Ingrid e Igor que são o motor que impulsiona minha vida, aos meus pais Maria e Adhemar (*in memoriam*), pela oportunidade que me deram de estudar e aos meus irmãos Celso, Célio, Márcia, Maria Helena e Marta, pelos bons momentos vividos na infância, dedico este trabalho que é um importante marco na minha vida profissional.

## **AGRADECIMENTOS**

À Universidade Federal de Viçosa (UFV), especialmente ao Departamento de Ciência do Solo, pela oportunidade de realização deste curso.

À Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), em especial a Embrapa Solos pela oportunidade concedida.

Ao professor e orientador Elpídio Inácio Fernandes Filho pela valorosa contribuição à minha vida profissional e, sobretudo, pela grande confiança em mim demonstrada.

Ao professor Carlos Ernesto Gonçalves Reynaud Schaefer pela boa vontade, profissionalismo e pelo grande conhecimento transmitido durante o curso.

A todos os professores e funcionários do Departamento de Ciência do Solo pelo excelente convívio e pela irrestrita colaboração, em especial ao professor João Carlos Ker, pela longa amizade.

Ao colega de curso e de Embrapa Waldir de Carvalho Júnior pela grande amizade cultivada nestes anos e pela valiosíssima contribuição, sem a qual este trabalho seria mais difícil de ser realizado.

A Dona Teresa, mãe do meu amigo Waldir, que gentilmente fez as correções de português.

A todos os colegas do curso de pós-graduação do Departamento de solos, pelo apoio e amizade e a Eliana de Souza pela colaboração na impressão dos mapas.

Ao professor do Departamento de Engenharia Civil, Carlos Antônio Oliveira Vieira, pela contribuição nos estudos relacionados às redes neurais.

Ao professor da UFRRJ Márcio Rocha Francelino e ao professor José Marinaldo Gleriani do DEF/UFV pelas contribuições dadas durante meu exame de qualificação.

Aos colegas da Embrapa Solos Pedro Luiz de Freitas (projeto Aquíferos) e José Ronaldo Macedo (projeto CTHIDRO), pela ajuda financeira e logística para coleta de dados da tese.

Aos colegas da Embrapa Solos Vinicius de Melo Benites, Nilson Rendeiro Pereira e Silvio Barge Bhering, pela contribuição nos trabalhos de campo.

Aos colegas da Embrapa Solos Elaine Cristina Cardoso Fidalgo e José Francisco Lumbreras, pela boa vontade e disponibilização de dados importantes para o desenvolvimento da tese.

Aos colegas de Embrapa Solos Braz Calderano e Fabiano Araújo, pelo excelente convívio e contribuição na coleta de amostras no campo, e ao colega Humberto Gonçalves pela ajuda na confecção dos abstracts.

E a todos aqueles que respeitam este valioso recurso natural e que fazem deste o seu meio de vida.

## **BIOGRAFIA**

CÉSAR DA SILVA CHAGAS, nascido em 07 de julho de 1960 é filho de Adhemar Chagas e Maria da Silva Chagas, e natural da cidade do Rio de Janeiro - RJ.

Em dezembro de 1983, concluiu o curso de Agronomia pela Universidade Federal Rural do Rio de Janeiro (UFRRJ).

Em janeiro de 1990, ingressou na Empresa Brasileira de Pesquisa Agropecuária como pesquisador, onde permanece até os dias atuais.

Em setembro de 1994 obteve o título de Mestre em Agronomia, área de concentração Solos e Nutrição de Plantas pela Universidade Federal de Lavras (UFLA).

Em abril de 2002, iniciou seus estudos para a obtenção do título de Doutor em Solos e Nutrição de Plantas, submetendo-se à defesa de tese em setembro de 2006.



## ÍNDICE

	Página
RESUMO.....	ix
ABSTRACT.....	xii
INTRODUÇÃO GERAL.....	1
CAPÍTULO 1.....	3
CONTEXTO DA PESQUISA - LEVANTAMENTOS DE SOLOS: SITUAÇÃO NO BRASIL, PROBLEMAS E NOVAS TENDÊNCIAS.....	3
RESUMO.....	3
SUMMARY.....	4
1. CONCEITOS.....	5
2. HISTÓRICO DO LEVANTAMENTO DE SOLOS NO BRASIL.....	7
3. PROBLEMAS E DESAFIOS DOS LEVANTAMENTOS DE SOLOS.....	9
4. AS NOVAS TENDÊNCIAS DO LEVANTAMENTO DE SOLOS.....	18
5. LITERATURA CITADA.....	27
CAPÍTULO 2.....	33
AVALIAÇÃO DE MODELOS DIGITAIS DE ELEVAÇÃO PARA APLICAÇÃO NO MAPEAMENTO DIGITAL DE SOLOS EM UMA REGIÃO DO DOMÍNIO DE MAR DE MORROS E ALINHAMENTOS SERRANOS NO NOROESTE DO ESTADO DO RIO DE JANEIRO.....	33
RESUMO.....	33
SUMMARY.....	35
1. INTRODUÇÃO.....	37
2. MATERIAL E MÉTODOS.....	45
2.1. Área de Estudo.....	45
2.2. Modelos Digitais de Elevação.....	46
2.2.1. MDEs Obtidos a partir de Linhas de Contorno.....	47
2.2.1.1. MDE TIN.....	47
2.2.1.2. MDE CARTA.....	48

2.2.2. MDEs Obtidos a partir de Sensores Remotos.....	49
2.2.2.1. MDE do SRTM (MDE SRTM).....	49
2.2.2.2. MDE do ASTER (MDE ASTER).....	49
2.3. Redução dos Erros nos MDEs.....	51
2.4. Avaliação da Qualidade dos MDEs.....	54
2.4.1. Avaliação Quantitativa.....	54
2.4.2. Avaliação Qualitativa.....	55
3. RESULTADOS E DISCUSSÃO.....	57
3.1. Avaliação Quantitativa.....	57
3.2. Avaliação Qualitativa.....	64
4. CONCLUSÕES.....	72
5. LITERATURA CITADA.....	74
 CAPÍTULO 3.....	 80
 RELAÇÕES GEOMORFOPEDOLÓGICAS EM UMA REGIÃO DO DOMÍNIO DE MAR DE MORROS E ALINHAMENTOS SERRANOS NO NOROESTE DO ESTADO DO RIO DE JANEIRO.....	         80
RESUMO.....	80
SUMMARY.....	82
1. INTRODUÇÃO.....	83
2. MATERIAL E MÉTODOS.....	87
2.1. Caracterização da Área Estudada.....	87
2.2. Modelo Solo-Paisagem.....	90
2.3. Atributos Topográficos.....	92
2.4. Amostragem e Caracterização Analítica.....	92
3. RESULTADOS E DISCUSSÃO.....	94
3.1. Atributos Topográficos.....	94
3.2. Relações Geomorfopedológicas.....	102
3.2.1. Granulitos da Unidade São José de Ubá.....	102
3.2.2. Migmatitos das Unidades Vista Alegre, São João do Paraíso e Catalunha e Milonito gnaisse da Unidade Santo Eduardo.....	115
3.2.3. Sedimentos do Quaternário.....	126
4. CONCLUSÕES.....	129

5. LITERATURA CITADA.....	131
CAPÍTULO 4.....	137
UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS PARA PREDIÇÃO DAS CLASSES DE SOLOS EM UMA REGIÃO DO DOMÍNIO DE MAR DE MORROS E ALINHAMENTOS SERRANOS NO NOROESTE DO ESTADO DO RIO DE JANEIRO.....	137
RESUMO.....	137
SUMMARY.....	139
1. INTRODUÇÃO.....	141
2. MATERIAL E MÉTODOS.....	147
2.1. Variáveis Discriminantes.....	148
2.2. Classes Informacionais de Solos.....	153
2.3. Classificação Supervisionada Utilizando-se Redes Neurais e o Classificador de Máxima Verossimilhança (MAXVER).....	154
2.4. Avaliação dos Resultados.....	157
3. RESULTADOS E DISCUSSÃO.....	161
3.1. Área 1 (granulitos da Unidade São José de Ubá).....	162
3.2. Área 2 (migmatitos das Unidades Vista Alegre, São João do Paraíso e Catalunha e milonito gnaisse da Unidade Santo Eduardo).....	177
3.3. Análise da Concordância entre as Classificações.....	189
3.4. Análise da Concordância entre os Mapas Inferidos e o Mapa de Solos Convencional.....	191
3.5. Análise da Concordância entre Pontos de Controle Coletados no Campo, os Mapas Inferidos e o Mapa de Solos Convencional.....	208
4. CONCLUSÕES.....	211
5. LITERATURA CITADA.....	213
CONCLUSÕES GERAIS	221

## RESUMO

CHAGAS, César da Silva, D.S. Universidade Federal de Viçosa, setembro de 2006.  
**Mapeamento digital de solos por correlação ambiental e redes neurais em uma bacia hidrográfica no Domínio de mar de morros.** Orientador: Elpídio Inácio Fernandes Filho. Co-orientadores: Carlos Ernesto Gonçalves Reynaud Schaefer, Carlos Antônio Oliveira Vieira e Márcio Rocha Francelino.

Os levantamentos de solos tradicionais vêm sendo muito criticados por serem caros, demorados e não apresentarem adequadamente as informações demandadas pelos diferentes usuários. Desta maneira, é preciso que os cientistas de solos busquem, através de pesquisa e adoção de novas técnicas, meios para torná-los mais rápidos, menos custosos e mais quantitativos, adequando-se às necessidades dos usuários modernos. O presente estudo teve como objetivo avaliar a utilização de atributos do terreno e dados de sensores remotos em uma abordagem por redes neurais para a predição de classes de solos em uma região montanhosa do Domínio de mar de morros e Alinhamentos serranos no Noroeste do Estado do Rio de Janeiro. Como a abordagem utilizada é grandemente influenciada pelos atributos do terreno derivados de um modelo digital de elevação (MDE), inicialmente foi realizada uma avaliação quantitativa e qualitativa de diferentes MDEs para subsidiar a escolha do modelo mais adequado para derivar estes atributos, que posteriormente foram utilizados na predição das classes de solos pelas redes neurais. A raiz quadrada do erro médio quadrático (RMSE), normalmente utilizado para medir a qualidade de MDEs, isoladamente, não foi suficiente para definir, entre os modelos testados, qual apresentava melhor qualidade. Assim, a análise

qualitativa identificou que o MDE CARTA obtido com a utilização do módulo TOPOGRID é superior aos demais, pois estes apresentaram artefatos e erros grosseiros que foram facilmente detectados por esta análise. Em seguida, foi realizado o estudo das relações geomorfopedológicas na área estudada. Dentre os atributos do terreno, elevação, declividade, aspecto e plano de curvatura são os que mais se correlacionam com a distribuição dos solos, e a sua utilização facilitou a identificação das diferentes interações que ocorrem na área. A mudança textural abrupta, que está presente nos solos derivados dos migmatitos e milonitos gnaisses e ausente nos desenvolvidos dos granulitos noríticos, é a diferença mais marcante entre os solos originados destas rochas. Variações microclimáticas determinadas pelo aspecto foram importantes na diferenciação dos solos das encostas convexas, independente do tipo de material de origem. Assim, os solos derivados dos granulitos noríticos, que ocorrem nas encostas noroeste e nordeste (vermelhos) e sudoeste (vermelho-amarelos), que são mais quentes e secas, são eutróficos e sem horizonte B latossólico em profundidade (Argissolo típico), enquanto os das encostas voltadas para sudeste (relativamente mais frias e úmidas) são vermelho-amarelados, distróficos e com horizonte B latossólico em profundidade (Argissolo latossólico). Nos solos derivados dos migmatitos e milonitos gnaisses, a única diferença encontrada foi a presença de horizonte Bw abaixo do Bt nas encostas voltadas para sudeste (Argissolo abruptico latossólico). Finalmente, foi utilizada uma abordagem por redes neurais para a predição de classes de solos. Nesta avaliação, baseada no clássico conceito solo-paisagem, foram testadas diferentes combinações entre as variáveis discriminantes: geologia, elevação, declividade, aspecto, plano de curvatura, índice de umidade (CTI) e três índices derivados de uma imagem do sensor ETM<sup>+</sup> do Landsat-7, quanto à capacidade de discriminação das classes de solo. Dentre os conjuntos de variáveis testados os melhores resultados foram obtidos quando os atributos do terreno e os índices do sensor ETM<sup>+</sup> do Landsat-7 foram utilizados, tanto para a área dos granulitos noríticos, quanto para a área dos migmatitos e milonitos gnaisses. O classificador baseado nas redes neurais produziu uma maior exatidão do que o classificador clássico da máxima verossimilhança e os mapas produzidos por estes classificadores mostraram uma baixa concordância entre si, assim como com o mapa de solos convencional. A comparação com pontos de controle de campo mostrou que o mapa produzido pela abordagem por redes neurais obteve um desempenho superior (70,83% de concordância) aos mapas produzidos pelo método convencional (52,77%) e pelo maxver (50,69%). O presente estudo mostrou que a utilização dos atributos do

terreno e dos dados de sensores remotos em uma abordagem por redes neurais pode contribuir grandemente para tornar o mapeamento de solos no Brasil mais científico, quantitativo e confiável.

## ABSTRACT

CHAGAS, César da Silva, D.S. Universidade Federal de Viçosa, September of 2006.  
**Digital soil mapping for environmental correlation and neural networks in a region of domain of hillslopes areas.** Adviser: Elpídio Inácio Fernandes Filho. Co-advisers: Carlos Ernesto Gonçalves Reynaud Schaefer, Carlos Antônio Oliveira Vieira and Márcio Rocha Francelino.

The traditional soil surveys have been very criticized for being expensive, time-consuming and not adequately present the information demanded by the different users. So, it is necessary that soils scientists develop research and new techniques adoption, aiming to make it faster, less expensive and more quantitative, adjusting it to the modern users needs. The objective of the present study was to evaluate the use of terrain attributes and remote sensing data with the aid of neural network simulator for the prediction of soils classes in hillslope areas and mountains alignments Domains in the Northwest of Rio de Janeiro State. As this approach is greatly influenced by the terrain attributes derived from a digital elevation model (DEM), a quantitative and qualitative evaluation of different DEM was carried out initially to subsidize the best fit model to derive these attributes, later used for the prediction of soil classes by the neural network simulator. The root mean square error (RMSE) normally used to measure the DEM quality, was not enough to define, between the tested models, which presented the better quality. Thus, the qualitative analysis identified that the CARTA DEM obtained by the use of TOPOGRID module had the highest quality compared to the others that presented devices and gross errors, easily detected by this analysis. After that, the study

of geomorphopedologic relations in the area was carried out. Among the terrain attributes, elevation, slope, aspect and curvature plan are the ones that had more influence on the soil distribution in the area, and were used to facilitate the identification of the different interactions that occur in the area. The abrupt textural change, that is present in soils derived from migmatites and milonites gneisses and absent in the soils developed from the noritic granulites, is the main difference among the soils derived from these rocks. Microclimatic variations determined by the aspect were important in the soil differentiation of the convex hillsides, independent of the parent material type. Thus, the soils derived from the noritic granulites, that occur in the northwest and northeast hillsides (red) and southwest (yellow-red), that are hotter and dry, are eutrofic and without Bw horizon in depth (typical Argissolo), while the Southeast oriented hillsides (relatively more cold and humid) are red-yellowish, distrofic and with Bw horizon in depth (latossolic Argissolo). In soils derived from migmatites and milonites gneisses, the difference observed was the presence of Bw horizon below the Bt horizon in the Southeast hillsides oriented (abruptic latossolic Argissolo). Finally, a neural network evaluation for prediction of soil classes was carried out. In this evaluation, based on the classic soil-landscape concept, different discriminant variables combinations have been tested: geology, elevation, slope, aspect, plan curvature, CTI index and three indexes derived from LANDSAT 7 image, about the soils classes discrimination capacity. Among the tested variable sets, the best results have been gotten when the terrain attributes and the LANDSAT 7 index had been used in the noritic granulites area and to the migmatites and milonites gneisses area. The neural network classifier was more accurated than the maximum likelihood classic classifier and the maps produced by these classifications had low agreement between them, as well as, with the conventional soil map. The comparison with the field collected points showed that the map produced by the neural network classifier had a higher performance (70.83% of agreement) compared with the conventional maps produced (52.77%) and with the maximum likelihood classifier (50.69%). The present study showed that the use of terrain attributes and remote sensing data in a neural network approach can greatly contribute to the soil mapping in Brazil to be more scientific, quantitative and trustworthy.



## INTRODUÇÃO GERAL

Atualmente, o Brasil conta apenas com uma base de solos de abrangência nacional, a nível exploratório/reconhecimento, em escalas que variam de 1:250.000 até 1:1.000.000. Por várias razões, principalmente restrições orçamentárias, não foi possível avançar no conhecimento da distribuição dos solos do país, em escala e detalhe adequados às exigências modernas. Além disso, fatores como o tempo de execução demasiado longo e o reduzido número de profissionais capacitados têm dificultado bastante a realização de levantamentos de solos no país. Assim, a realização destes levantamentos, pelos métodos tradicionais, para todo o território nacional, em escalas adequadas, é inviável.

Nos últimos anos, as pesquisas relacionadas com o mapeamento de solos estão sendo direcionadas para o estudo de novas técnicas, que utilizam os conhecimentos disponíveis em sistemas de informações geográficas, sensoriamento remoto, geoestatística, entre outros, buscando uma melhoria no processo de coleta de dados e organização das etapas do levantamento de solos.

Este estudo teve como objetivo principal avaliar a eficiência da utilização de atributos do terreno, derivados de um modelo digital de elevação (MDE), dados de sensores remotos orbitais e redes neurais na identificação de classes de solo em uma área de relevo movimentado no Noroeste do Estado do Rio de Janeiro. A abordagem proposta combinou o conhecimento específico do pedólogo com procedimentos de sistemas de informação geográfica e redes neurais para gerar um levantamento de solos mais preciso e de menor custo, com menor gasto de tempo, quando comparado ao levantamento de solos convencional.

Embora a abordagem utilizada seja baseada em novas tecnologias, o modelo empregado permanece fundamentado na equação dos fatores de formação do solo. De acordo com o conceito solo-paisagem, uma vez conhecidas as relações entre os solos e seus respectivos ambientes, é possível inferir os solos que ocorrem em uma determinada área, por meio da avaliação das condições ambientais.

Para alcançar os objetivos propostos esta tese foi dividida em quatro capítulos. O primeiro capítulo apresenta uma revisão sobre levantamento de solos, alvo principal deste estudo, destacando seus conceitos básicos, o histórico desta atividade no Brasil, problemas e desafios identificados por diversos autores em todo o mundo, e as novas tendências para os levantamentos de solos impulsionadas pelos avanços tecnológicos e evolução da tecnologia da informação.

Visto que os estudos de correlação ambiental são fortemente baseados em atributos do terreno derivados de um MDE, no capítulo 2 foi realizada uma avaliação da qualidade de dois conjuntos distintos de MDEs, um derivado de curvas de nível e outro derivado de sensores remotos orbitais, para subsidiar a escolha do modelo mais adequado para derivar os atributos do terreno que foram utilizados em uma abordagem por redes neurais para a predição de classes de solo.

O capítulo 3 teve como objetivo principal estabelecer a influência do material de origem e dos atributos do terreno na distribuição dos solos da bacia do rio São Domingos. O estudo das relações geomorfopedológicas é fundamental nos estudos de correlação ambiental, pois permite estabelecer as interações existentes entre os diferentes fatores de formação do solo. Este capítulo utiliza informações geradas no capítulo 2, e ambos são primordiais para a predição das classes de solo realizada no capítulo 4.

No capítulo 4 é utilizada uma abordagem por redes neurais para a predição das classes de solo que ocorrem na bacia do rio São Domingos, no Noroeste do Estado do Rio de Janeiro. Nesta abordagem foram usados atributos do terreno derivados do MDE escolhido no capítulo 2, dados geológicos da bacia e dados de sensores remotos orbitais como variáveis ambientais discriminantes. Ao final, os resultados obtidos com esta abordagem foram comparados com uma classificação feita utilizando o MAXVER e com o método tradicional de levantamento de solos.

Finalmente, são apresentadas as conclusões gerais, que mostra os principais resultados obtidos nesta pesquisa, as limitações e as recomendações para trabalhos futuros.

## **CAPÍTULO 1**

### **CONTEXTO DA PESQUISA**

#### **LEVANTAMENTO DE SOLOS: SITUAÇÃO NO BRASIL, PROBLEMAS E NOVAS TENDÊNCIAS**

##### **RESUMO**

O levantamento de solos, ao longo das últimas décadas, vem sofrendo com a redução dos recursos destinados à atualização do inventário dos solos brasileiros. A falta de apoio para esta atividade por parte dos governos e agências financiadoras tem levado a um enfraquecimento das instituições governamentais que tradicionalmente executam estes levantamentos no Brasil. O dismantelamento ou a incorporação dos institutos de levantamento de solos em outros institutos de caráter mais generalizado verificado em outros países também ocorreu no Brasil, com a extinção do Projeto Radambrasil e a transformação do antigo Serviço Nacional de Levantamento e Conservação de Solos da Embrapa em Centro Nacional de Pesquisa de Solos, com atribuições mais amplas do que as do seu antecessor. Várias são as causas apontadas para o problema que o levantamento de solos vem enfrentando. Dentre estas, há que se destacar o fato de que os levantamentos de solos tradicionais são caros, demorados e não apresentam adequadamente as informações demandadas pelos diferentes usuários. Mais do que defender com paixão os levantamentos de solos no Brasil, é preciso que os pedólogos busquem, através de pesquisa e adoção de novas técnicas, meios para torná-los mais rápidos, menos custosos e mais quantitativos, adequando-se às necessidades dos usuários modernos. A pedometria, estabelecida pela Sociedade Internacional de Ciência do Solo nos anos 90 como um importante ramo da ciência do solo, ainda hoje não é reconhecida pela Sociedade Brasileira de Ciência do Solo. Assim, este trabalho tem como objetivo apresentar um breve relato sobre a situação do levantamento de solos no Brasil, os problemas e desafios que este tem enfrentado no mundo e apontar as novas tendências mundiais para esta atividade vital para o desenvolvimento da humanidade.

**Palavras-chave:** Levantamento de solos; pedometria.

## SUMMARY

In the last decades soil surveys have gone through many obstacles with the budget shortage intended to update the inventory of Brazilian soils. The lack of support for this activity by the governments and financial agencies has led to a weakness of the governmental institutions that traditionally execute these surveys in Brazil. The dismantling or the incorporation of the institutes of soil survey in others institutes with more generalized character, occurred in other countries and also in Brazil, with the extinction of the Radambrasil Project and the transformation of the old Soil Survey and Conservation National Service of Embrapa in National Center of Soil Research, with wider attributions than its predecessor. Several causes are pointed with respect to the problems that soil surveys are facing. Among them, is the fact that the traditional soil surveys are expensive, time-consuming and do not adequately present the information demanded for the different users. Rather th

## 1. CONCEITOS

De acordo com Hudson (1990) e Estados Unidos (1993), embora, de maneira geral, se considere que o solo forma um *continuum* na paisagem, suas propriedades variam de lugar para lugar de modo não aleatório. Desta maneira, devido às discontinuidades observáveis entre as unidades de paisagem e a forte covariância entre estas e os solos, é possível o delineamento de limites com exatidão e com um número limitado de observações, através do levantamento de solos.

O levantamento de solos é um conjunto de processos que tem como objetivo determinar a distribuição espacial de propriedades morfológicas, físicas e químicas dos solos de uma determinada área e sua apresentação de uma maneira que possa ser entendida e interpretada por vários tipos de usuários (Dent & Young, 1981). Para Ibañez et al. (1993), o levantamento de solos não é apenas uma operação técnica, mas uma atividade científica e interdisciplinar.

De acordo com Estados Unidos (1993), os levantamentos de solos descrevem as características morfológicas, físicas, químicas e mineralógicas dos solos de uma área, classificam-nos de acordo com um sistema de classificação, delimitam seus limites em mapas e fazem previsões sobre o seu comportamento. Dent & Young (1981), consideram que o objetivo principal de um levantamento de solos é disponibilizar informações sobre os solos que possibilitem fazer previsões sobre o potencial da terra, para usos específicos, melhores do que poderia ser feito na ausência destas informações.

Para Rossiter (2000), esta definição apresenta um caráter utilitário, ou seja, o solo deve ser mapeado para objetivos específicos e não como um objeto de estudo científico. Segundo Buol (1996), os levantamentos de solos utilitários, que apresentam informações adequadas a um grupo potencial de usuários, custam menos, porém apresentam valor limitado. Um levantamento feito para um objetivo específico raramente servirá para diferentes propostas (Estados Unidos, 2001).

Os levantamentos de solos utilitários buscam responder a questões específicas sobre o comportamento da terra a um determinado uso e apresentam a vantagem de serem mais rápidos e poderem ser realizados por pedólogos menos experientes. No

entanto, estes não registram propriedades dos solos que são vitais para outros usos. Já os levantamentos científicos ou gerais objetivam entender o solo como um corpo natural na paisagem e fornecem a base para uma variedade de interpretações para vários tipos de usos. Apresentam a vantagem de poderem ser usados para muitos propósitos e a desvantagem de serem muito caros (Schargel, 1993; Rossiter, 2000). Há que se destacar que em muitas situações um levantamento científico é o modo mais eficiente para se obter um levantamento utilitário, já que é difícil mapear a distribuição de propriedades específicas do solo sem entender a base científica das relações solo-paisagem (Rossiter, 2000).

Para a estratificação de uma área em segmentos ou unidades é necessário se ter algum modelo para explicar como os diferentes tipos de solos estão distribuídos na paisagem. Dentre os conceitos que têm sido usados para explicar a variabilidade dos solos, o modelo baseado nos cinco fatores de formação do solo estabelecidos por Jenny (1941), conforme conceitos inicialmente emitidos por Dokuchaiev em 1883, tem sido o mais empregado. Desde a sua introdução no final do século XIX, este conceito tem servido como um modelo geral para afirmar que teoricamente os solos podem ser mapeados. No entanto, poucos são capazes de descrever um modelo generalizado que atenda a todas as situações. Embora bastante difundidos, os conceitos empregados ainda são gerais e descritivos e não explicam como é possível mapear algo com tamanha variabilidade como o solo, com tão pouca amostragem (Hudson, 1990).

Os principais conceitos do modelo solo-paisagem (Hudson, 1990), são: 1) as unidades solo-paisagem são terrenos naturais resultantes dos fatores de formação de solos e possuem forma reconhecível na superfície da terra; 2) possuem um relacionamento espacial previsível com outras unidades; 3) em uma área, normalmente, são encontradas poucas unidades que ocorrem repetidas; 4) quanto maior a diferença entre duas unidades adjacentes, mais abrupta e notável é a separação entre elas; 5) os limites entre unidades distintas podem ser observados e mapeados como descontinuidades na superfície da terra, podendo ser delineados com precisão; 6) uma cobertura de solo relativamente homogênea desenvolve-se em cada unidade solo-paisagem; 7) se os limites entre unidades de paisagem distintas tendem a ser abruptos e proeminentes, então os limites entre os solos associados a estas unidades também o serão; 8) solos adjacentes, porém distintos, tenderão a estar em unidades de paisagem diferentes, separadas por uma descontinuidade abrupta; e 9) solos adjacentes, porém

similares, em uma mesma unidade de paisagem, tendem a ter limites entre si pouco distintos e graduais, não podendo ser separados com precisão.

## **2. HISTÓRICO DO LEVANTAMENTO DE SOLOS NO BRASIL**

Os levantamentos de solos mais realizados no país foram os exploratórios elaborados, principalmente, pelo Projeto Radambrasil e os de reconhecimento executados pela Divisão de Pedologia do Ministério da Agricultura, transformada em Serviço Nacional de Levantamento e Conservação dos Solos/Embrapa e atualmente Centro Nacional de Pesquisas de Solos/Embrapa Solos, que cobrem a quase totalidade dos estados brasileiros. Em algumas regiões foram realizados levantamentos semidetalhados, destacando-se os realizados no Estado de São Paulo, como a Quadrícula de Campinas (Klamt & Santos, 1997).

A escolha destes tipos de levantamentos deveu-se, basicamente, à escassez de recursos financeiros e o reduzido número de pedólogos capacitados no país. O objetivo principal foi dotar o país, em primeiro nível, de informações generalizadas sobre o recurso de solos (levantamentos exploratórios), e em segundo nível, fazer uma estimativa qualitativa e semiquantitativa deste recurso - levantamentos de reconhecimento (Embrapa, 1981). As escalas dos principais levantamentos executados no Brasil variam de 1:1.000.000, no caso dos exploratórios até 1:250.000, no caso dos de reconhecimento (Santos, 1993).

Os registros mais antigos dos estudos de solos no país datam de 1935, provenientes da Seção de Agrogeologia do Instituto Agrônomo de Campinas - IAC (atual seção de Pedologia). Entre os resultados destes estudos, encontra-se o “Esboço Agrogeológico do Estado de São Paulo”, publicado em 1943, que se constitui no primeiro mapa de solos elaborado no país (Larach, 1997).

Na década de 50, o Instituto Agrônomo de Campinas, através da Seção de Pedologia realizou o trabalho “Observações gerais sobre os grandes tipos de solos do Estado de São Paulo”, publicado em 1951 (Paiva Neto et al., 1951), em que a geologia era utilizada como característica distintiva das classes de solos (Larach, 1997).

Em 1953, a recém-criada Comissão de Solos organizou um programa de levantamento dos solos do Brasil, com o objetivo de inventariar o potencial dos recursos dos solos do território nacional. Um dos problemas enfrentados foi determinar o nível do levantamento a ser realizado, considerando: a extensão continental do país; a escassez de pessoal técnico especializado; a ausência de pesquisa pedológica de apoio ao levantamento; a inacessibilidade a grande parte do território nacional; a deficiência de mapas básicos e mesmo ausência de cartografia de algumas regiões; os enormes vazios demográficos especialmente nas regiões centro-oeste e norte; as condições econômicas do país e o elevado custo da execução do levantamento e da publicação de mapas e boletins.

Em razão destas considerações, a Comissão de Solos resolveu que os levantamentos seriam feitos a nível generalizado (reconhecimento e exploratórios), tomando como unidade de trabalho os estados e territórios. Iniciaram efetivamente a pesquisa com a elaboração do primeiro levantamento de solos realizado pelo Serviço Nacional de Pesquisas Agronômicas, em 1951 e concluído em 1954, intitulado “Contribuição ao mapeamento, em séries, dos solos do município de Itaguaí, RJ”. Posteriormente, vieram os levantamentos do Estado do Rio de Janeiro e do Distrito Federal em 1954, e o levantamento do Estado de São Paulo, em 1955, como importantes contribuições ao Mapa de Solos do Brasil (Santos, 1994).

Com relação a este último, a metodologia adotada para elaboração foi do tipo combinado: compilado-exploratório. A execução foi processada mediante desenvolvimento gradativo por aproximações sucessivas. As unidades de mapeamento são, quase na totalidade, associações geográficas de solos, aproximadamente correspondentes às classes de categoria de Grande Grupo. A legenda de identificação é do tipo multinível, proporcionando três níveis de generalização e comportando 248 unidades de mapeamento (Camargo, 1981).

A expansão dos levantamentos de solos por várias regiões do país e, sobretudo as viagens de correlação, possibilitaram a identificação de solos desconhecidos até então e a necessidade de reclassificação de outros já conhecidos, o que levou à criação de novas classes para enquadrá-los. Assim, surgiram várias classes de solos, que até pouco tempo, antes do lançamento do atual Sistema Brasileiro de Classificação de Solos (Embrapa, 1999), eram utilizadas nos levantamentos de solos, e que eram discriminadas



com base nos horizontes diagnósticos subsuperficiais e superficiais, adaptados do Soil Taxonomy (Estados Unidos, 1975) e da Legenda da FAO (1974) para o mapa de solos do mundo. As várias frentes de trabalho concentraram esforços nos estados sulinos, produzindo levantamentos de reconhecimento, e nos estados nordestinos, levantamentos exploratório-reconhecimento (Larach, 1997).

Os estudos sobre os solos brasileiros neste período originaram concepções que foram introduzidas, até mesmo, em sistemas de classificação taxonômica de aceitação ampla como o Soil Taxonomy e a Legenda do Mapa de Solos do Mundo (Klamt & Santos, 1997).

Atualmente, as informações disponíveis, sobre a distribuição dos solos no Brasil, em escalas e níveis de detalhe adequados, são escassas. Regiões do país, que vêm sofrendo grandes pressões de ocupação, contam apenas com informações muito generalizadas, inadequadas para subsidiar a ocupação ordenada de seu território. Nas regiões tradicionalmente agrícolas a falta de informações adequadas, entre outros aspectos, tem contribuído para um inadequado processo de ocupação das terras, ocasionando sérios problemas de degradação ambiental. Por uma série de razões, pode-se afirmar que os levantamentos de solos no Brasil vêm, há muito, atravessando um período de recessão. Além disso, têm sido questionados como atividade que não está diretamente ligada à produção e cuja relação custo/benefício tem sido pouco compreendida e difícil de ser estimada (Embrapa, 1995).

### **3. PROBLEMAS E DESAFIOS DOS LEVANTAMENTOS DE SOLOS**

As predições de que o levantamento de solos estaria enfrentando um período de recessão, ao longo dos últimos anos, tem sido muito freqüente (Dudal, 1986; Zinck, 1987; Dumanski, 1993; Embrapa, 1995; Indorante et al, 1996; Basher, 1997). Entre as críticas mais habituais aos levantamentos de solos, Dudal (1986), destaca as seguintes: *i*) inadequada apresentação dos resultados; *ii*) falta de comunicação entre cientistas de solo, agricultores e economistas; *iii*) terminologia muito especializada; *iv*) interpretações de dados insuficientes; *v*) falta de interesse dos planejadores e tomadores de decisão; *vi*)

necessidade de ajustes nas técnicas de levantamento e classificação do solo para atingir completamente as necessidades dos potenciais usuários; *vii*) falta de um sistema de classificação aceito de maneira geral pela comunidade de ciência do solo; e *viii*) perda parcial de informação durante o processo de realização de mapas e legendas.

Algumas das principais razões para esta preocupação, segundo Zinck (1990), são externas aos levantamentos de solos e fortemente influenciadas pela situação econômica atual - ditas conjunturais. Outras são estruturais, isto é, são inerentes ao próprio levantamento.

As questões conjunturais estão relacionadas, principalmente: a restrições orçamentárias, que têm levado muitos países a reduzirem consideravelmente os seus inventários de recursos naturais; ao fato de que o levantamento de solos não é considerado como uma atividade ligada diretamente à produção, derivada da dificuldade de se avaliar os seus benefícios; à expansão da política econômica que tende a favorecer o controle do mercado sobre a ocupação do solo em detrimento do planejamento de uso da terra por parte dos governos; e finalmente ao fato de que alguns países já completaram, ou quase, o levantamento sistemático de seus solos em uma escala apropriada (Zinck, 1990).

Em muitos países em desenvolvimento os recursos financeiros limitados alocados aos levantamentos de solos têm impedido o seu desenvolvimento (Ibañez et al., 1993). No Brasil, não foi possível avançar na cobertura da informação de solos, em escala e detalhe adequados às exigências da agricultura moderna. Restrições orçamentárias resultaram numa desaceleração da atualização progressiva do conhecimento dos solos brasileiros, através dos levantamentos de solos, a partir da década de 70 do século passado, que se estende até os dias atuais, dando início ao enfraquecimento institucional de apoio a esta atividade, conforme se observa hoje em vários estados, carentes, na maioria, de informações adequadas que possibilitem orientar o uso e manejo sustentável de suas terras (Embrapa, 1995).

De acordo com Basher (1997), as expressões mais óbvias da pressão que a pedologia vem sofrendo, em vários países desenvolvidos e mesmo em países em desenvolvimento, são: a redução nos recursos financeiros para áreas tradicionais da pesquisa pedológica; o declínio no número de pedólogos; a redução no apoio

institucional para a pedologia pelas agências financiadoras e de pesquisa; e as mudanças ocorridas nas próprias instituições de pesquisa de solos.

O número de profissionais capacitados a realizar levantamentos de solos, no Brasil, vem sendo reduzido a cada ano, dificultando sobremaneira o esforço feito para dotar o país de informações adequadas. Estima-se que o número de profissionais habilitados no país seja um pouco superior a 100. Recentemente, vários profissionais ligados à ciência do solo, destacaram a importância dos levantamentos de solos e também ressaltaram o número reduzido de pedólogos para a realização dos mesmos (Dalmolin, 1999; Demattê, 1999; Ker, 1999; Jacomine, 1999; Santos, 1999; Oliveira, 1999).

Situação semelhante foi evidenciada por Basher (1997), com relação à redução do número de pedólogos e do número de levantamentos de solos realizados na Nova Zelândia, Austrália e Inglaterra. Burrough (1993); Ibañez et al. (1993); Basher (1997) destacam, ainda, o desmantelamento ou a incorporação dos institutos de levantamento de solos em outros institutos de pesquisa agrícola ou ambiental, de caráter mais generalizado, em países onde os levantamentos de solos, em escala adequada, foram ou estão quase terminados. Como exemplo, podemos citar o caso do National Soil Conservation Service dos Estados Unidos, que em 1995 passou a se chamar National Resources Conservation Service. Com a mudança, maior importância passou a ser dada à melhoria da acessibilidade à informação e a assuntos como qualidade do solo, preservação de terras úmidas e erosão, em detrimento da realização de novos levantamentos de solos (Indorante et al., 1996).

As questões estruturais ressaltadas por Zinck (1990), envolvem: a apresentação inadequada da informação de solos, que freqüentemente leva à subutilização dos mapas, legendas e relatórios; a baixa precisão relacionada com o delineamento dos limites e homogeneidade das unidades de mapeamento, devido à presença de impurezas e inclusões que diminui a qualidade das interpretações sobre o potencial dos solos; e os elevados custos dos levantamentos.

Indorante et al. (1996) ressaltam que os relatórios dos levantamentos de solos são uma excelente fonte de informações de solos, mas tornaram-se obsoletos, em variados graus, com a emergência de novas tecnologias, com a maior consciência

ambiental dos usuários, com os novos tipos e intensidade de uso da terra e com o aumento do entendimento das respostas do solo à atividade humana. Ressaltam, ainda, que os relatórios não contêm a maioria das informações que foram armazenadas em notas e transectos, e assim fornecem ao usuário apenas parte das características dos solos, das paisagens e do potencial de uso da terra. Além disso, Purnell (1993) destaca que os levantamentos de solos não são dinâmicos e raramente são seguidos pelo monitoramento das mudanças que ocorrem nos solos ao longo do tempo.

De maneira resumida, as alterações ocorridas com o levantamento de solos, em parte estão relacionadas com os efeitos das restrições orçamentárias e com a mudança na ênfase da caracterização e exploração planejada dos recursos naturais para a dependência nas forças do mercado em ditar as necessidades de uso da terra e de informações. Em parte, podem ser atribuídas às diferentes necessidades dos usuários pela informação de solos e ao fracasso do objetivo geral do levantamento em atender a estas necessidades e entregar informação relevante e de qualidade a um custo satisfatório e a um tempo apropriado (Dudal, 1986; Zinck, 1993). Outros autores consideram que o espírito conservador, introspectivo, pouco imaginativo e a falta de visão dos pedólogos também contribuíram para a situação atual por que passa o levantamento de solos (White, 1993).

O número e o tipo de usuários do levantamento de solos se expandiu para além da agricultura tradicional e novas tecnologias têm aumentado e refinado as necessidades dos agrônomos pelas informações de solos. Assim, os usuários necessitam de informações que sejam atuais, acessíveis em uma variedade de formas e facilmente entendíveis. Para tanto, alguns cientistas começaram a investir na melhoria dos bancos de dados e em interpretações de solos mais precisas. De todo modo, o levantamento de solos, que em décadas não mudou substancialmente nos seus conceitos ou formato, deve evoluir para satisfazer às necessidades e expectativas atuais por dados eficientes e inovadores, e melhorar a apresentação e interpretação de suas informações (Ibañez et al., 1993; Indorante et al., 1996; Basher, 1997).

Segundo Basher (1997), a pedologia tem experimentado mudanças, e diferentemente do passado, uma maior importância tem sido dada atualmente aos seguintes tópicos: pesquisas baseadas em assuntos específicos mais do que na coleção de dados generalizados, ou seja, questões como degradação da terra, poluição dos solos

e uso sustentável da terra, estão sendo favorecidos pelas agências de financiamento em detrimento do inventário do solo e avaliação de terras; conhecimento das propriedades temporais dos solos para complementar o conhecimento das propriedades espaciais, em particular as relações entre práticas de manejo e impactos nos solos para ajudar a fornecer bases científicas para o uso sustentável da terra; e informação sobre a distribuição espacial de propriedades específicas do solo mais do que a taxonomia, particularmente para a modelagem do solo e dinâmica da água.

Para Jamagne & King (1991), as mudanças ocorridas na pedologia decorrem de duas razões: a primeira está relacionada à mudança da prioridade de pesquisa para estudos aplicados em detrimento dos estudos básicos; a segunda diz respeito ao aumento da conscientização sobre as questões ambientais da maioria dos governos, para as quais a ciência do solo, em particular, e as ciências da terra, em geral, podem contribuir significativamente.

A questão ambiental tem conduzido o interesse pela ciência do solo para além do uso dos solos como um meio para o desenvolvimento da agricultura, por considerar o solo como um componente dos ciclos e processos ecológicos, um repositório para a deposição de lixo, um melhorador da qualidade da água, um meio para bioremediação e usos na engenharia, e como uma fonte de informação sobre a história natural e cultural (Miller, 1993; Schargel, 1993).

Schargel (1993) ressalta que, a partir dos anos 60, os levantamentos de solos publicados nos Estados Unidos incluíam, além das tradicionais recomendações para manejo e conservação de culturas, pastagens, florestas e preservação da vida selvagem, numerosas interpretações relacionadas com o uso não agrícola, fato que também ocorreu em outros países desenvolvidos. Nos países menos desenvolvidos os levantamentos de solos são mais utilizados em projetos de desenvolvimento da terra para aumentar a produção de alimento ou culturas de exportação, sendo que as aplicações para uso não agrícola têm recebido pouca atenção.

Tradicionalmente, o levantamento de solos tem sido produzido, principalmente, para um público não técnico. Entretanto, com o aumento da consciência ambiental, os usuários técnicos estão demandando inventários de solos mais precisos e interpretações mais cuidadosas (Brown & Huddleston, 1991). Mais do que atributos gerais dos solos

que cobrem grandes áreas e cenários não específicos, o usuário técnico necessita de informações estatísticas, tais como, média, variância, desvio padrão, coeficientes de variação e número de amostras usadas no cálculo dos dados. Mais do que uma idéia geral do relacionamento de um solo com seu vizinho, o usuário técnico necessita de conhecimento preciso da variação dos atributos do solo na paisagem (Indorante et al., 1996).

O desenvolvimento da agricultura, a expansão urbana, a degradação ambiental e a economia dos recursos naturais são apontados por Ibañez et al. (1993) como fontes de desafios e oportunidades para a criação ou mobilização das informações de solos. No entanto, para Dumanski (1993), as informações fornecidas pelos levantamentos de solos tradicionais, com ênfase nos aspectos relacionados com o uso e manejo da terra, não são adequadas para os estudos de manejo ambiental.

Alguns países vêm sofrendo conflitos derivados do aumento da demanda pela terra para usos alternativos, tais como, uso industrial, urbano, sanitário e para lazer. Para minimizar os efeitos da conversão de uso da terra, alguns países têm criado medidas e regulamentações legais para proteger suas terras agrícolas. Assim, a necessidade de maiores cuidados com o planejamento de uso da terra pode ajudar a promover a reativação dos levantamentos de solos nestes países (Hartge, 1986).

Bouma (1994) considera as questões relacionadas ao uso sustentável da terra como o alvo futuro da pedologia e sugeriu que esta pode desempenhar um papel importante, através da: quantificação da resistência e resiliência do solo pelos efeitos do uso para auxiliar na avaliação das interpretações de uso da terra; definição das propriedades das unidades de mapeamento em relação ao manejo dos solos para distinguir aquelas que são intrínsecas daquelas que são uma resposta ao manejo; e aumento da utilização dos dados existentes mais eficientemente através do uso das funções de pedotransferência.

De acordo com Zinck (1993), o levantamento de solos permanece, ainda, uma atividade vital para aquisição de dados e geração de informações interpretadas sobre o uso, manejo e conservação do recurso solos. Basher (1997) considera que as informações geradas nestes levantamentos continuarão a ser importantes para o planejamento do manejo sustentável da terra, o que leva a uma necessidade contínua por

este tipo de atividade. Entretanto, Indorante et al. (1996), consideram que o produto do levantamento de solos deve ser mais quantitativo, mais fácil para o leigo entender e hábil para incorporar novos dados a variadas escalas.

Comparado com outras ciências de monitoramento de recursos naturais, o levantamento de solos permanece um dos poucos em que a maioria da informação coletada e apresentada ao usuário está na forma qualitativa. Enquanto áreas como a meteorologia, hidrologia e geofísica coletam dados quantitativos que podem ser analisados por complexos modelos matemáticos, o levantamento de solos é ainda amplamente descritivo. Embora apresente este caráter descritivo, os cientistas de solos têm dado importantes contribuições na quantificação de fenômenos, tais como propriedades físicas dos solos, lixiviação de nutrientes e pesticidas, erosão e degradação da terra. Entretanto, estes estudos são realizados por grupos de pesquisa independentes e não fazem parte da rotina dos levantamentos de solos (Burrough, 1993).

Segundo Zinck (1990), novos desafios estão sendo colocados para os levantamentos de solos como resultado do rápido desenvolvimento da tecnologia dos sistemas de informações geográficas (SIG) e aumento da aplicação dos procedimentos de modelagem. Ambos necessitam de mais e melhores dados de solos para serem aplicados apropriadamente. Para Basher (1997), um dos maiores desafios será a integração de informações coletadas a diferentes escalas, incluindo diferentes conjuntos de parâmetros, dentro do SIG e dos sistemas de informações de solos.

Embora a adoção da tecnologia de SIG tenha tornado os procedimentos de reclassificação, interpretação e redesenho dos mapas de solos mais fáceis e baratos, não fornece novas informações sobre como os solos variam no espaço e tempo. A qualidade das informações geradas pelos SIG's depende da qualidade dos dados de solos existentes. Com a grande ênfase dada atualmente ao desenvolvimento e aplicação de bancos de dados e com o declínio da aquisição de dados no campo, existe a preocupação de que interpretações sofisticadas, utilizando a tecnologia de SIG, sejam realizadas sobre dados antigos e inadequados (Basher, 1997). Neste sentido, Zinck (1990) e Burrough (1993), ressaltam que a utilização destas tecnologias sofisticadas, com uma base de dados pobre e pouco confiável pode comprometer a qualidade da interpretação e a tomada de decisão sobre o uso da terra.

Burrough (1993) ressalta ainda que, embora os institutos de levantamento de solos em todo o mundo tenham adotado tecnologias de SIG e sistemas de informações de solos para arquivamento, recuperação, análise e apresentação das informações de maneira mais eficiente para os usuários, a automação de tarefas anteriormente realizadas manualmente e a digitalização de dados qualitativos, por si só, são insuficientes para assegurar um futuro viável em longo prazo para o levantamento de solos como uma disciplina prática e científica.

Diferentemente dos impactos causados pela tecnologia de SIG nos levantamentos de solos, os impactos dos recentes avanços na tecnologia de análises de laboratório têm sido mais modestos. Do mesmo modo, a amostragem de campo utilizada para avaliar a variabilidade espacial dos solos e gerar dados de laboratório representativos, ainda não é totalmente adequada. Além disso, a inerente rigidez dos sistemas de classificação de solos impede a aceitação de técnicas analíticas inovadoras e não contribui para promover determinações de laboratório adicionais para interpretações de solos para variados objetivos (Ibañez et al., 1993).

A modelagem solo-paisagem vem tornando-se conhecida como novo paradigma para o levantamento de solos, e para o entendimento e predição dos padrões naturais do solo constituindo parte das novas tendências dos levantamentos de solos (Hudson, 1992). Segundo Petersen et al. (1991), os modelos solo-paisagem estão sendo combinados com bancos de dados e SIGs para predição da distribuição espacial e variação das propriedades dos solos. Espera-se que esta abordagem contribua para a redução dos custos dos levantamentos de solos tradicionais.

Zinck (1990) considera que a capacidade de resposta do levantamento de solos frente aos questionamentos apresentados deve estar baseada em quatro pilares: conceitos sólidos, melhoria de métodos, técnicas inovadoras e aplicações criativas.

Simonson (1991) sugeriu alguns objetivos a serem alcançados pela ciência do solo em longo prazo, que incluem: a necessidade de melhoria da reputação do cientista de solo na comunidade científica como um todo e melhoria da ligação com outras disciplinas, planejadores e tomadores de decisão; a necessidade de um relacionamento mais efetivo entre cientistas do solo e profissionais das áreas agrícolas e não agrícolas para tornar a ciência do solo mais útil para outros profissionais e para o público em



geral, uma vez que, a ligação da ciência do solo com a agricultura levou ao isolamento desta em relação a outras ciências como geologia, hidrologia, engenharia e ecologia (Nielsen, 1987); e a necessidade de melhoria da imagem pública da ciência do solo, de modo que sua contribuição para o manejo ambiental e para o desenvolvimento econômico seja mais bem reconhecida.

As perspectivas e prioridades da ciência do solo devem mudar. Os antigos objetivos da classificação e mapeamento deverão ser mudados para uma ênfase na aquisição da informação, interpretação do comportamento do sistema solo-paisagem e interatividade com os usuários (Indorante et al., 1996). Purnell (1993) considera que os levantamentos de solos devem ser mais acessíveis e compreensíveis para os diferentes tipos de usuários; devem tratar com uma grande variedade de usos da terra; satisfazer às necessidades dos planejadores e tomadores de decisão; e enfatizar os aspectos econômicos relacionados com os diferentes usos da terra.

Para Burrough (1993), os levantamentos de solos devem buscar informações quantitativas sobre os solos e sobre a forma como estes variam, no tempo e espaço, em resposta aos métodos naturais de formação do solo e aos impactos advindos da atividade humana. Para tanto, devem trabalhar com modelos de processos ambientais, uso de métodos geoestatísticos para otimizar a amostragem e interpolação, entender as relações quantitativas entre as forma do terreno e propriedades do solo e utilizar métodos de recuperação de dados, análise e classificação que possam tratar com a complexidade do solo melhor do que os métodos qualitativos convencionais.

A evolução histórica dos levantamentos de solos no Brasil mostra que os sistemas de classificação e os métodos de mapeamento, desenvolvidos para levantamentos de reconhecimento carecem de revisão, atualização e de detalhamento para satisfazer às necessidades de levantamentos de solos mais detalhados; portanto, torna-se necessária a pesquisa de critérios taxonômicos e de técnicas de mapeamento. Soma-se a isto, a necessidade de informações cada vez mais precisas e exatas, e mais confiáveis, além de uma maior rapidez na obtenção dos dados, com redução de tempo, de custos de pesquisa e de serviços (Silva, 2000).

Finalmente, para aumentar sua capacidade de arrecadação de recursos, as organizações de levantamento de solos devem experimentar um processo de

modernização, suportado pela implementação de novos conceitos de solos, pelo uso de técnicas de levantamento avançadas e tecnologias de informação, e pelo desenvolvimento de aplicações inovadoras e diversificadas (Zinck, 1993). Jamagne & King (1991), consideram, ainda, que neste contexto o pedólogo deve ser mais receptivo para assimilar inovações tecnológicas do que para criar alternativas conceituais para responder aos assuntos multifacetados do levantamento de solos.

#### **4. AS NOVAS TENDÊNCIAS DO LEVANTAMENTO DE SOLOS**

Diversas fontes de dados são utilizadas em levantamento de solos para auxiliar no delineamento das unidades de mapeamento. A interpretação visual de fotos aéreas, tradicional, é a técnica mais reconhecida de obtenção de informações em escalas médias e grandes, pois permite a delimitação relativamente apurada das unidades de mapeamento e uma predição satisfatória das características internas e externas destas unidades. A predição destas características é baseada no clássico modelo solo-fator de formação e o resultado da fotointerpretação pode ser substancialmente melhorado quando combinado com uma abordagem geomórfica (Zinck, 1990).

O uso de fotografias aéreas, a partir de 1930, tornou-se quase universal no mapeamento de solo. As fotografias aéreas permitiram aumentar grandemente a precisão com que os limites de solo podem ser delineados nos mapas. Finalmente, os solos são examinados em algumas poucas localizações para verificar os modelos que estão sendo utilizados no processo de mapeamento (Estados Unidos, 1993).

Segundo Zhu (1997), a capacidade de conduzir levantamentos de solos convencionais precisos e eficientes é grandemente limitada por dois fatores: o processo de mapeamento baseado em polígonos e a produção manual dos mapas. No primeiro caso, fundamentado no modelo conceitual discreto, os solos no campo são representados por meio de polígonos, com cada polígono mostrando a distribuição espacial de uma classe de solo particular. Um dos problemas associados ao modelo de representação discreto é que este limita o tamanho da unidade de mapeamento que pode ser delineada como um polígono sobre um mapa de papel. Unidades que apresentam

tamanho menor do que aquele estabelecido são ignoradas ou anexadas em unidades maiores, fazendo com que sejam criadas unidades de solos compostas para expressar a inclusão de diferentes solos no polígono. Entretanto, a localização espacial destes componentes não pode ser mostrada no mapa. Este procedimento é conhecido como generalização dos solos no domínio espacial. Esta generalização pode ser muito significativa, podendo os corpos de solos variar de poucas a centenas de hectares dependendo da escala do mapa (Zhu, 2000).

Outra limitação do modelo discreto é que um polígono representa somente a distribuição espacial de um conjunto de classes de solos estabelecidas em um sistema de classificação (conceito central da classe). No mapeamento, uma vez que um solo é enquadrado em uma determinada classe, este é dito típico daquela classe; assim, as condições particulares daquele solo são perdidas. Embora, seja sabido que os solos podem diferir do conceito central da classe, é difícil representar convenientemente estas diferenças utilizando o modelo discreto de representação dos solos. Este procedimento é denominado por Zhu (2000) como generalização no domínio do parâmetro, o que significa que a variação do solo aparece somente nos limites dos polígonos de solos. Neste caso, embora, as mudanças abruptas possam ocorrer, mudanças nas propriedades dos solos freqüentemente são mais graduais e contínuas do que o modelo discreto permite representar.

O processo de produção manual dos mapas de solos convencionais dificulta enormemente a atualização rápida e acurada dos levantamentos de solos. Além disso, existem muitas limitações associadas a este processo. Primeiramente, mudanças sutis e importantes nas condições ambientais podem não ser facilmente observadas devido à limitação da percepção visual humana, principalmente quando se tenta processar muitas variáveis simultaneamente. A interpretação visual de fotografias aéreas, além de consumir muito tempo é um processo bastante propenso a erros. Como resultado, interpretações erradas podem ocorrer durante o procedimento de delineamento dos limites dos solos. A transferência dos limites delineados nas fotografias aéreas para mapas-base também consome tempo e pode conduzir a erros, degradando a qualidade dos mapas. Finalmente, a repetição deste processo para cada atualização de um levantamento de solos torna a atualização muito ineficiente (Zhu et al., 2001).

Para superar todas estas limitações, os métodos de levantamentos de solos têm passado, ao longo de anos, por vários ajustes e aperfeiçoamentos. A tecnologia para aquisição e manipulação da informação tem evoluído enormemente ao longo das últimas décadas e o levantamento de solos vem-se beneficiando bastante destas mudanças, que têm possibilitado um aumento da qualidade e melhoria na eficiência dos levantamentos realizados (Arnold, 1987).

As variações contínuas do solo no espaço e no tempo são consideradas problemáticas em relação aos esforços de amostragem, qualidade da informação e manejo adequado (McBratney, 1992). Por outro lado, tratar com a variação do solo não tem sido muito fácil para o levantamento desde seu início (Hengl, 2003).

O caráter qualitativo do levantamento de solos convencional tem sido bastante criticado. No entanto, com a crescente preocupação ambiental, este caráter qualitativo vem dando lugar a uma abordagem mais quantitativa. Nos últimos 30 anos, vários métodos quantitativos (Pennock et al., 1987; Odeh et al., 1992; McKenzie & Austin, 1993; Moore et al., 1993; McKenzie & 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).

De acordo com Webster (1994), pedometria é um neologismo derivado das palavras gregas pedos (solos) e metron (medida), e é formada e usada analogamente a outras palavras como biometria, psicometria, econometria e a mais antiga de todas, a geometria. A pedometria tem sido definida como a área da ciência do solo preocupada com a descrição, classificação, formação e distribuição do solo por técnicas estatísticas e matemáticas quantitativas (McBratney, 1992).

A pedometria surgiu da necessidade de quantificar muitas das abordagens convencionais da descrição, classificação e mapeamento dos solos. Seu surgimento era necessário para avaliar a precisão e exatidão das afirmativas sobre as classes e atributos dos solos, para tornar os procedimentos mais reproduzíveis e os resultados mais comparáveis (McBratney, 1992).

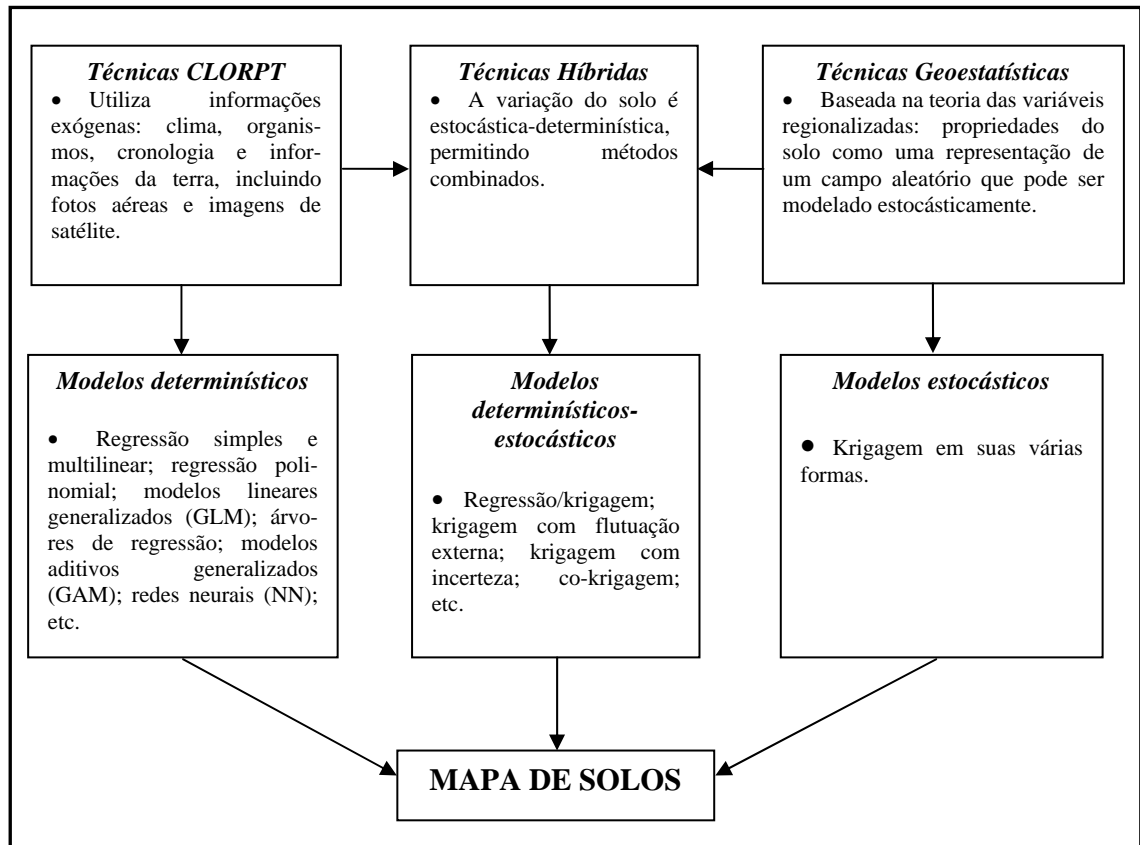
Segundo Hengl (2003), o domínio da pedometria mudou um pouco desde sua fundação. Atualmente, a pedometria é mais bem definida como um campo interdisciplinar entre a ciência do solo, a estatística e matemática aplicadas e a ciência da geoinformação, significando que reúne diferentes campos científicos, que podem variar desde a geoestatística até a microbiologia do solo.

O desenvolvimento da pedometria é também resultado das novas descobertas e melhoramentos tecnológicos, como técnicas de sensoriamento remoto, posicionamento por GPS e computadores em geral (Burrough et al., 1994). Um tópico importante da pesquisa pedométrica é o desenvolvimento de modelos e ferramentas que possibilitam trabalhar com a variação espaço-temporal dos solos, que uma vez implementados permitirão melhorar ou substituir o mapeamento de solo convencional (McBratney et al., 2000).

Segundo McBratney et al. (2000), as técnicas pedométricas são utilizadas para analisar dados com o objetivo de tornar os inventários de solos quantitativos, mais eficientes e mais baratos. Existe uma variedade de técnicas disponíveis para a análise da distribuição espacial do solo. Os métodos mais comumente utilizados são a geoestatística, a estatística clássica e a combinação destas duas.

Os trabalhos pioneiros em pedometria utilizaram a classificação numérica baseada em sistemas de computadores (Hole & Hironaka, 1960; Moore & Russell, 1967). Desde então, sua aplicação tem crescido enormemente. Análise espacial e geoestatística, manejo de banco de dados de solos, análise discriminante são algumas das aplicações da classificação numérica na ciência do solo. Embora as aplicações da classificação numérica para os estudos do solo sejam, até certo ponto, baseadas na representação contínua do solo no espaço, seus resultados ainda são interpretados em termos de classes descontínuas (Odeh et al., 1992). Os recentes avanços nesta área são baseados na teoria dos conjuntos fuzzy (Zadeh, 1965) que busca otimizar a qualidade de predição da classificação resultante e que leva em consideração a natureza contínua da variação do solo (McBratney & Odeh, 1997).

organismos, R = relevo, P = material de origem e T = tempo) e os métodos geoestatísticos. As principais características de cada uma destas técnicas são apresentadas na Figura 1, conforme McBratney et al. (2000).



Fonte: adaptado de McBratney et al. (2000).

**FIGURA 1. Técnicas pedométricas genéricas.**

Os métodos CLORPT são baseados no modelo determinístico empírico originado dos fatores de formação do solo de Jenny (1941). Muitos dos primeiros estudos, que utilizaram a função CLORPT, foram baseados na regressão linear simples-bivariada e geral, embora modelos de regressão polinomial múltipla tenham sido também aplicados. No entanto, muitos destes estudos não acomodam a não linearidade nas relações, por isso, as recentes aplicações estão utilizando métodos mais robustos tais como, modelos lineares generalizados, modelos aditivos generalizados, árvores de regressão e redes neurais. A desvantagem dos métodos CLORPT é que eles, embora tratem satisfatoriamente bem com as relações determinísticas, não são adequados para tratar com as autocorrelações espaciais das propriedades dos solos, especialmente a nível local (McBratney et al., 2000).

Esta abordagem resultou provavelmente do advento dos primeiros sistemas de informações geográficas e também possivelmente como uma resposta pedológica aos geoestatísticos (McBratney et al., 2003).

Segundo McKenzie & Ryan (1999), uma análise completa das vantagens das diferentes estratégias de correlação ambiental ainda precisa ser realizada para os levantamentos de solos. No entanto, os modelos de correlação ambiental podem ser usados na estimativa da distribuição espacial dos solos e podem formar uma base para uma abordagem mais científica dos levantamentos.

Os métodos geoestatísticos são baseados na teoria das variáveis regionalizadas que permite considerar a variabilidade espacial de uma propriedade do solo como resultado de uma função aleatória representada por um modelo estocástico. As principais limitações da técnica geoestatística univariada da krigagem advém da hipótese de estacionaridade, que freqüentemente não é encontrada em conjuntos de dados de campo, e os requerimentos de grandes quantidades de dados para definir a autocorrelação espacial. A krigagem também tem seu uso limitado em situações de complexidade do terreno onde os processos de formação do solo são complexos (McBratney et al., 2000).

Visto que, tanto o solo como os fatores exógenos são multivariados, a escolha mais adequada deve ser uma combinação de análises univariadas e multivariadas, usando os fatores CLORPT e os métodos geoestatísticos, os denominados métodos híbridos. Nos casos em que uma variável do solo está determinísticamente relacionada a alguns fatores causais, ou seja, exibe uma tendência, a krigagem univariada ordinária não é apropriada. Nestes casos, métodos híbridos, tais como a krigagem universal, co-krigagem, krigagem-regressão, krigagem com tendência externa e krigagem fatorial, são mais adequados (McBratney et al., 2000).

O mapeamento pedométrico é geralmente caracterizado como uma produção geoestatística quantitativa da geoinformação do solo. Este usualmente é concluído com a produção de um mapa no formato matricial e uma medida da incerteza deste mapa. O mapeamento pedométrico é também referido como mapeamento digital do solo, já que este depende enormemente do uso de tecnologias da informação, embora, de modo

específico signifique que na produção da geoinformação do solo são utilizados, principalmente, métodos quantitativos (Hengl, 2003).

A abordagem pedométrica para o mapeamento do solo é bastante diferente da abordagem convencional. As diferenças entre estas são sumarizadas por Hengl (2003), na Tabela 1. De modo geral, as principais diferenças são: o levantamento de solos convencional é baseado na fotointerpretação e predição dos tipos de solos, enquanto as técnicas pedométricas são, principalmente, baseadas nas propriedades do solo, produzidas com a utilização de alguma técnica geoestatística. O levantamento convencional produz mapas de polígonos de solos e os produtos das técnicas pedométricas são mapas de propriedades dos solos de grande escala.

**TABELA 1. Comparação entre o mapeamento pedométrico e o convencional.**

<b>Etapas</b>	<b>Mapeamento Pedométrico</b>	<b>Mapeamento Convencional</b>
Preparação e planejamento do projeto	Identificação dos tipos de variáveis ambientais dos solos.	Identificação dos fatores de formação dos solos (conceito de catena).
Dados auxiliares utilizados (pré-processamento)	Imagens de sensores remotos; atributos do terreno derivados de um MDE; dados geológicos, entre outros.	Fotointerpretação e levantamento de reconhecimento.
Esquema de amostragem	Amostragem baseada em um esquema (amostras aleatórias, amostras estratificadas ao acaso) ou baseada em um modelo (estratificação igual da área).	Amostragem livre.
Aquisição de dados de campo	Navegação usando um SIG.	Navegação usando fotografias aéreas.
Organização e entrada dos dados	Análise dos dados e interpolação usando alguma técnica geoestatística.	Designação das unidades de mapeamento e de suas composições.
Apresentação e distribuição dos produtos do levantamento de solos	Mapas de grande escala das variáveis dos solos com estimativa da incerteza (mapeamento temático).	Mapa de polígonos com atributos das propriedades dos solos (médias).

Fonte: Hengl (2003).

Os métodos geoestatísticos têm sido de grande utilidade para o levantamento de solos quantitativo de grande escala, porém sua utilidade para levantamentos de média e pequena escala é pouco clara. Por outro lado, os métodos convencionais são aparentemente mais eficientes a estas escalas porque usam as relações entre



propriedades do solo e aspectos ambientais mais facilmente observáveis como base para o mapeamento. Estas relações são derivadas de modelos mentais complexos e qualitativos desenvolvidos pelos pedólogos durante o levantamento de campo (McKenzie & Ryan, 1999).

Para superar as limitações impostas pelas generalizações relacionadas com a representação dos solos no mapeamento convencional, Zhu (1997), desenvolveu um modelo de similaridade, que apresenta duas partes: *a*) a representação matricial dos solos no domínio espacial; e *b*) a representação de similaridade dos solos no domínio dos parâmetros. Com a representação matricial, a generalização dos solos no domínio espacial pode ser grandemente reduzida e detalhes espaciais da variação dos solos podem ser representados com grande resolução. Neste sentido, cabe ressaltar, que a resolução é ditada pela qualidade dos dados digitais existentes, e não pela força de trabalho, nem pela decisão *a priori* com relação à escala do mapa.

Por sua vez, a representação de similaridade dos solos no domínio dos parâmetros é baseada na lógica fuzzy. Nesta, o solo a um determinado pixel pode ser enquadrado em mais do que uma classe de solo com graus variados de enquadramento (Burrough et al., 1997), referidos como membros fuzzy. Esta representação permite que um solo em cada pixel possua um membro parcial em cada uma das classes prescritas. Cada membro fuzzy é considerado como uma medida de similaridade entre o solo descrito e o conceito central de uma determinada classe. Todos os membros fuzzy são mantidos nesta representação de similaridade, formando um vetor  $S_{ij}$  ( $S^1_{ij}$ ,  $S^2_{ij}$ , .....,  $S^k_{ij}$ , .....,  $S^n_{ij}$ ), onde  $n$  é o número de classes e  $S^k_{ij}$  representa o valor de similaridade entre o solo no pixel  $ij$  e a classe de solo  $k$ . Este método de representação, que permite que o solo receba valores intermediários aos valores típicos da classe modal, evita enormemente o problema de generalização no domínio dos parâmetros (Zhu et al., 2001).

Pela combinação da representação de similaridade com um modelo de dados matricial, os solos em uma área são representados como uma fileira de pixels, com cada solo sendo representado como um vetor de similaridade. Deste modo, a variação espacial dos solos pode ser mostrada como um continuum nos domínios espacial e dos parâmetros (Zhu et al., 2001).

Existe uma grande necessidade de métodos de levantamentos quantitativos aplicáveis a escalas intermediárias, equivalente às escalas cartográficas de 1:50.000 a 1:100.000. Uma possibilidade é a integração de métodos convencionais aos métodos quantitativos, como a utilização de polígonos mapeados para estratificação antes ou durante as análises geoestatísticas (Voltz & Webster, 1990). Este apresenta a vantagem de incorporar os conhecimentos qualitativos dos pedólogos na predição espacial, assim como, fornecer um retrato mais realístico da variação do solo, que pode ser tanto contínua quanto descontínua.

Segundo McKenzie & Ryan (1999), dada a complexidade natural dos solos e de suas propriedades, o desenvolvimento de modelos quantitativos, mecânicos e matemáticos para predição espacial é uma tarefa quase impossível na rotina dos levantamentos de solos tradicionais. No nível de conhecimento e tecnologia atuais, o desenvolvimento de um sistema especialista híbrido, semi-automatizado e semi-subjetivo que integre o conhecimento empírico do pedólogo sobre solos às ferramentas de SIG é a única solução possível.

A aplicação de cada uma das técnicas pedométricas apresentadas depende do objetivo, resolução e organização do levantamento, visto que o uso final da informação do levantamento de solo determina a exatidão necessária. Conseqüentemente, as técnicas pedométricas não podem ser aplicadas para qualquer situação sem se considerar as necessidades específicas e a conveniência das hipóteses inerentes de cada técnica (McBratney et al., 2000).

Schellentrager et al. (1988) e Zinck (1990) destacaram a importância dos avanços tecnológicos como: o sensoriamento remoto orbital, análise de imagens digitais, técnicas de investigação não invasivas (Radar de Penetração no Solo - GPR) e análise de vídeo imagem (VIA), para o aumento da eficiência de aquisição de dados primários nos levantamentos de solos.

O processamento digital de imagens espectrais vem sendo crescentemente empregado para identificação e mapeamento de aspectos superficiais. A alta resolução espacial e espectral permite melhorar a cartografia dos solos, especialmente com relação à precisão dos limites das unidades de mapeamento (Zinck, 1990). Dados obtidos pelo sensoriamento remoto são usados em diferentes estágios do levantamento de solos.

Estes dados podem ser facilmente processados usando técnicas numéricas e fornecem grandes quantidades de informações espaciais e temporais (Ibañez et al., 1993).

Em anos recentes, o mapeamento digital dos solos tem experimentado um rápido desenvolvimento de métodos novos e econômicos, devido, principalmente à crescente disponibilidade de mapas auxiliares. Neste sentido, dois grupos principais têm tido um papel importante: as imagens de sensoriamento remoto orbital e os atributos do terreno derivados de modelos digitais de elevação (Dobos et al., 2000).

Como conseqüência de todo este processo de evolução o levantamento de solos está cada vez mais sofisticado, interdisciplinar e holístico, atuando como uma ligação para troca de informações entre especialistas que anteriormente trabalhavam isolados. Isto tem sido verificado na esfera da ciência do solo e nas suas interações com pesquisadores de outras disciplinas (Ibañez et al., 1993).

## 5. LITERATURA CITADA

ARNOLD, R. W. & WILDING, L. P. The need to quantify spatial variability. In: MAUSBACH, M. J. & WILDING, L. P. (Eds.). **Spatial variabilities of soils and landforms**. Madison, Wisconsin: Soil Science Society of America, 1991. p.1-8. (SSSA Special Publication; nº 28)

BASHER, R. Is pedology dead and buried? **Australian Journal of Soil Research**, v.35, p.979-994, 1997.

BOUMA, J. Sustainable land use as a future focus for pedology. **Soil Science Society of America Journal**, v.58, p.645-646, 1994.

BROWN, R. B. & HUDDLESTON, J. H. Presentation of statistical data on map units to the user. In: MAUSBACH, M. J. & WILDING, L. P. (Eds.). **Spatial variabilities of soils and landforms**. Madison, Wisconsin: Soil Science Society of America, 1991. p.127-148. (SSSA Special Publication; nº 28)

BUOL, S. W. The importance of soil survey: The United States Case. In: ALVAREZ V., V. H.; FONTES, L. E. F. & FONTES, M. P. F. (Eds.). **O solo nos grandes domínios morfoclimáticos do Brasil e o desenvolvimento sustentado**. Sociedade Brasileira de Ciência do Solo/UFV, Viçosa, MG, p.695-701, 1996.

BURROUGH, P. A. The technologic paradox in soil survey: new methods and techniques of data capture and handling. In: ZINCK, J. A. Soil survey: perspectives and strategies for the 21<sup>st</sup> century. **ITC Publication**, Enschede, The Netherlands, n.21, p.15-23, 1993.

BURROUGH, P. A.; BOUMA, J. & YATES, S. R. The state of the art in pedometrics. **Geoderma**, v.62, p.311-326, 1994.

BURROUGH, P. A.; Van GAANS, P. & HOOTSMANS, R. Continuous classification in soil survey: spatial correlation, confusion and boundaries. **Geoderma**, v.77, p.115-135, 1997.

CAMARGO, M. N. **Comunicado expositivo do mapa de solos do Brasil 1:5.000.000**. [S.l.; s.n.], 1981. 9p.

DALMOLIN, R. S. D. Faltam pedólogos no Brasil. **Boletim Informativo da Sociedade Brasileira de Ciência do Solo**, Viçosa, MG, v.24, p.13-15, 1999.

DEMATTE, J. L. I. A pedologia direcionada ao manejo de solos. **Boletim Informativo da Sociedade Brasileira de Ciência do Solo**, Viçosa, MG, v.24, p.16-17, 1999.

DENT, D. & YOUNG, A. **Soil survey and land evaluation**. London: George Allen & Unwin Publishers, 1981. 278p.

DOBOS, E. et al. Use of combined digital elevation model and satellite radiometric data for regional soil mapping. **Geoderma**, v.97, p.367-391, 2000.

DUDAL, R. The role of pedology in meeting the increasing demands on soils. In: International Congress of Soil Science, 13., 1986, Hamburg. **Proceedings...** Hamburg: IUSS, 1986. v.1, p.80-96.

DUMANSKI, J. Strategies and opportunities for soil survey information and research. In: ZINCK, J. A. Soil survey: perspectives and strategies for the 21<sup>st</sup> century. **ITC Publication**, Enschede, The Netherlands, n.21, p.36-41, 1993.

EMBRAPA. Centro Nacional de Pesquisa de Solos. **Procedimentos normativos de levantamentos pedológicos**. Brasília: Embrapa - SPI, 1995. 116p.

EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação de Solos**. Brasília: Embrapa Produção de Informação; Rio de Janeiro: Embrapa Solos, 1999. 412p.

EMBRAPA. Serviço Nacional de Levantamento e Conservação de Solos. **Bases para leitura de mapas de solos**. Rio de Janeiro: EMBRAPA-SNLCS, 1981. (Série Miscelânea, 4).

ESTADOS UNIDOS. Department of Agriculture. **Soil taxonomy**: a basic system of soil classification for making and interpreting soil surveys. Washington: U. S. Govt. Printing Office, 1975. 754p. (USDA. Agriculture handbook, 436).

ESTADOS UNIDOS. Department of Agriculture. Natural Resources Conservation Service. Soil Survey Staff. **National Soil Survey Handbook**: revised. 2001.

ESTADOS UNIDOS. Department of Agriculture. Soil Survey Division. Soil Conservation Service. Soil Survey Staff. **Soil survey manual**: revised. Washington: Enlarg. Ed., 1993. 437p. (USDA. Agriculture handbook, 18).

FAO. **Soil map of the world**: legend. Paris: UNESCO, v.1, 1974.

HARTGE, K. H. Demands on soils increasing in diversity and intensity. In: International Congress of Soil Science, 13., 1986, Hamburg. **Proceedings...** Hamburg: IUSS, 1986. v.1, p.1-12.

HENGL, T. **Pedometric mapping**: bridging the gaps between conventional and pedometric approaches. 2003. 200f. (PhD thesis) - Wageningen University, Enschede, The Netherlands, 2003.

HOLE, F. D. & HIRONAKA, M. An experiment in ordination of some soil profiles. **Soil Science Society of America Proceedings**, v.24, p.309-312, 1960.

HUDSON, B. D. Concepts of soil mapping and interpretation. **Soil Survey Horizons**, v.31, p.63-72, 1990.

HUDSON, B. D. The soil survey as a paradigm-based science. **Soil Science Society of America Journal**, v.56, p.836-841, 1992.

IBAÑEZ, J. J.; ZINCK, J. A. & JIMÉNEZ-BALLESTA, R. Soil survey: old and new challenges. In: ZINCK, J. A. Soil survey: perspectives and strategies for the 21<sup>st</sup> century. **ITC Publication**, Enschede, The Netherlands, n.21, p.7-14, 1993.

INDORANTE, S. J. et al. Positioning soil survey for the 21<sup>st</sup> century. **Journal of Soil and Water Conservation**, v.51, p.21-28, 1996.

JACOMINE, P. K. T. É preciso investir na formação de novos pedólogos. **Boletim Informativo da Sociedade Brasileira de Ciência do Solo**, Viçosa, MG, v.24, p.21-22, 1999.

JAMAGNE, M. & KING, D. Mapping methods for the 1990s and beyond. In: HODGSON, J. M. (Ed.). **Soil survey, a basis for European soil protection**. Brussels: CEC, p.181-196, 1991.

JENNY, H. **Factors of soil formation; a system of quantitative pedology**. New York: McGraw-Hill, 1941. 281p.

KER, J. C. O futuro da pedologia no Brasil. **Boletim Informativo da Sociedade Brasileira de Ciência do Solo**, Viçosa, MG, v.24, p.18-21, 1999.

KLAMT, E. & SANTOS, F. J. A informação de solos e o desenvolvimento sustentável. In: Congresso Brasileiro de Ciência do Solo, 26., 1997, Rio de Janeiro. **Anais...** Rio de Janeiro: SBCS, 1997. 1 CD-ROM.

LARACH, J. O. I. Histórico dos levantamentos de solos no território nacional. In: Congresso Brasileiro de Ciência do Solo, 26., 1997, Rio de Janeiro. **Anais...** Rio de Janeiro: SBCS, 1997. 1 CD-ROM.

McBRATNEY, A. B. & ODEH, I. O. A. Application of fuzzy sets in soil science: fuzzy measurements and fuzzy decisions. **Geoderma**, v.77, p.85-113, 1997.

McBRATNEY, A. B. et al. An overview of pedometric techniques for use in soil survey. **Geoderma**, v.97, p.293-327, 2000.

McBRATNEY, A. B. On variation, uncertainty and informatics in environmental soil management. **Australian Journal of Soil Research**, v.30, p.913-935, 1992.

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

MILLER, F. P. Soil science: a scope broader than its identity. **Soil Science Society of America Journal**, v.57, p.299-564, 1993.

MOORE, A.W. & RUSSELL, J. S. Comparison of coefficients and grouping procedures in numerical analysis of soil trace element data. **Geoderma**, v.1, p.139-158, 1967.

NIELSEN, D. R. Emerging frontiers in soil science. **Geoderma**, v.40, p.267-273, 1987.

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.

OLIVEIRA, V. A. O Brasil carece de novos pedólogos. **Boletim Informativo da Sociedade Brasileira de Ciência do Solo**, Viçosa, MG, v.24, p.25-28, 1999.

PAIVA NETO, J. E. et al. Observações sobre os grandes tipos de solos do Estado de São Paulo. **Bragantia**, v.11, p.227-253, 1951.

PENNOCK, D. J.; ZEBARTH, B. J. & De JONG, E. Landform classification and soil distribution in hummocky terrain, Saskatchewan, Canada. **Geoderma**, v.40, p.297-315, 1987.

PETERSEN, G. W.; NIELSEN, G. A. & WILDING, L. P. Geographic information system and remote sensing in land resource analysis and management. **Suelo y Planta**, v.1, p.531-543, 1991.

PURNELL, M. F. Soil survey information supply and demand: international policies and stimulation programmes. In: ZINCK, J. A. Soil survey: perspectives and strategies for the 21<sup>st</sup> century. **ITC Publication**, Enschede, The Netherlands, n.21, p.30-35, 1993.

ROSSITER, D. G. **Methodology for soil resource inventories**: 2<sup>nd</sup> revised version. ITC Soil Science Division, Lecture Notes & Reference, 2000. 132p.

SANTOS, H. G. Country reports: past, present and future of soil surveys in selected countries - Brazil. In: ZINCK, J. A. Soil survey: perspectives and strategies for the 21<sup>st</sup> century. **ITC Publication**, Enschede, The Netherlands, n.21, p.61-67, 1993.

SANTOS, H. G. **Some strategies of quality control for reconnaissance soil survey**. 1978. 128f. (MSc. Thesis) - Faculty of Graduate School of Cornell University, Ithaca, NY, 1978.

SANTOS, R. D. Quem defende a extinção do pedólogo não conhece a sua importância. **Boletim Informativo da Sociedade Brasileira de Ciência do Solo**, Viçosa, MG, v.24, p.23-24, 1999.

SCHARGEL, R. Multipurpose applications of soil information. In: ZINCK, J. A. Soil survey: perspectives and strategies for the 21<sup>st</sup> century. **ITC Publication**, Enschede, The Netherlands, n.21, p.23-29, 1993.

SCHELLENTRAGER, G. W. et al. Using ground-penetrating radar to update soil survey information. **Soil Science Society of America Journal**, v.52, p.746-752, 1988.

SILVA, E. N. **Mapas de solos produzidos em escalas e épocas distintas**. 2000. 177f. Tese (Doutorado em Solos e Nutrição de Plantas) - Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, SP, 2000.

SIMONSON, R. W. Soil science - goals for the next 75 years. **Soil Science**, v.151, p.7-18, 1991.

VOLTZ, M. & WEBSTER, R. A comparison of kriging, cubic splines and classification for predicting soil properties from sample information. **Journal of Soil Science**, v.41, p.473-490, 1990.

WEBSTER, R. The development of Pedometrics. **Geoderma**, v.62, p.1-15, 1994.

WHITE, R. E. The role of soil scientists in shaping policies for sustainable land management. **Soils News**, v.93, p.1-4, 1993.

ZADEH, L. Fuzzy sets. **Information and Control**, v.8, p.338-353, 1965.

ZHU, A. X. A similarity model for representing soil spatial information. **Geoderma**, v.77, p.217-242, 1997.

ZHU, A. X. et al. Soil mapping using GIS, expert knowledge, and fuzzy logic. **Soil Science Society America Journal**, v.65, p.1463-1472, 2001.

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

ZINCK, J. A. Introduction. In: ZINCK, J. A. Soil survey: perspectives and strategies for the 21<sup>st</sup> century. **ITC Publication**, Enschede, The Netherlands, n.21, p.2-6, 1993.

ZINCK, J. A. La información de suelos y tierras en el marco de los sistemas de información geográfica. In: Congreso Latinoamericano de la Ciencia del Suelo, 10., 1987, Maracaibo. **Acta...**Maracaibo: SLACS, 1987. p.1-30.

ZINCK, J. A. **Soil Survey: epistemology of a vital discipline**. Enschede, The Netherlands: ITC, 1990. 40p.



## **CAPÍTULO 2**

### **AVALIAÇÃO DE MODELOS DIGITAIS DE ELEVAÇÃO PARA APLICAÇÃO NO MAPEAMENTO DIGITAL DE SOLOS EM UMA REGIÃO DO DOMÍNIO DE MAR DE MORROS E ALINHAMENTOS SERRANOS NO NOROESTE DO ESTADO DO RIO DE JANEIRO**

#### **RESUMO**

No Brasil, a demanda por modelos digitais de elevação (MDEs), para subsidiar estudos em várias áreas da pesquisa ambiental, tem aumentado significativamente. No entanto, diferentemente de alguns países desenvolvidos, não existe no país um órgão responsável pela elaboração e normatização dos procedimentos utilizados na criação destes modelos. Normalmente, estes modelos são produzidos pelos próprios usuários e pouca atenção é dada às suas limitações como fonte de informação espacial. O objetivo deste estudo foi avaliar MDEs gerados a partir de curvas de nível (MDE TIN e MDE CARTA, gerado utilizando o TOPOGRID) e de sensores remotos (MDE ASTER e MDE SRTM), para subsidiar a escolha de um modelo adequado para derivar atributos topográficos que serão utilizados em uma abordagem por redes neurais para a predição de classes de solo em uma região montanhosa no Noroeste do Estado do Rio de Janeiro. A qualidade dos MDEs normalmente é apresentada na forma de raiz quadrada do erro médio quadrático da elevação (RMSE, sigla em inglês), que foi calculado pela diferença entre os valores de elevação estimados pelos MDEs e os pontos de referência coletados com DGPS. Foi também realizada uma avaliação da qualidade através da análise do número e extensão das depressões espúrias; comparação entre a drenagem mapeada e a drenagem numérica; comparação entre as curvas de nível derivadas e as curvas de nível originais; e análise das bacias de contribuição derivadas. Os resultados mostram que os MDEs TIN e CARTA apresentam em todos os aspectos qualidade superior aos MDEs obtidos a partir dos sensores remotos. O RMSE não foi suficiente para definir, entre os modelos originados de curvas de nível e o MDE SRTM, qual apresenta melhor qualidade. Assim, a análise qualitativa identificou que o MDE CARTA é superior, pois os MDEs TIN e SRTM apresentam artefatos e erros grosseiros que são facilmente detectados por esta análise. O MDE ASTER apresentou valores de RMSE

significativamente mais elevados do que os demais MDEs. De maneira geral, O MDE SRTM e o MDE ASTER representam uma superfície mais elevada do que os pontos de referência utilizados e do que o MDE CARTA. A baixa qualidade do MDE ASTER foi atribuída à presença de nuvens; à falta de pontos de controle adequados para geração do modelo; e à pouca experiência na utilização do software empregado. Já o MDE SRTM se mostrou melhor do que o MDE ASTER e seus resultados foram semelhantes aos obtidos em outros estudos. Considerando as avaliações realizadas o MDE CARTA foi o que apresentou os melhores resultados. Finalizando, os resultados alcançados chamam, mais uma vez, a atenção para o uso indiscriminado destes modelos sem que haja uma análise prévia criteriosa, principalmente em áreas de relevo movimentado, como é o caso da bacia do rio São Domingos.

**Palavras-chave:** MDE; TOPOGRIG; TIN; ASTER; SRTM; avaliação de MDEs

## SUMMARY

In Brazil, the demand for digital elevation models (DEM), to subsidize studies in many areas of environmental research, has increased significantly. However, differently of some developed countries, there is not in Brazil an agency responsible for the elaboration and organization of the procedures to be used in the creation of these models. Normally, these models are produced by users and little attention is given to their limitations as sources of spatial information. The objective of this study was to evaluate DEMs generated from contour lines (MDE TIN and MDE CARTA, generated by the TOPOGRID) and from remote sensing data (MDE ASTER and MDE SRTM), to subsidize the choice of an adjusted model to derive topographical attributes that will be used in a neural network approach to obtain a digital soil mapping in hillslopes areas in the Northwest of the Rio de Janeiro State. The DEMs quality normally is presented in the form of root mean square error (RMSE), calculated by the difference between the elevation values estimated by the DEMs and the control points collected with DGPS. It was also carried out a quality evaluation through the analysis of the spurious depression numbers and extensions; comparison between the mapped and numerical drainage; comparison between the contour lines derived and the original contour lines; and analysis of the derived watershed. The results show that the DEMs TIN and CARTA present, in all aspects, high quality compared with those from remote sensing data. The RMSE was not enough to define, between the models originated by contours lines and the DEM SRTM, which presented the better quality. Thus, the qualitative analysis identified that the DEM CARTA was superior; therefore the DEMs TIN and SRTM presented artifacts and gross errors that were easily detected by this analysis. The DEM ASTER showed values of RMSE significantly greater than the other DEMs. In a generalized view, the DEM SRTM and DEM ASTER represent a higher surface in comparison with the control points used and with the DEM CARTA. The low quality of the DEM ASTER was attributed to the cloud presence; the lack of adjusted control points for generation of the model; and the little experience in the software package. The DEM SRTM showed better quality than the DEM ASTER and its results had been similar to other studies. Considering the evaluations, the DEM CARTA showed the best results. Finally, the reached results call, once more, the attention for the indiscriminate

use of those models without a criterious previous analysis, especially in areas with high variations in relief, as is the case of the São Domingos river watershed.

**Keywords:** DEM; TOPOGRID; TIN; ASTER; SRTM; DEM evaluation

## 1. INTRODUÇÃO

A topografia do terreno exerce enorme controle sobre os processos hidrológicos superficiais e sobre os ecossistemas, influenciando a radiação solar, precipitação, escoamento superficial, evaporação, regime de umidade do solo e tipo de vegetação. As condições de energia e fluxo de massa influenciam os tipos de vegetação e sua sucessão. Estes fluxos são afetados pela topografia através da influência combinada da elevação, declividade, orientação e rugosidade do terreno. Os parâmetros topográficos determinam a exposição de uma paisagem, condicionando, assim, seu microclima. Pelos mecanismos de realimentação a vegetação afeta os fluxos de massa e energia, afetando não somente o ambiente local, mas também o clima regional e global. Assim, a topografia é um elemento chave no estudo de ecossistemas complexos (Dixon, 1995).

Um modelo digital do terreno (MDT), também referido como modelo digital de elevação (MDE) é definido como qualquer representação quantitativa digital da variação contínua do relevo sobre o espaço, ou seja, um mapa de elevação, que pode ser utilizado para derivar diferentes atributos topográficos (Burrough, 1986; Wilson & Gallant, 2000).

Muitas organizações no mundo produzem e distribuem dados de elevação, os quais variam grandemente em escala, exatidão, formato, projeção, política de distribuição, restrições de *royalty* e preço (Dixon, 1995). Neste sentido, três fontes principais são utilizadas para geração de MDEs, para as quais diferentes técnicas são aplicadas. Estas fontes são: *a*) pontos de altitude, considerados como fonte ideal de dados para a maioria das técnicas de interpolação; *b*) curvas de nível e rios, que são ainda a fonte de dados mais comum para grandes áreas; e *c*) dados obtidos a partir de imagens de sensores remotos (Hutchinson & Gallant, 2000).

Modelos digitais de elevação podem ser elaborados diretamente pela interpretação estereoscópica de dados coletados por sensores remotos a bordo de aeronaves e satélites. Neste caso, a fotografia aérea vertical é a fonte tradicional destes dados, e a partir do lançamento do satélite SPOT, as imagens de satélite passaram a ser utilizadas para a elaboração de MDEs (Hutchinson & Gallant, 2000).

Os MDEs gerados a partir de pares de imagens estereoscópicas de satélites apresentam algumas vantagens significativas sobre outras fontes de dados, como: a disponibilidade de dados em nível mundial; grande cobertura de área por cena; resolução moderadamente elevada; processamento mais rápido através de softwares sofisticados e pouco esforço manual; baixo custo de processamento; e capacidade de aquisição em qualquer condição ambiental, no caso de sensores ativos (Subramanian et al., 2005).

Apesar das vantagens apresentadas, nenhum dos sensores disponíveis pode medir confiavelmente as elevações do terreno abaixo da cobertura da vegetação. Até mesmo na ausência de vegetação, os métodos medem as elevações com erros significativos, os quais dependem da limitação inerente dos instrumentos de observação, bem como da rugosidade e declividade da superfície. Os métodos também necessitam de pontos de controle localizados precisamente para minimizar o erro sistemático, o que nem sempre é fácil de ser obtido, especialmente em regiões remotas (Dixon, 1995).

Os sistemas orbitais utilizados para obtenção de dados topográficos incluem o SPOT (*Système Probatoire d'Observation de la Terre*), o JERS-1 (*Japanese Earth Resources Satellite*), o AVNIR (*Advanced Visible and Near-Infrared Radiometer*) no ADEOS (*Japanese Advanced Earth Observing System*), o SRTM (*Shuttle Radar Topography Mission*) e o ASTER (*Advanced Spaceborne Thermal Emission and Reflection Radiometer*) no EOS (*Earth Observing System*) da NASA. Dentre estes os que mais se destacam são: o SPOT, o SRTM e mais recentemente o ASTER.

Imagens pancromáticas do SPOT adquiridas com uma resolução de 10m têm sido usadas desde 1986 para produzir MDEs (Day & Muller, 1989). O sistema “cross-track” do SPOT permite a obtenção da segunda imagem do par estereoscópico em até dois dias após a primeira. Os MDEs produzidos a partir destas imagens, por estereocorrelação automatizada, com resolução espacial de 10 e 20m têm apresentado uma exatidão entre  $\pm 5$  e  $\pm 20$ m (RMSE - root mean square error na coordenada Z) dependendo da relação base/altura utilizada (Al-Rousan & Petrie, 1998). Entretanto, o custo e a dificuldade de obtenção de imagens livres de nuvens para muitas áreas, pelo sistema “cross-track” do SPOT-1 a 4, tem limitado a possibilidade de geração de MDEs de grandes áreas contíguas. Com isso, grande atenção tem sido dada a outras

configurações de sensores como o sistema “along-track” incorporado no SPOT-5 (Hirano et al., 2003).

O SPOT 5, último satélite da família SPOT, foi lançado em maio de 2002. Este satélite assegura a continuidade dos dados gerados pelos satélites anteriores do programa, além de possibilitar uma melhoria na resolução espacial (2,5m) das imagens com seus dois instrumentos HRG (*High Resolution Geometry*) e novas capacidades estereoscópicas com o instrumento HRS (*High Resolution Stereoscopic*). Utilizando dois telescópios, o instrumento HRS adquiri imagens estéreo com um intervalo de 90 segundos, utilizando um sistema “along-track”, com uma relação base/altura de aproximadamente 0,8 (Gleyzes et al., 2003). As primeiras avaliações da exatidão de MDEs produzidos a partir das imagens do SPOT 5 apresentaram bons resultados. Em áreas planas ou paisagens levemente onduladas a exatidão altimétrica obtida foi menor do que 5m (RMSE) (Rudowski, 2003; Nonin, 2003).

O SRTM é um projeto conjunto entre a National Geospatial Intelligence Agency (NGA) e a National Aeronautics and Space Administration (NASA), que teve como objetivo produzir dados topográficos digitais para 80% da superfície da Terra (entre as latitudes de 60° N e 56° S). O SRTM dotado de um radar de abertura sintética (SAR) adquiriu dados da superfície terrestre, nas bandas C e X, fazendo uso da técnica de interferometria (USGS, 2005).

A interferometria de radar é um método alternativo ao método estereoscópico tradicional de extração de informações altimétricas, utilizando as propriedades de coerência do radar (SAR), e aproveitando as vantagens dos sistemas de radar e do processamento digital de imagens. Por se tratar de um sensor ativo e por atuar na região de microondas do espectro eletromagnético, este não sofre a influência de fatores ambientais indesejáveis, como nuvens e condições climática adversas (Dixon, 1995; Toutin & Gray, 2000).

Segundo Farr et al. (2000), os MDEs produzidos a partir dos dados do SRTM apresentam uma exatidão aproximada de 16m (90% de confiança). No entanto, alguns trabalhos apontam a possibilidade de serem atingidas precisões superiores a esta. Apesar das vantagens, os dados SRTM apresentam alguns problemas, tais como: valores

espúrios (positivos e negativos) nas proximidades do mar e áreas onde não são encontrados valores (Barros et al., 2005a).

Um estudo comparativo entre o MDE do SRTM e um MDE gerado a partir de cartas topográficas 1:50.000, utilizando o TOPOGRID (MDE TOPO), ambos com 90m de resolução, realizado por Jarvis et al. (2004) em Honduras demonstrou que o MDE do SRTM apresenta uma maior exatidão do que o segundo, baseado em uma comparação realizada com pontos de controle no campo obtidos com GPS. Neste sentido, o MDE do SRTM teve um erro médio de 8m contra 20m do MDE TOPO. Entretanto, alguns erros sistemáticos foram identificados pelos autores nos dados do SRTM, relacionados com o atributo orientação da encosta. Estes erros foram mais elevados nas encostas voltadas para nordeste, o que foi atribuído ao efeito do ângulo de incidência das imagens de radar originais usadas para produzir o MDE do SRTM. Entretanto, o MDE do SRTM contém mais detalhes da superfície do que o MDE TOPO (Jarvis et al., 2004).

Alguns estudos realizados no Brasil apontam para um bom potencial de uso dos dados do SRTM para aplicações em diferentes áreas das ciências ambientais. Santos et al. (2005) avaliaram a precisão vertical dos modelos SRTM na Amazônia e concluíram que a utilização destes modelos para áreas com características de baixa variação de altitude, como é o caso de grande parte da região amazônica, é viável como alternativa à geração de modelos a partir de cartas topográficas na escala de 1:250.000 e 1:100.000, tanto para aplicações cartográficas quanto temáticas.

Segundo Barros et al. (2005a), o potencial de uso dos dados do SRTM é muito grande, em função principalmente de sua boa qualidade, facilidade de aquisição, gratuidade e abrangência, embora apresente imperfeições que mereçam atenção especial. Considerando aplicações temáticas que não exijam rigor cartográfico, caso muito comum entre usuários de geotecnologias, o SRTM pode ser uma alternativa viável para estudos que envolvam a aquisição de dados digitais de altimetria.

O Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) é um radiômetro de imageamento multiespectral de alta resolução (Yamaguchi et al., 1998). O ASTER está a bordo da nave TERRA da NASA, que foi lançada em 1999. TERRA é formalmente conhecida como EOS AM-I e leva cinco



instrumentos de observação que são: ASTER, CERES, MISR, MODIS e MOPITT (Kaufman et al., 1998).

O sensor ASTER foi desenvolvido para fornecer imagens em 14 bandas espectrais nas regiões do visível e infravermelho próximo (VNIR), infravermelho de ondas curtas (SWIR) e infravermelho termal (TIR) e produz imagens multiespectrais da superfície da terra de alta resolução (15 - 90m). Os dados do ASTER podem ser usados para auxiliar estudos de monitoramento em longo prazo de mudanças locais e regionais da superfície da terra, podendo-se observar respostas relativas à mudança climática global, ou seja, uso da terra, desflorestamento, desertificação, mudanças no nível de lagos e praias, mudanças nas comunidades vegetacionais, movimentos glaciais e processos vulcânicos. O VNIR é bastante útil para interpretação topográfica por causa da sua cobertura estéreo “along-track” com 15m de resolução espacial e também é importante na avaliação da vegetação e minerais de óxido de ferro na superfície de solos e rochas. Por sua vez, as bandas do SWIR foram selecionadas principalmente para o mapeamento mineral e da superfície do solo (Yamaguchi et al., 2001). Além disso, as imagens ASTER apresentam um baixo custo de obtenção, o que vem a ser uma grande vantagem, quando comparadas a imagens de outros sensores.

As imagens estereoscópicas do ASTER que possibilitam a geração de MDEs são registradas somente na banda 3, na região do infravermelho próximo de 0,78 a 0,86  $\mu\text{m}$ . Usando telescópios na posição Nadir e Off-Nadir, são gerados pares estereoscópicos adquiridos em uma mesma órbita (“along track”), através de dois sensores idênticos. As cenas são obtidas com intervalo de aproximadamente 60 s e produzem uma relação B/H de 0,6; considerada próxima da ideal para geração de MDEs por técnicas automatizadas para uma variedade de condições do terreno. A principal vantagem do sistema “along-track” quando comparado ao sistema “cross-track” do SPOT - 1 a 4, por exemplo, é que as imagens são adquiridas em condições atmosféricas e de iluminação semelhantes, resultando em um estereopar de qualidade consistente, adequado para geração de MDEs por técnicas automatizadas (Hirano et al., 2003).

Uma avaliação da qualidade vertical de MDEs gerados por estereocorrelação a partir de imagens ASTER realizada por Hirano et al. (2003) demonstrou que valores de RMSE de aproximadamente  $\pm 7$  a  $\pm 15\text{m}$  podem ser obtidos quando se utiliza imagens de boa qualidade e adequado conjunto de pontos de controle terrestre. A comparação

realizada entre as elevações do MDE do ASTER e 52 pontos de elevação de referência produziu um RMSE de  $\pm 8,6\text{m}$ . Baseados nos resultados obtidos neste estudo os autores concluíram que as imagens do ASTER provaram ser adequadas para várias aplicações ambientais que envolvem a utilização de MDEs e também para o mapeamento topográfico de áreas montanhosas nas escalas de 1:50.000 a 1:100.000 com intervalos de curvas de nível de 40m ou maiores.

A utilidade e a validade dos resultados derivados dos MDEs estão estreitamente relacionadas com a qualidade do modelo original. É muito freqüente na bibliografia a ausência de informação sobre as características destes modelos utilizados nas aplicações, especialmente quando estes foram construídos pelos próprios investigadores e não provêm de fontes oficiais de organismos qualificados (Felicísimo, 1994a).

A qualidade de um MDE depende do tipo e magnitude dos erros a ele relacionados. É importante considerar que os erros são inevitáveis, visto que os MDEs são visões simplificadas da realidade, submetidas a um processo de generalização. Os parâmetros modelados são, portanto, inerentemente imprecisos, embora sua representação possa se realizar com mais ou menos exatidão, dependendo do método de coleta de dados utilizados (Felicísimo, 1994a).

Segundo Fryer et al. (1994), os cientistas que estudam a terra e a água não estão completamente atentos para as limitações dos MDEs como fontes de informação espacial. Esta preocupação não é injustificada, pois poucos são os relatórios publicados que informam a exatidão dos MDEs e atributos deles derivados ou o efeito introduzido nos parâmetros geomórficos (Bolstad & Stowe, 1994). Os MDEs são criados, distribuídos e usados muito freqüentemente sem qualquer referência à magnitude do erro ou ao método aplicado para sua detecção ou correção (Felicísimo, 1994a).

De acordo com Burrough (1986), o erro pode ser definido como sendo o afastamento de uma medida de seu verdadeiro valor. Frequentemente, na análise geográfica ou na análise de sistema naturais complexos usando dados espaciais não se conhece ou não se tem acesso ao valor verdadeiro. A falta de conhecimento sobre a confiabilidade de uma medida nesta representação do valor verdadeiro é referida como incerteza. A incerteza é uma medida do que não se conhece, e segundo Hunter & Goodchild (1997), está sempre presente nos MDEs. Infelizmente, a natureza e a

localização exata deste erro não podem ser determinadas precisamente. Assim, a incerteza se refere à falta de conhecimento sobre este erro.

Vários são os fatores que contribuem para erros nos MDEs: dados desatualizados (cartas topográficas antigas), densidade de observações incompleta, tipo de amostragem espacial utilizada, imprecisão posicional, falta de dados ou manipulação tendenciosa do observador. Os erros de processamento incluem erros numéricos no computador, erros de interpolação ou problemas de classificação e generalização (Wise, 1998; Burrough, 1986).

Segundo Wise (2000), os erros nos MDEs podem ser categorizados como aleatórios (inerentes ao próprio MDE), sistemáticos e erros de manipulação. Os erros aleatórios estão presentes em qualquer sistema de medida e seus efeitos reduzem a exatidão do conjunto de dados. Sempre irão existir nas medidas originais nas quais o MDE é baseado e podem ser gerados pelo método de produção utilizado, como um resultado de arredondamento, por exemplo. Os erros sistemáticos resultam da deficiência na medida ou processamento e irão afetar a exatidão dos dados finais, isto é, o grau pelo qual o conjunto final concorda com a realidade. Muitos métodos de interpolação são conhecidos por produzirem erros sistemáticos, que usualmente se manifestam como artefatos em um MDE. Os erros de manipulação são originados pelo erro humano e afetam a confiabilidade do conjunto de dados. Podem surgir em qualquer estágio do processamento dos dados. Muitas vezes pode ser difícil separar a origem destes erros, porque alguns algoritmos são mais sensíveis do que outros.

Os erros sistemáticos não são facilmente detectáveis. Erros em dados espaciais, tais como valores de elevação incorretos assinalados a um ponto são espacialmente correlacionados. Um erro na medida de um ponto de referência irá afetar todos os valores de elevação desenvolvidos a partir daquele ponto. Quando o erro espacialmente dependente é desconhecido, a incerteza relacionada a este erro também o é, o que pode determinar erros sistemáticos nos MDEs e criar um problema para os métodos estatísticos não espaciais usados para definir a exatidão do mapa como o RMSE (Wechsler, 1999).

Wise (2000) destaca que antes de se utilizar um MDE é preciso detectar e procurar reduzir seus erros. Vários algoritmos têm sido propostos para detectar erros em

MDEs pela comparação de um determinado ponto com os seus vizinhos. Essencialmente, estes métodos comparam os valores de elevação em um MDE a valores obtidos por interpolação a partir dos pontos vizinhos. Neste processo, um limite é estabelecido e um ponto é considerado errado quando a diferença excede este limite (Felicísimo, 1994a).

A correção de erros em um MDE não é uma tarefa simples, já que não se conhece o verdadeiro valor da elevação que deve ser adicionado ao ponto considerado errado. Frequentemente, uma variedade de algoritmos é usada para reduzir os efeitos de erros sistemáticos e aleatórios em um conjunto de dados. Estes métodos geralmente utilizam interpoladores baseados na vizinhança.

O método tradicional de avaliação da qualidade de um MDE é confrontar uma amostra de pontos de elevação do MDE produzido contra pontos de elevação conhecidos, provenientes de uma fonte de dados mais acurada. O grau de concordância entre estes MDEs é então referido como raiz quadrada do erro médio quadrático (RMSE) da elevação.

Para Wise (2000), dois problemas estão relacionados a esta abordagem. O primeiro se refere ao fato de que normalmente esta é baseada em muito poucos pontos de amostras (20 a 30 pontos). O outro, e talvez o mais importante é que esta abordagem não auxilia na identificação da fonte do erro, isto é, não possibilita determinar se o erro é aleatório, sistemático ou erro de manipulação. Apesar disso, esta abordagem tem sido muito utilizada na comparação da qualidade de MDEs produzidos de diferentes fontes e métodos de interpolação.

Algumas abordagens para avaliar valores de elevação são baseadas mais na observação dos padrões dos valores do que em amostras isoladas. Os métodos mais simples comparam a elevação em um ponto com seus vizinhos. Deste modo, grandes diferenças podem indicar problemas com o valor no pixel central (Felicísimo, 1994b). Métodos mais sofisticados têm usado técnicas como histogramas de elevação (Carrara et al., 1997), análise espectral (Tempfli, 1980), semivariogramas (Brown & Bara, 1994) e análise de componentes principais (Lopez, 1997), para identificar variações inesperadas na estrutura espacial de valores de elevação que podem ser indicativas de erros sistemáticos ou isolados.

Erros presentes em um MDE podem confundir as relações esperadas entre atributos do terreno computados e as condições locais. Estes problemas podem ser amplificados quando atributos de primeira e segunda ordem são computados (Bolstad & Stowe, 1994), sendo, usualmente, encontrados problemas mais sérios quando atributos secundários são derivados.


O presente estudo tem como objetivo avaliar MDEs gerados a partir de dados do sensor ASTER, do SRTM e de cartas topográficas na escala de 1:50.000, em uma região montanhosa no Noroeste do Estado do Rio de Janeiro. Tal avaliação tem por finalidade auxiliar na escolha do modelo digital de elevação mais adequado para derivar atributos topográficos primários e secundários que serão empregados em uma abordagem por redes neurais para a predição de classes de solo.

## **2. MATERIAL E MÉTODOS**

### **2.1. Área de Estudo**

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 aproximadas de 21° 15' e 21° 30' S e 41° 47' e 42° 04' WGr, englobando a totalidade do município de São José de Ubá e parte do município de Itaperuna, no noroeste do Estado do Rio de Janeiro (Figura 1).

A área da bacia do rio São Domingos compreende um conjunto diversificado de rochas metamórficas e ígneas de idade pré-cambriana a eopaleozóica, representada por terrenos colinosos de baixa amplitude de relevo em alternância com alinhamentos de cristas serranas de elevada amplitude, bastante comuns ao longo do interior do Estado do Rio de Janeiro (Dantas, 2000). A bacia é constituída de áreas planas com elevações em torno de 100 m e áreas extremamente íngremes que alcançam quase 1000 m de altitude. Embora apresente grande variação altimétrica, 84,12% da área da bacia apresenta altitudes que variam entre 80 e 300 m, com uma elevação média de 216,92 m.



**FIGURA 1. Localização da bacia do Rio São Domingos no Estado do Rio de Janeiro.**

## **2.2. Modelos Digitais de Elevação**

O objetivo deste estudo foi realizar uma avaliação da qualidade de dois conjuntos distintos de MDEs. O primeiro gerado a partir de curvas de nível e o segundo desenvolvido a partir de métodos baseados em sensoriamento remoto orbital. As curvas de nível são uma fonte de dados de elevação problemática para a geração de MDEs, pois apresentam a desvantagem de sobre amostrar a elevação ao longo das curvas de nível e não fazer nenhuma estimativa entre estas. Isto significa que em áreas mais planas pode existir pouca informação sobre a elevação do terreno, necessária para a interpolação (Wise, 2000).

Por outro lado, a tendência atual na geração de MDEs é o desenvolvimento de métodos baseados em sensoriamento remoto, que possuem a vantagem de que as medidas podem ser tomadas de qualquer lugar sobre o terreno, evitando-se os problemas de amostragem espacial verificado quando se utilizam curvas de nível (Wise, 2000).

Deste modo, os MDEs foram avaliados com relação à qualidade vertical que apresentam e quanto à capacidade para derivar atributos do terreno que refletem os

principais processos geomórficos, climáticos e hidrológicos que ocorrem na área estudada. Para possibilitar a comparação, todos os MDEs foram gerados com uma resolução espacial de 30m. O modo de obtenção de cada um é descrito a seguir.

### **2.2.1. MDEs Obtidos a partir de Curvas de Nível**

Estes MDEs foram elaborados utilizando-se os dados relativos às curvas de nível, com equidistância vertical de 20m, hidrografia e pontos cotados contidos nas cartas topográficas do IBGE, na escala de 1:50.000, no formato digital, referentes às Folhas Miracema (SF-23-X-D-III-4) e São João do Paraíso (SF-24-G-I-3).

Primeiramente, procedeu-se à união das folhas com relação aos planos de informação hidrografia, curvas de nível e pontos cotados. A rede hidrográfica foi editada no software ARC/INFO (ESRI, 1997), para a obtenção de uma rede de arcos simples, conectados e orientados na direção do escoamento, de modo a se evitarem erros futuros na geração do MDE. Da mesma maneira, o plano de informação de curvas de nível foi editado para eliminar os erros relacionados com o posicionamento de curvas que não se fechavam e com valores errados. Além disso, estas foram ajustadas à hidrografia para assegurar sua coerência. Para evitar erros de interpolação nas bordas, as curvas de nível ultrapassaram os limites da bacia. Os pontos cotados também foram checados para eliminar aqueles assinalados erroneamente.

Existem numerosos métodos disponíveis para produção de MDEs a partir de curvas de nível, os quais podem ser distinguidos pela maneira como tentam modelar a superfície usando a informação das curvas (Wise, 2000). No presente estudo foram selecionados para avaliação dois métodos, um baseado na triangulação (TIN) e outro baseado no ajustamento da superfície (TOPOGRID), que são descritos a seguir.

#### **2.2.1.1. MDE TIN**

Neste método a superfície é representada como uma série de triângulos irregulares, gerados a partir da interpolação de temas de linhas e pontos. O modelo de dados TIN (Triangulated Irregular Network) é um meio eficiente para armazenar e analisar superfícies. Essa estrutura faz uso de uma rede triangular irregular cujos triângulos são formados a partir de pontos espaçados irregularmente, com valores de x,

y, e z. Deste modo, a partir das informações contidas nas cartas topográficas descritas anteriormente, foi gerado um modelo TIN, utilizando-se o módulo 3D Analyst do ArcGIS Desktop 9.0. Uma vez criado, foi transformado para um modelo matricial regular, denominado MDE TIN.

#### **2.2.1.2. MDE CARTA**

Na geração do MDE CARTA, foi utilizado o módulo TOPOGRID do software ARC/INFO (ESRI, 1997). Este módulo utiliza um método de interpolação especificamente desenhado para a criação de um modelo digital de elevação hidrologicamente consistente. É baseado no programa ANUDEM desenvolvido por Hutchinson (1993) que utiliza uma técnica de interpolação por diferenças finitas, e combina a eficiência de uma interpolação local, tal como o Inverso do Quadrado da Distância, com métodos de interpolação global que utilizam uma superfície de continuidade, como o interpolador Kriging (ESRI, 1997).

As curvas de nível e pontos cotados, juntamente com a hidrografia, devidamente editada para assegurar que todos os rios estavam fluindo para a foz, mais o limite da área foram utilizados como dados de entrada na função GRID do ARC/INFO para geração do MDE. Assim, o TOPOGRID interpola uma superfície a partir dos dados de elevação, e posteriormente modifica esta superfície pela imposição da drenagem mapeada (coverage da hidrografia), que possibilita uma suavização e um aumento sensível da precisão do modelo gerado, produzindo uma superfície hidrologicamente consistente.

De acordo com Dobos et al. (2000), os algoritmos de interpolação podem criar pequenas imperfeições no modelo gerado que são conhecidas como depressões espúrias, de valores imprevisivelmente baixos. Na versão 7.1, o módulo TOPOGRID foi atualizado para incluir as revisões realizadas no ANUDEM por Hutchinson desde que este foi incorporado ao ARC/INFO. Uma das principais mudanças realizadas está relacionada com o RMSE usado para interpolar o grid, que agora varia automaticamente de acordo com a declividade local da célula que está sendo calculada. Isto determina uma melhoria nos resultados em áreas de vales planos adjacentes a áreas montanhosas, como é o caso da bacia do rio São Domingos, reduzindo a tendência de criar falsas depressões em tais situações (ESRI, 1997).



## **2.2.2. MDEs Obtidos a partir de Sensores Remotos**

### **2.2.2.1. MDE do SRTM (MDE SRTM)**

Os MDEs do SRTM são disponibilizados gratuitamente, a partir do servidor de ftp da USGS (<ftp://edcsgs9.cr.usgs.gov/pub/data/srtm/>). Estes são organizados no formato de 1° por 1° e identificados pelas informações de latitude e longitude do canto inferior esquerdo. Para compor a área de estudo foram obtidos dois modelos do MDE do SRTM (S22W042 e S22W043) e em seguida, criado um mosaico a partir destes, de onde foi recortada a área de interesse deste estudo. Finalmente, esta foi analisada para a verificação da existência de valores negativos e/ou áreas sem valores de altitudes. O MDE final (MDE SRTM\_90) foi, então, projetado no ArcGIS Desktop 9.0 para a projeção Universal Transversa de Mercator (UTM), Zona 24S e *datum* Córrego Alegre.

Para se adequar aos objetivos do trabalho e possibilitar a comparação com os demais MDEs da área, o MDE SRTM (90m) foi reamostrado para 30m usando-se o ArcGIS Desktop 9.0, para fornecer um MDE de maior resolução (MDE SRTM\_30). Na reamostragem, utilizou-se a opção bilinear que realiza uma interpolação bilinear para determinar novos valores para as células do grid baseado na média obtida para os quatro pixels vizinhos mais próximos ao pixel de saída, semelhantemente ao procedimento utilizado por Crepani & Medeiros (2004).

### **2.2.2.2. MDE do ASTER (MDE ASTER)**

Para a geração do MDE ASTER foi utilizada uma imagem deste sensor produzida em fevereiro de 2002, correspondente ao nível 1B, com 7% de cobertura de nuvens. A partir desta imagem foi feito um recorte da área de interesse para o estudo e em seguida corrigiu-se geometricamente com base nas cartas topográficas do IBGE, para o sistema de coordenadas UTM (Universal Transversa de Mercator), *datum* Córrego Alegre e zona 24S. A transformação geométrica ou mapeamento direto foi realizado utilizando-se o modelo polinomial, a partir de 15 pontos de controle retirados de cartas topográficas do IBGE. O método de reamostragem empregado foi o vizinho mais próximo, que usa o nível de cinza mais próximo ao resultado do mapeamento inverso, e o RMS obtido foi de 0,48. O software empregado nestes procedimentos foi o ERDAS Imagine, versão 8.5.

A estereocorrelação automatizada tornou-se um método padrão para geração de MDEs a partir de imagens estéreo digitais. A estereocorrelação é um procedimento computacional e estatístico utilizado para derivar MDEs automaticamente a partir de um estereopar de imagens registradas (Lang & Welch, 1999). Embora as abordagens possam variar de acordo com o software empregado, o procedimento básico utilizado inclui a coleta de pontos de controle terrestre (PCTs), a determinação dos valores de paralaxe para cada pixel e o pós-processamento para remoção de anomalias (Kok et al., 1987).

Assim, a extração de MDEs a partir de imagens ASTER também se baseia no princípio da paralaxe, que parte da premissa de que olhando um objeto de dois pontos de vista diferentes é possível se obter uma imagem em três dimensões. Com a conversão das imagens 3N e 3B em imagens quase epipolares (o centro da imagem orientado exatamente para o norte), que possuem um deslocamento de pixel na direção do vôo do satélite proporcional a elevação do pixel, assume-se que qualquer deslocamento entre as duas bandas é correspondente ao valor de elevação do terreno em um determinado pixel. Desta maneira, através do método de correlação e da paralaxe, o deslocamento em pixel na imagem 3B é proporcional à altimetria do pixel da imagem 3N.

A partir das imagens 3N e 3B, um conjunto de pontos de controle terrestre (se disponíveis) é usado para definir as coordenadas tridimensionais sobre as imagens do par estéreo. Assim, utilizando um modelo matemático e os pontos de controle, os parâmetros orbitais precisos (efemérides) da plataforma do sensor, a posição e atitude (como o sensor adquiriu a imagem) são calculados. Uma vez que estes são conhecidos, as coordenadas terrestres de cada ponto dentro do modelo estereoscópico são computadas para todas as coordenadas da imagem.

A resolução ou tamanho da célula do MDE gerado a partir do sensor ASTER pode ser de 15, 30 ou 60m. Podem ser criados como MDEs relativos (sem a utilização de pontos de controle) ou MDEs absolutos (com a utilização de pontos de controle). Os MDEs do ASTER são mais adequados para utilização em estudos em escalas que variam de 1:50.000 a 1:250.000 para que se obtenha uma maior exatidão nos mapas gerados a partir destes.

O MDE ASTER foi gerado utilizando o módulo AsterDTM 2.2 do software ENVI 4.2. Este módulo, além de possibilitar a geração de MDEs, permite a correção radiométrica e geométrica de imagens ASTER no nível 1A para o nível 1B, bem como a ortoretificação de imagens a partir do MDE gerado e criação de visualizações 3D. Na criação do MDE é possível se trabalhar com imagens no nível 1A ou 1B e também determinar os limites do MDE desejado, por meio da escolha de coordenadas na projeção da imagem.

No menu principal, através do comando “Options - Define Processing Parameters” é possível definir os parâmetros de saída do MDE, como: resolução espacial (15, 30 ou 60m), valores máximos e mínimos de elevação a serem encontrados na imagem, valor numérico que será atribuído para regiões em que nenhum valor de elevação pode ser extraído, entre outras opções. Após a realização dos cálculos, uma imagem monocromática com valores de elevação associados aos pixels é gerada, juntamente com outra, em que aparece uma representação dos valores de correlação entre as duas imagens do par estereoscópico. Após esta etapa é possível escolher entre a finalização do processo ou a ortoretificação das bandas SWIR (1, 2 e 3) através do MDE gerado (Zocolotti & Centeno, 2004). O MDE ASTER gerado neste estudo é um MDE relativo já que não se dispunha de pontos de controle terrestres de elevada exatidão para criação de um MDE absoluto.

### **2.3. Redução dos Erros nos MDEs**

Inicialmente, as depressões espúrias dos MDEs foram removidas utilizando-se o módulo Spatial Analyst do ArcGIS Desktop 9.0, através da função “Fill”. Em seguida, foi realizado um procedimento para detectar e corrigir possíveis erros, representados por valores muito improváveis (*outliers*), gerados pelos métodos de estereocorrelação automática, no caso de dados de sensores remotos; pelo processo de coleta e manipulação de dados vetoriais ou, ainda, pelo algoritmo utilizado no processo de interpolação (Felicísimo, 1994b; Hengl et al., 2004). Os erros foram detectados e corrigidos usando-se a abordagem estatística sugerida por Felicísimo (1994b), conforme descrito a seguir.

Esta abordagem é baseada na análise das diferenças existentes entre o valor de elevação de cada ponto do MDE (seja ele certo ou errado) e o valor obtido pela

interpolação a partir dos pontos vizinhos. O processo começa com o cálculo para cada ponto do modelo de um valor de elevação ( $Z$  estimado) usando seus vizinhos mais próximos, conforme a equação 1.

$$Z_{estimado}(i, j) = 0,25 * (Z(i, j - 1) + Z(i, j + 1) + Z(i - 1, j) + Z(i + 1, j)) \quad (1),$$

onde  $i$  = linha e  $j$  = coluna.

A diferença entre o valor estimado e o valor de elevação do MDE é dada, então pela equação 2.

$$\Delta Z(i, j) = Z_{estimado}(i, j) - Z(i, j) \quad (2)$$

Como o procedimento é aplicado em todo o MDE, é possível obter-se uma média aritmética e um desvio padrão das diferenças, aqui denominados “deltamedia” e “deltadesvio”. À medida que o MDE constitui uma população, os valores que definem a distribuição podem ser considerados como parâmetros da população ao invés de amostras estatísticas. Conhecendo os parâmetros que definem a distribuição é possível realizar um teste de significância, assumindo-se a normalidade da distribuição, para os valores individuais de delta ( $i, j$ ) com os quais se pode validar ou rejeitar a hipótese de que um valor de desvio observado pode pertencer à população de desvios (Felicísimo, 1994b). Isto é implementado pelo teste  $t$  de Student, conforme a equação 3.

$$t(i, j) = ((\Delta Z(i, j) - \text{deltamedia}) / \text{deltadesvio}) \quad (3)$$

Este valor é considerado um desvio padronizado e como o número de dados do modelo é normalmente elevado, sua magnitude pode ser comparada ao valor  $t(\alpha, \infty)$  tabulado. A condição de erro ( $e$ ) é dada, então, pela equação 4.

$$e \leftarrow |t(i, j)| \geq t(\alpha, \infty) \quad (4),$$

onde  $\alpha$  é o nível de significância adotado.

Segundo Felicísimo (1994b), a localização de pontos com um valor de  $t(i, j)$  altamente significativo não implica necessariamente em erro, mas é um excelente sinal de alarme.

A etapa de detecção dos erros deve ser seguida pela correção dos dados errôneos. A correção automática usa algoritmos para estimar um valor de elevação aceitável (embora não necessariamente real) que irá substituir o valor considerado errado. O método mais simples de correção é a substituição deste valor pela média dos vizinhos mais próximos. A detecção e correção dos erros do MDE CARTA foi implementada no software ARC/INFO (ESRI, 1997) usando uma rotina escrita em AML (Arc Macro Language), conforme Felicísimo (1994b).

## **2.4. Avaliação da Qualidade dos MDEs**

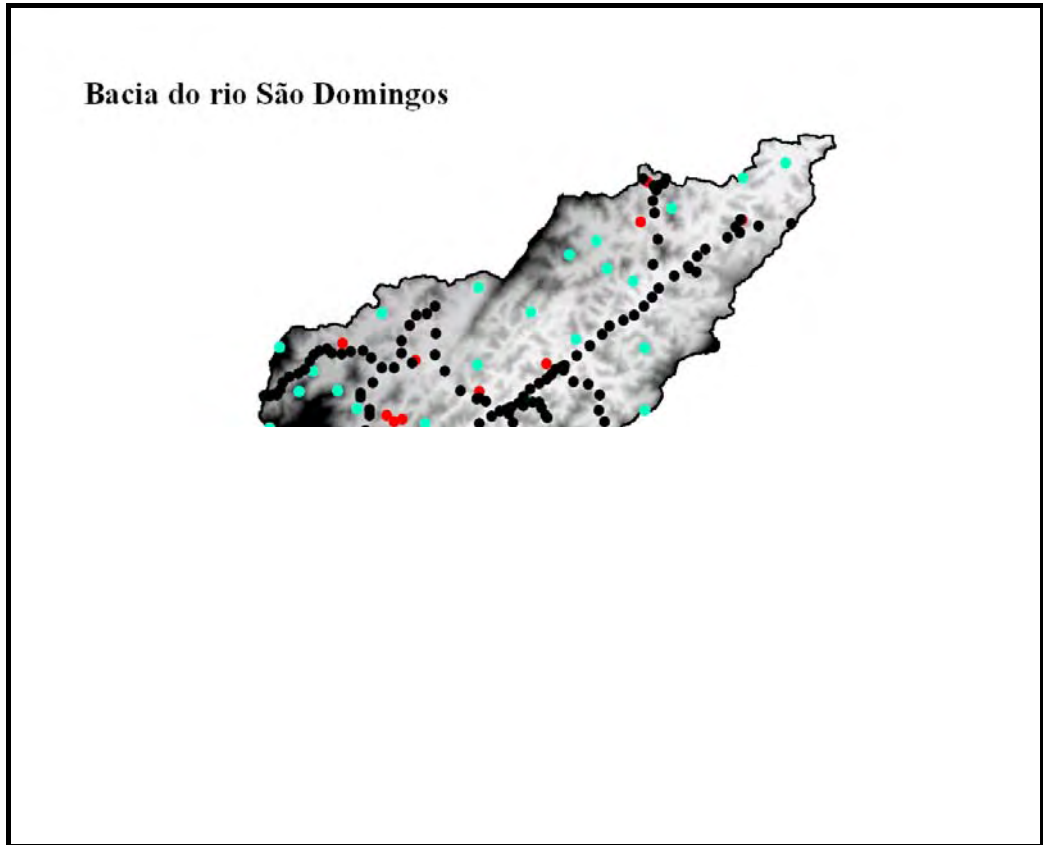
Os MDEs foram avaliados quantitativa e qualitativamente e os procedimentos utilizados nestas avaliações são descritos a seguir.

### **2.4.1. Avaliação Quantitativa**

Para determinar o nível de erro ou incerteza contido em um conjunto de dados de elevação é necessário comparar estes dados a um conjunto de referência de elevada exatidão. Assim, inicialmente foram utilizados 18 pontos de elevação obtidos diretamente no campo pela equipe do Departamento de Recursos Minerais do Rio de Janeiro (DRM-RJ), como parte das atividades do projeto “Monitoramento integrado dos recursos hídricos e definição das zonas de recarga dos aquíferos”. Estes pontos foram coletados utilizando-se um GPS da marca TRIMBLE, modelo Geoexplorer®3. As coordenadas obtidas por este GPS no modo diferencial foram processadas no software Pathfinder Office 2.8 da Trimble com a finalidade de atingir precisão submétrica.

Visto que os pontos de elevação coletados pela equipe do DRM eram insuficientes, foram coletados 158 pontos adicionais com GPS de precisão da marca ASHTECH modelo ProMark II. As coordenadas obtidas por este GPS no modo cinemático e no modo estático foram processadas no software Ashtech Solutions com a finalidade de atingir também uma precisão submétrica. Além dos pontos coletados com DGPS foram também utilizados 36 pontos retirados das cartas topográficas do IBGE, na escala de 1:50.000, localizados em áreas onde o acesso difícil impossibilitou a coleta de pontos com DGPS.

Desta maneira, foram utilizados 212 pontos, considerados como pontos de elevação de referência. A distribuição destes pontos na bacia do rio São Domingos é mostrada na Figura 2.



**FIGURA 2. Distribuição dos pontos de referência coletados com DGPS.**

Vários são os métodos empregados na avaliação da qualidade vertical de MDEs. Usualmente, a medida da qualidade destes MDEs é apresentada na forma da raiz quadrada do erro médio quadrático (RMSE) da elevação, calculado conforme a equação 5.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n d_i^2}{n}} \quad (5),$$

onde  $d$  é a diferença de elevação entre os MDEs avaliados e  $n$  é o número de pontos de elevação testados. Segundo Holmes et al., (2000), o RMSE é medido a partir de pontos de amostra discretos e é comumente utilizado para estimar o erro ou a incerteza nos locais onde o erro não foi medido diretamente. Para um MDE o RMSE se refere ao grau

de diferença entre os valores interpolados e os valores de elevação mais prováveis, de modo que o termo elevação verdadeira não deve ser utilizado, já que este normalmente é considerado como sendo desconhecido.

Desta forma, o primeiro estágio do processo de avaliação constou da determinação do RMSE dos MDEs, calculados pela comparação de cada MDE testado com os pontos de elevação de referência descritos anteriormente. Nesta comparação foi utilizada uma operação de álgebra de mapas (subtração entre grids), através do módulo Spatial Analyst do ArcGIS Desktop 9.0. Assim, quanto maiores são os valores do RMSE, maiores são as discrepâncias entre os conjuntos de dados comparados.

Segundo Wood (1996), a principal vantagem e motivo pelo qual o RMSE é bastante utilizado, é a sua facilidade de computação. Para Wechsler (1999), o RMSE é essencialmente um desvio padrão e, desta maneira, é baseado na hipótese de que os erros nos MDEs são aleatórios e normalmente distribuídos.

Finalmente, foram realizadas comparações entre os MDEs TIN, ASTER e SRTM com o MDE CARTA, por meio da obtenção dos perfis de elevação e da diferença. Os primeiros foram obtidos utilizando-se a opção Raster/Profile Tools/Spatial Profile do ERDAS Imagine 8.5. Os perfis da diferença foram obtidos utilizando-se, primeiramente, uma operação de álgebra de mapas, através da subtração entre os MDEs envolvidos para a aquisição do grid da diferença, e em seguida a opção Raster/Profile Tools/Spatial Profile do ERDAS Imagine 8.5 para a aquisição do perfil.

#### **2.4.2. Avaliação Qualitativa**

Visto que a maioria das aplicações dos MDEs depende de representações da forma da superfície e estrutura da drenagem, medidas absolutas dos erros de elevação não fornecem uma avaliação completa da qualidade de um MDE (Wise, 2000). Um grande número de técnicas descritivas para avaliação da qualidade de dados tem sido desenvolvido. Estas são medidas não clássicas da qualidade de dados que oferecem meios para análise sem a utilização de pontos de referência de elevada exatidão (Hutchinson & Gallant, 2000).

O desenvolvimento do solo em muitas situações ocorre em resposta ao modo como a água se move através e sobre a paisagem. Os atributos do terreno podem

caracterizar os caminhos do fluxo e as interações com os atributos do solo. Assim, para contornar as limitações da utilização do RMSE na avaliação dos MDEs foi realizada uma avaliação da qualidade destes em termos da representação dos aspectos da superfície, conforme sugerido por Hutchinson & Gallant (2000) e Wise (2000), que são: *a)* análise do número e extensão das depressões espúrias; *b)* comparação entre a drenagem mapeada e a drenagem derivada pelos diferentes MDEs; *c)* comparação entre as curvas de nível derivadas e as curvas de nível originais; e *d)* análise das bacias de contribuição derivadas.

Depressões espúrias em MDEs são muito frequentes e constituem uma fonte significativa de problemas em muitas aplicações, principalmente hidrológicas. Depressões podem ser causadas por dados incorretos ou insuficientes, ou ainda pela técnica de interpolação utilizada. Desta maneira, a análise das depressões espúrias pode ser um modo eficiente de detectar erros na fonte de dados e de avaliar a qualidade geral da estrutura da drenagem do MDE (Hutchinson & Gallant, 2000). As depressões espúrias nos MDEs avaliados foram detectadas em número e extensão utilizando-se o módulo Spatial Analyst do ArcGIS Desktop 9.0.

A rede de drenagem foi derivada para cada MDE, após a remoção das depressões espúrias, usando as funções *FlowDirection* e *FlowAccumulation* no módulo Spatial Analyst do ArcGIS Desktop 9.0. O valor de escoamento acumulado necessário para gerar a rede de drenagem numérica com aproximadamente o mesmo nível de detalhe da rede de drenagem mapeada (1:50.000) foi obtido por meio de tentativa e erro.

De acordo com Hutchinson & Gallant (2000), as curvas de nível derivadas de um MDE fornecem uma avaliação sensitiva sobre a estrutura do terreno e é bastante útil devido a sua sensibilidade aos erros de elevação na fonte de dados. Deste modo, foi realizada uma comparação visual entre as curvas de nível derivadas a partir dos MDEs com as curvas de nível originais para detectar a presença de artefatos nos primeiros. Neste procedimento também foi utilizado o módulo Spatial Analyst do ArcGIS Desktop 9.0.

Deficiências na qualidade de um MDE podem ser detectadas pela derivação das bacias de contribuição (Wise, 2000). Estas foram obtidas utilizando-se a função *Watershed* no módulo Spatial Analyst do ArcGIS Desktop 9.0.



### 3. RESULTADOS E DISCUSSÃO

#### 3.1. Avaliação Quantitativa

Os resultados da avaliação quantitativa pelo RMSE dos MDEs são apresentados na Tabela 1 e mostram uma grande semelhança entre os valores de RMSE produzidos pelos MDEs derivados das curvas de nível e pelo MDE SRTM. Por outro lado, todos mostram resultados bastante distintos daqueles obtidos para o MDE ASTER, com os primeiros apresentando valores significativamente melhores.

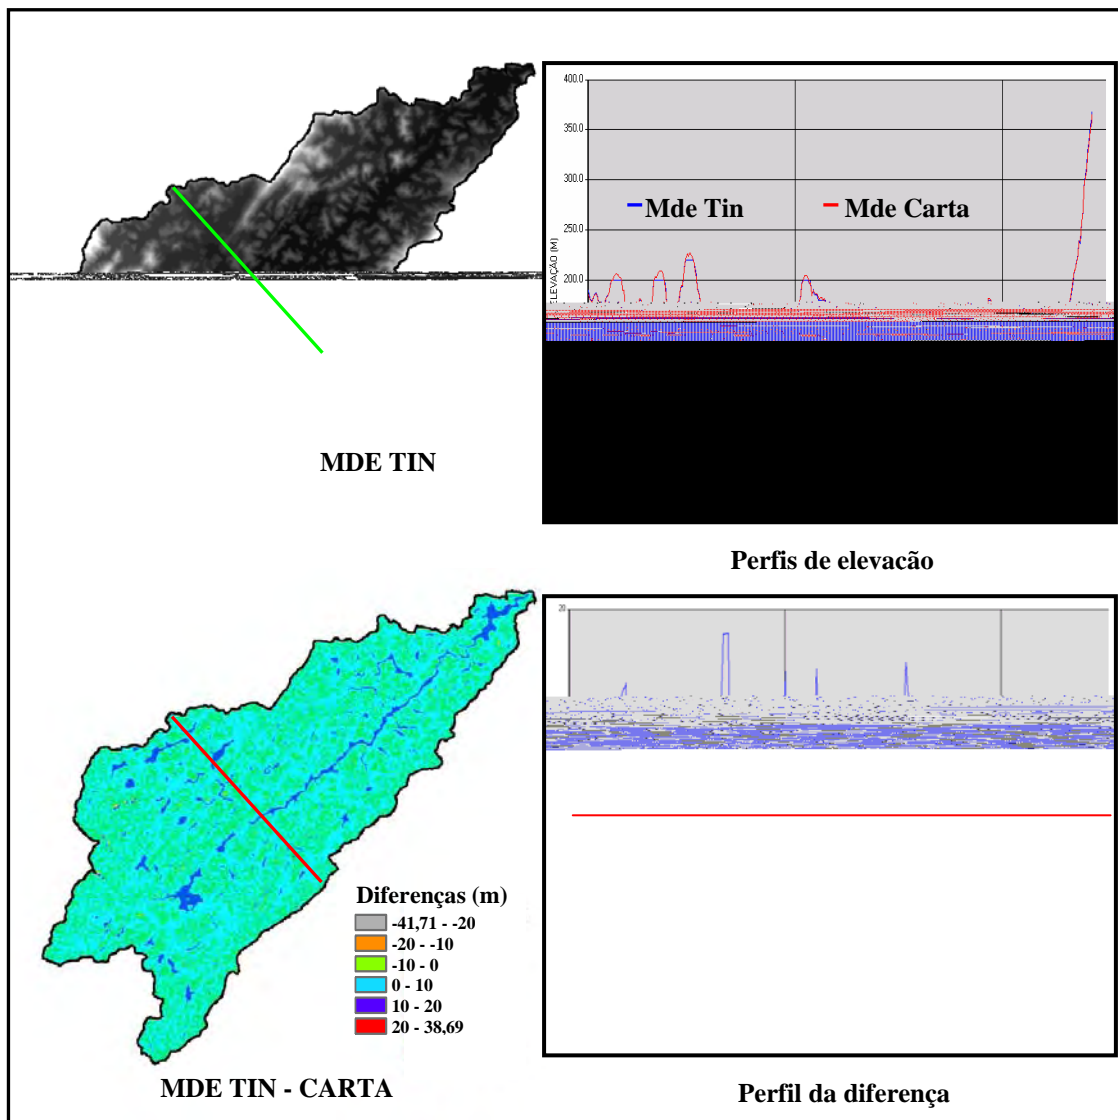
**TABELA 1. Resultados estatísticos para os diferentes MDEs estudados.**

MDE	Valor Mínimo	Valor Máximo	Média	Desvio padrão	RMSE <sup>(a)</sup> (m)
CARTA	69	913	212,44	120,47	14,23
TIN	80	920	213,83	119,47	13,41
ASTER	102	877	235,95	113,46	36,69
SRTM	82	901	219,14	119,31	12,04

(a) obtido pela diferença com os pontos de elevação de referência.

Uma comparação entre os MDEs derivados de curvas de nível mostra, no entanto, que o MDE TIN é ligeiramente superior ao MDE CARTA, sugerindo que o algoritmo de interpolação linear produziu uma interpolação dos valores de elevação (RMSE de 13,41) levemente melhor do que o TOPOGRID (RMSE de 14,23). Estes resultados corroboram as afirmativas de que o método baseado na triangulação (TIN) é bastante eficiente em áreas de relevo acidentado, como é o caso da área estudada (Fernandes & Menezes, 2005). Segundo Namikawa (1994), os MDEs que utilizam grades regulares são bastante adequados para a representação de superfícies suaves e de variação contínua. Quando a superfície de análise possui descontinuidades ou grandes variações essas grades apresentam deficiências. No entanto, o módulo TOPOGRID, que utiliza a hidrografia e outros corpos de água como elementos de descontinuidade e suavização, possibilita um sensível aumento da precisão dos modelos gerados (Fernandes & Menezes, 2005).

Os resultados obtidos para a comparação dos MDEs TIN, ASTER e SRTM com o MDE CARTA são mostrados nas Figuras 3, 4 e 5.



**FIGURA 3. Comparação entre o MDE TIN e o MDE CARTA.**

Os métodos de triangulação têm dificuldades para interpolar dados oriundos de curvas de nível, criando muitos triângulos planos ao longo dos canais e cumes onde os dados de elevação são escassos. Assim, apesar de os perfis de elevação do MDE TIN e do MDE CARTA apresentarem uma boa semelhança, é possível verificar, no perfil de elevação da Figura 3, que a falta de dados, produziu áreas planas e topos planos no MDE TIN que não são encontrados no MDE CARTA.

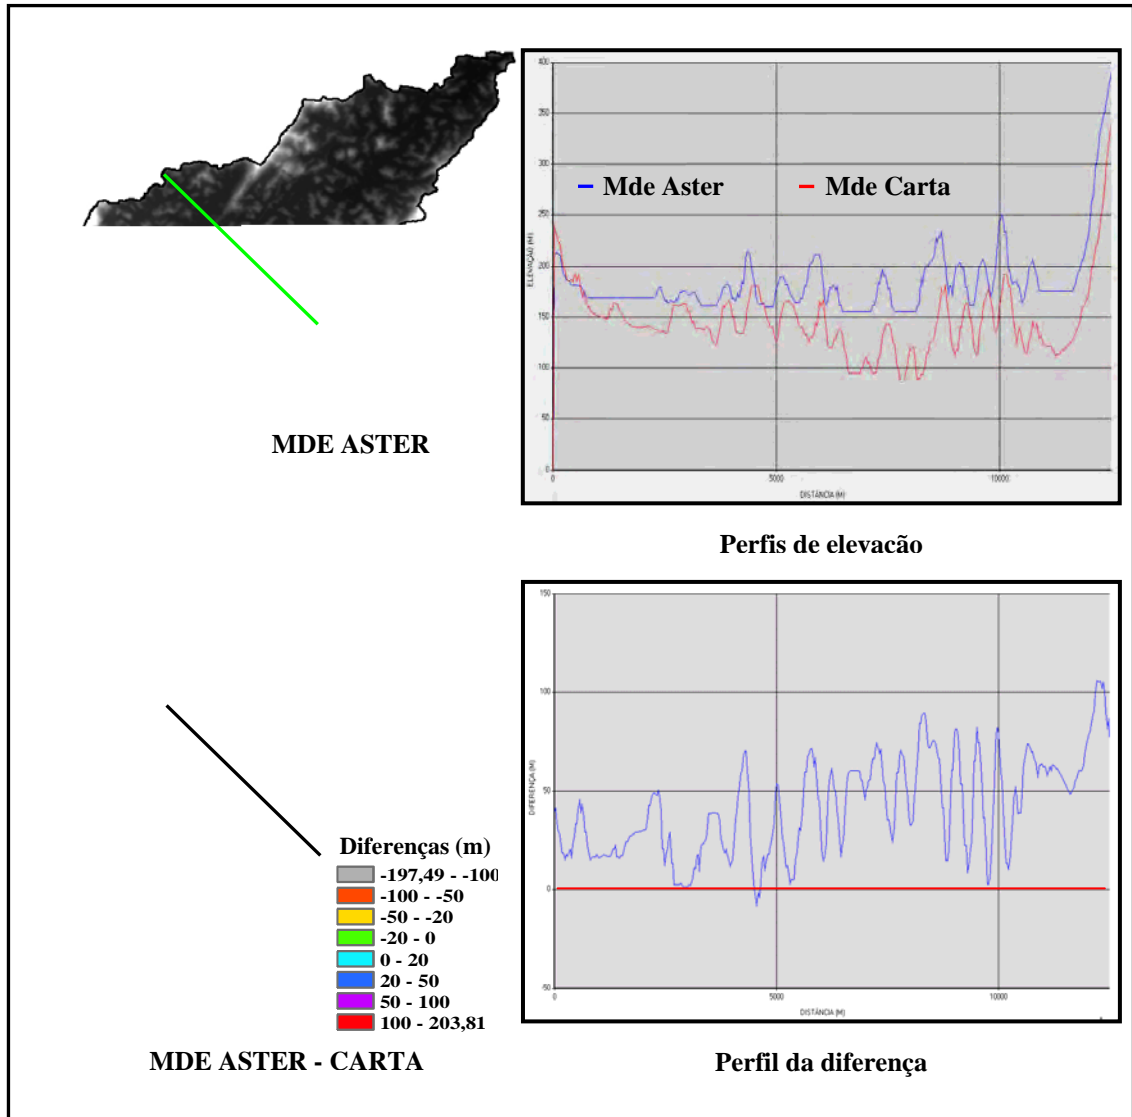
Uma comparação mais detalhada mostra diferenças marcantes entre estes, sendo estas mais pronunciadas nas áreas mais planas (diferença entre 10 e 20m), onde o modelo TIN mostra exatamente suas maiores limitações. Nas encostas íngremes a maior parte das diferenças é negativa (entre -10 e 0), significando que nestas áreas o MDE

TIN representa uma superfície mais baixa do que o MDE CARTA. Os dois modelos apresentam resultados comparáveis àqueles citados como padrão para os MDEs do USGS, ou seja, RMSE inferior a uma vez e meia o intervalo das curvas de nível, ou seja, 30m.

O MDE ASTER produziu um valor de RMSE bastante elevado, na comparação com os pontos de elevação de referência (36,69m) (Tabela 1), apresentando o pior desempenho entre os MDEs avaliados. Estes resultados são bastante discordantes daqueles obtidos em outros estudos, que obtiveram resultados mais satisfatórios (Hirano et al., 2003; Cuartero et al., 2004; Poli et al., 2004). Prováveis explicações para estes resultados incluem as características do terreno, a presença de nuvens nas imagens, a falta de pontos de controle terrestres adequados, o pouco domínio sobre o software e até mesmo o próprio software empregado para obtenção do MDE.

Estudo realizado por Kääb et al. (2002), obteve um RMSE de aproximadamente 60 m para uma área montanhosa na Nova Zelândia, com o erro máximo alcançando até 500 m. Análises realizadas mostraram erros severos no MDE derivado do ASTER localizados nas encostas íngremes. De acordo com os autores, estes erros são previsíveis considerando-se o fato de que tais encostas ficam totalmente escondidas ou sombreadas quando da passagem do sensor que obtém a banda 3B, ou pelo menos são grandemente distorcidas. Nestas condições, as encostas recebem menos iluminação solar reduzindo o contraste da imagem e aumentando a probabilidade de falhas na correlação entre as imagens 3N e 3B.

Na área estudada são encontradas encostas extremamente íngremes que podem atingir mais de 900 m de altitude (Alinhamentos Serranos do Noroeste Fluminense), adjacentes a áreas planas com altitudes em torno de 100 m. Assim, os problemas descritos acima podem ter interferido negativamente para o elevado valor do RMSE do MDE ASTER. Para confirmar esta hipótese, as maiores diferenças negativas, com relação ao MDE CARTA, estão localizadas, principalmente nas encostas mais íngremes, enquanto as diferenças positivas estão localizadas nas encostas menos íngremes e nas áreas planas (Figura 4).



**FIGURA 4. Comparação entre o MDE ASTER e o MDE CARTA.**

Erros grosseiros em MDEs gerados a partir de dados de sensoriamento remoto podem ser atribuídos a muitos fatores, como: ruídos nos processos de aquisição e transferência dos dados, erros na geometria da órbita ou a presença de nuvens nas imagens. Como a obtenção da elevação no MDE derivado do sensor ASTER depende da correlação entre as bandas 3N e 3B, a existência de nuvens e sombras em pelo menos uma das bandas introduz um erro no procedimento de correlação. Um pixel na banda 3N que esteja sob uma nuvem possui valor próximo a 255, quando correlacionado com a banda 3B esse mesmo pixel fica perdido dentro da janela de busca, pois a nuvem vai apresentar altos valores de radiância em uma vasta extensão da janela, produzindo altos valores de coeficiente de correlação. Essa perda de posicionamento provocará valores

errados de paralaxe e conseqüentemente de elevação (Druzina, 2004). Deste modo, a presença de 7% de nuvens nas imagens ASTER utilizadas neste estudo pode ter contribuído significativamente para reduzir a qualidade final do MDE gerado a partir destas imagens.

Avaliações da qualidade vertical de MDEs derivados do sensor ASTER a partir de estereocorrelação indicam que valores de RMSE entre  $\pm 7$  e  $\pm 15$ m podem ser alcançados quando se utilizam softwares adequados, imagens de boa qualidade e pontos de controle terrestres adequados (Hirano et al., 2003). No presente estudo, a falta de pontos de controle adequados para geração do MDE ASTER pode ter contribuído também para a baixa qualidade do modelo. As especificações para o RMSE de MDEs relativos variam de 10 a 30m (Lang & Welch, 1999), e neste caso, o RMSE obtido foi superior ao especificado.

Alguns estudos mostram que o software utilizado para geração do MDE ASTER tem influência marcante sobre os valores de RMSE obtidos. Cuartero et al. (2004), obtiveram resultados distintos para valores de RMSE utilizando dois diferentes softwares na geração de MDEs ASTER. O software Ortho Engine (Geomatica), que tem um módulo específico para dados do ASTER apresentou, para uma mesma área, resultados melhores (RMSE de 12,6 m) do que o módulo Ortho Base do ERDAS IMAGINE (RMSE de 34,8 m). Assim, o software utilizado na geração do MDE ASTER deste estudo (AsterDTM 2.2 do software ENVI 4.2) pode ter influenciado nos resultados obtidos. Além disso, a pouca experiência em sua utilização, também pode ter contribuído negativamente.

Na Figura 4 é possível verificar a grande diferença nos valores de elevação entre o MDE ASTER e o MDE CARTA, sendo essa diferença em grande parte positiva, ou seja, o MDE ASTER representa uma superfície mais elevada do que o MDE CARTA. A média e o desvio padrão obtidos para esta diferença foram de 23,50 e 28,43 m, respectivamente. De modo geral, as maiores discrepâncias são verificadas em altitudes inferiores a 200 m, como mostra o perfil de elevação da Figura 4.

Druzina (2005) obteve resultados semelhantes ao comparar um MDE derivado do ASTER com pontos de controle terrestre e com um MDE derivado de curvas de nível em uma região montanhosa no sul de Santa Catarina e nordeste do Rio Grande do

Sul. Nas duas comparações o MDE ASTER representou uma superfície mais elevada que os pontos de controle terrestre e o MDE derivado de curvas de nível.

Resultados discordantes foram obtidos por Kamp et al. (2003); Bolch & Kamp (2003) e Eckert & Kellenberger (2002), que em geral obtiveram valores de elevação mais baixos do que os pontos de controle utilizados como referência. Kamp et al. (2003), atribuíram estes resultados à falta de pontos de controle para geração do MDE e ao procedimento de suavização do software empregado (Geomatica).

Os resultados da Tabela 1 mostram que o MDE SRTM produziu um valor de RMSE bastante satisfatório, na comparação com os pontos de elevação de referência (12,04m), sendo equivalente aos resultados obtidos pelos MDEs derivados das curvas de nível. Cabe ressaltar que, para esta avaliação, os dados originais do SRTM foram reamostrados para 30 m, de modo a permitir uma comparação com os demais MDEs. Apesar disso, os resultados obtidos foram superiores aos demais.

Segundo a USGS (2005), a exatidão vertical esperada para os dados do SRTM é de  $\pm 16\text{m}$ , portanto, os resultados alcançados estão de acordo com o especificado. Barros et al. (2005b), obtiveram um RMSE de 23,94 m para um MDE do SRTM em uma área litorânea montanhosa no sul do Estado do Rio de Janeiro, com um resíduo máximo de 48,3m em relação aos pontos de controle utilizados.

Entretanto, alguns trabalhos têm apontado para a possibilidade de obtenção de precisões melhores do que as inicialmente estimadas (Koch et al., 2002; Santos et al., 2005). Santos et al. (2005), em estudo realizado na região amazônica compararam dados do SRTM com MDEs gerados a partir de cartas topográficas, em diferentes escalas, utilizando um conjunto de pontos de controle. Em todas as situações avaliadas o MDE do SRTM apresentou melhores resultados altimétricos com relação ao MDE originado de cartas topográficas, com valores do erro médio quadrático de 10,74 m, para a escala de 1:50.000, quando se considerou a totalidade dos pontos de controle disponíveis. As maiores diferenças verificadas entre os modelos avaliados foram encontradas nos vales próximo aos rios.

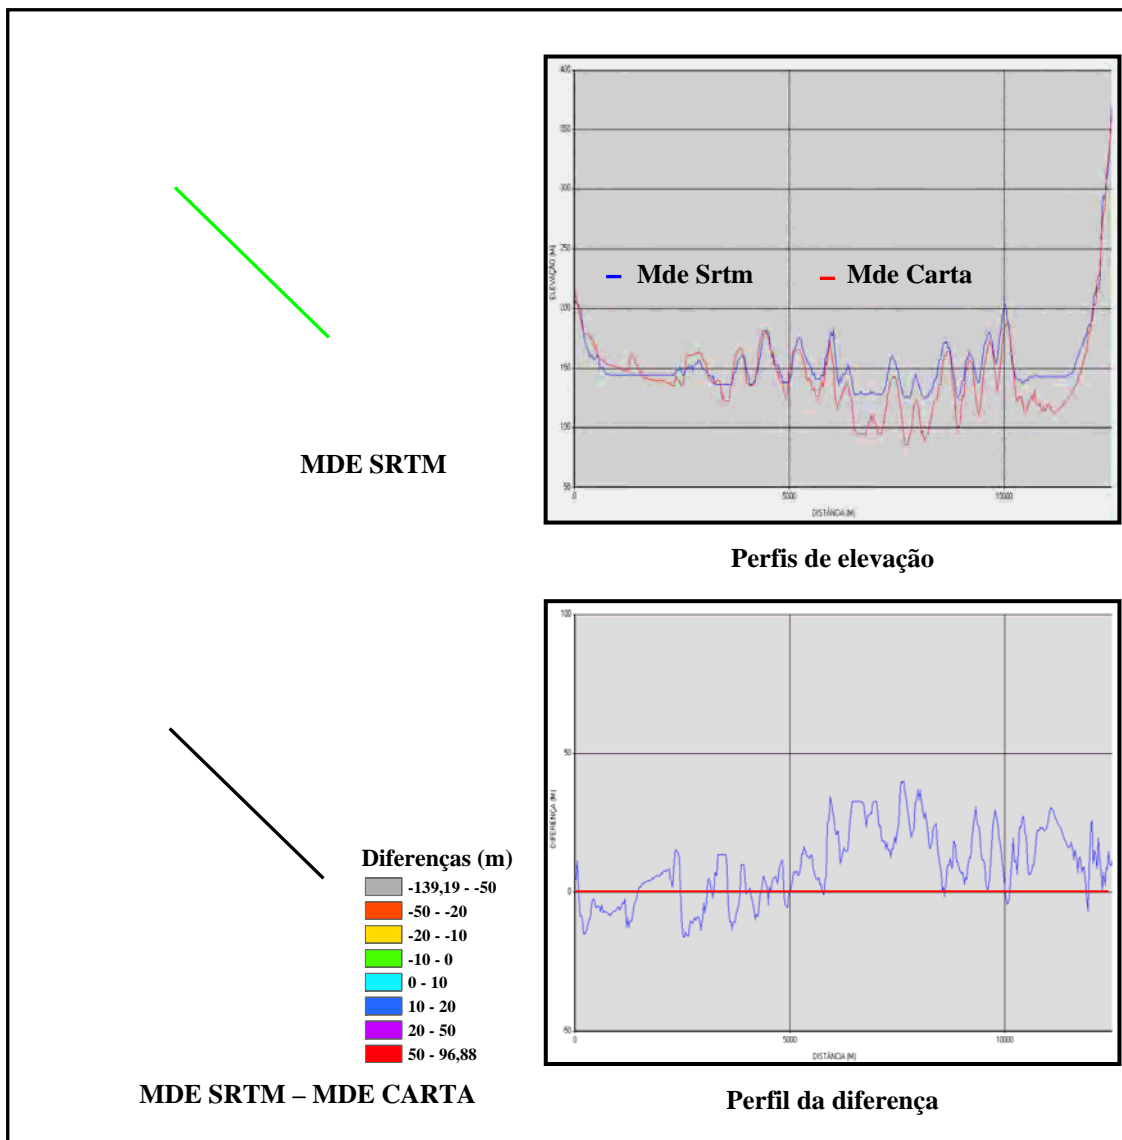
Os resultados obtidos para o MDE SRTM podem ser influenciados pelas características do terreno da área estudada. Resultados de estudos realizados por Kocak et al. (2004) e Gerstenecker et al. (2005), mostraram que a exatidão de MDEs derivados

de sensores remotos é muito dependente da inclinação do terreno, sendo a qualidade mais baixa em áreas declivosas do que em áreas planas.

Os MDEs do SRTM não são editados para remoção de erros grosseiros antes de serem disponibilizados e, portanto, apresentam ruídos e falhas, principalmente, em áreas muito íngremes. O instrumento In-SAR banda C utilizado para coletar dados do SRTM tem um ângulo de incidência que varia entre 31 e 61°. A área da bacia do rio São Domingos apresenta uma declividade média de 13,98° (25,57%), sendo que aproximadamente 3,2% das encostas apresentam declividade superior à 31°. Encostas que apresentam ângulos entre 31 e 61° são imageadas com menor exatidão, pois nestas condições ocorrem problemas relacionados com a interrupção do sinal de retorno do radar, que levam à produção de erros nos dados gerados (Kocak et al., 2004; Gerstenecker et al., 2005). Desta maneira, Falorni et al. (2005), sugerem que em terrenos muito elevados e íngremes a exatidão especificada de 16 m para MDEs do SRTM deva ser considerada apenas como uma diretriz.

A Figura 5 mostra que as maiores discordâncias entre o MDE SRTM e o MDE CARTA na seção longitudinal ocorrem nas partes mais baixas e planas da área. No entanto, as maiores diferenças nos valores de elevação entre eles ocorrem exatamente nas áreas com as maiores declividades. A maior parte das diferenças observadas é positiva (67,13%), como mostra o perfil da diferença da Figura 5, estando estas localizadas, principalmente, na porção centro-leste da área em encostas voltadas para sul. As diferenças negativas (32,87%), por sua vez, são mais pronunciadas nas encostas voltadas para norte.

Jarvis et al., (2004), observaram uma tendência semelhante nos dados de elevação influenciada pela orientação da encosta ao avaliarem um MDE SRTM para Honduras. No entanto, neste estudo as diferenças positivas, em relação ao MDE oriundo de cartas topográficas, estavam presentes nas encostas norte, nordeste ou leste, enquanto as negativas foram observadas nas encostas sul, sudeste ou oeste. Estes resultados, segundo os autores, foram atribuídos ao efeito do ângulo de incidência das imagens de radar originais usadas para produzir o MDE do SRTM.



**FIGURA 5. Comparação entre o MDE SRTM e o MDE CARTA.**

### 3.2. Avaliação Qualitativa

A derivação da rede de drenagem é sensivelmente afetada pela presença de depressões espúrias em um MDE, que podem comprometer análises futuras (Wise, 2000). Assim, inicialmente a avaliação qualitativa constou da determinação do número e extensão das depressões em cada MDE. Os resultados obtidos são mostrados na Tabela 2 e Figura 6.



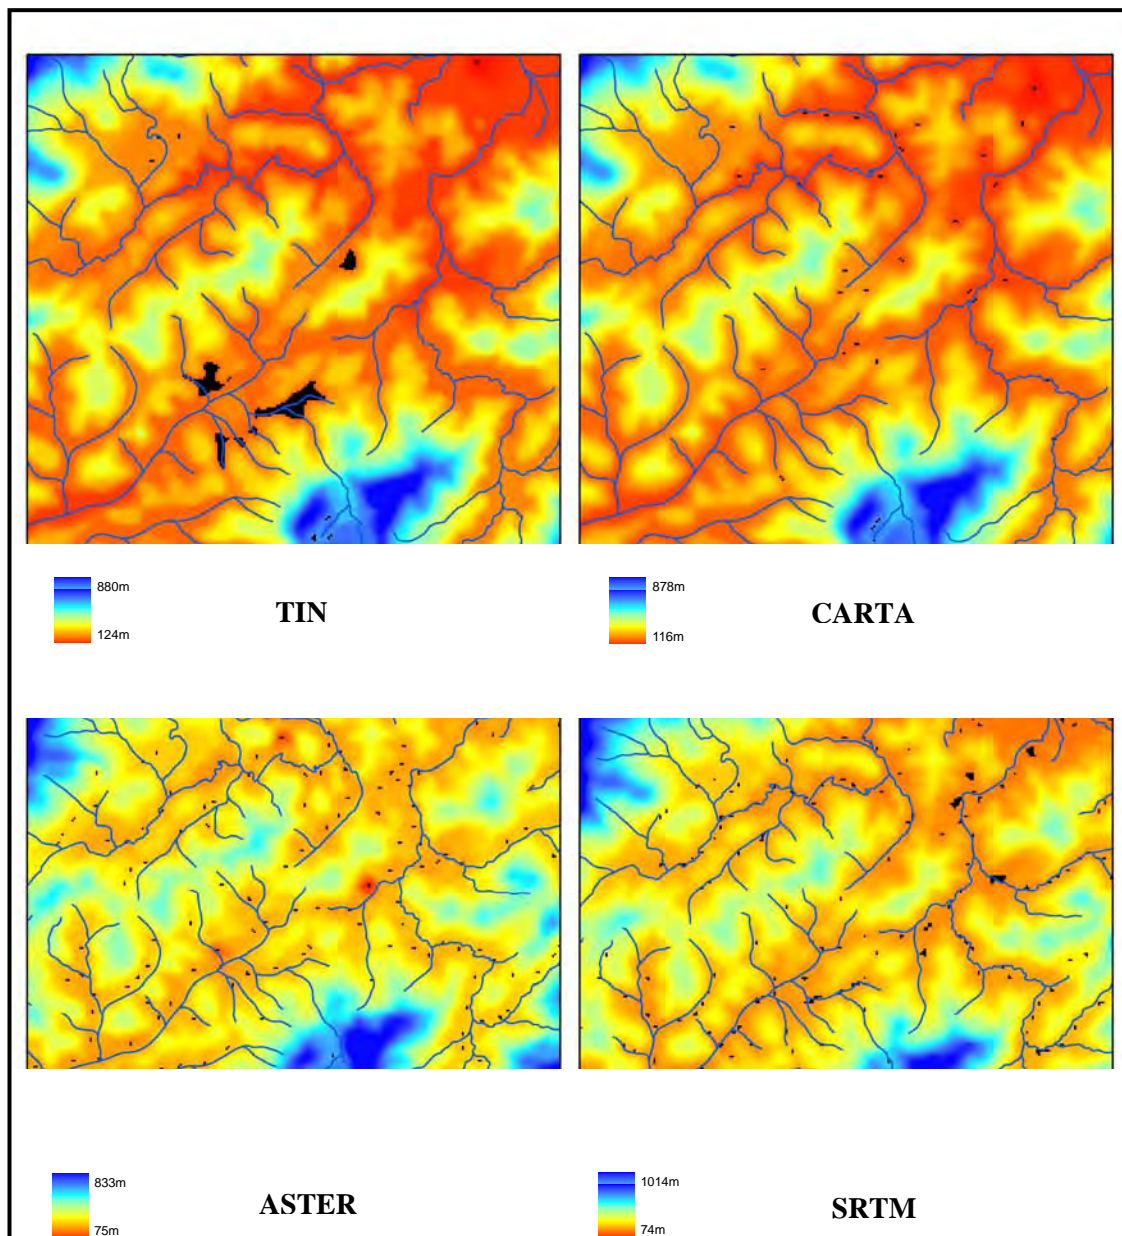
**TABELA 2. Número e extensão das depressões espúrias dos MDEs avaliados.**

<b>MDE</b>	<b>Número de depressões</b>	<b>Número de pixels nas depressões</b>	<b>% em relação ao grid total</b>
<b>TIN</b>	48	524	0,06
<b>CARTA</b>	394	781	0,10
<b>ASTER</b>	2104	4308	0,53
<b>SRTM</b>	2057	6601	0,81

A Tabela 2 mostra que existe uma diferença marcante no número e extensão das depressões espúrias entre os MDEs derivados das curvas de nível e os derivados dos sensores remotos. Quando se considera o número de depressões verifica-se que os MDEs derivados de sensores remotos apresentam aproximadamente 40 vezes mais depressões do que o verificado no MDE TIN, e 5 vezes mais do que o observado no MDE CARTA. Com relação ao número de pixels afetados pelas depressões as diferenças são menos marcantes, no máximo 12 vezes, quando se compara o MDE SRTM com o MDE TIN.

Considerando apenas o número e a extensão das depressões espúrias o melhor MDE produzido é o MDE TIN com apenas 48 depressões, que englobam 524 pixels. Mesmo apresentando poucas depressões, cabe ressaltar que será necessário removê-las antes que o mesmo possa ser utilizado. No MDE TIN as poucas depressões encontradas estão limitadas às porções sudoeste e noroeste da área (Figura 6). O maior número de pixels envolvidos nestas depressões se deve ao fato de que o processo de triangulação produz triângulos que se estendem pelas áreas planas dos vales, onde existem poucos pontos de elevação, os quais podem formar barreiras que interrompem o fluxo de água através da superfície do modelo.


Embora o MDE CARTA tenha sido produzido com a utilização do módulo TOPOGRID, desenhado para a criação de um modelo digital de elevação hidrologicamente consistente, o número de depressões espúrias nele presentes é relativamente alto (394) quando comparado ao MDE TIN. Uma possível explicação para estes resultados, levantada por Wise (2000), em estudo em uma área com características semelhantes a da área estudada, é a natureza do terreno que combina encostas muito íngremes com vales planos, o que leva a formação de depressões, principalmente, nos limites entre os vales e as encostas (Figura 6).



**FIGURA 6. Localização das depressões espúrias em uma parte dos MDEs avaliados.**

Os MDEs ASTER e SRTM apresentam um elevado número de depressões espúrias disseminadas por toda a área estudada (Figura 6). Apesar de serem numerosos, o número de pixels envolvidos em cada depressão é reduzido, normalmente de 1 a 2 pixels. Somente em poucos casos, principalmente no MDE SRTM, o número de pixels é superior a 2, como pode ser observado no canto superior direito deste, na Figura 6. O elevado número de depressões espúrias nestes MDEs, muito comum em dados derivados de sensores remotos, pode ser atribuído a erros grosseiros oriundos do método de coleta de dados utilizado por estes sensores (Hengl et al., 2004).

Embora estejam presentes em todos os MDEs avaliados, as depressões espúrias não ultrapassam 1% da área total. Apesar disso, estas depressões foram removidas para possibilitar a derivação de uma rede de drenagem para cada um dos MDEs. No entanto, cabe ressaltar que o procedimento de remoção das depressões pode causar mudanças nos valores das elevações e afetar muito



**FIGURA 7. Comparação entre as redes de drenagem derivadas (vermelho) e a drenagem mapeada (azul), em parte dos MDEs avaliados.**

Embora na produção do MDE TIN tenham sido utilizados os mesmos dados (curvas de nível, pontos de elevação e hidrografia mapeada) do MDE CARTA, os resultados alcançados não são satisfatórios quando se compara a drenagem derivada deste com a drenagem mapeada. Estes são sensivelmente piores do que os obtidos pelo MDE CARTA e um pouco melhores do que os alcançados pelos MDEs ASTER e SRTM. Entretanto, a presença de artefatos produzidos pelo algoritmo de interpolação linear, principalmente ao longo dos limites dos triângulos proporcionou o aparecimento de grande número de feições que cruzam as curvas de nível e também de linhas


paralelas em toda a extensão da área estudada. A análise mostra também que existe, no MDE TIN, uma diferença na concordância, em função da localização topográfica na área estudada, sendo melhor nas partes mais declivosas e pior nas partes planas. Nestas últimas, as linhas de drenagem foram distorcidas em relação à localização real, seguindo os caminhos de menor resistência gravitacional do MDE (Saunders, 1999).

O objetivo que se busca na criação de um MDE é a obtenção de um modelo que contenha o máximo possível de detalhes topográficos, preservando sempre as características do terreno. Os resultados da comparação visual entre as curvas de nível geradas a partir dos MDEs com as curvas de nível originais são mostrados na Figura 8.

As curvas de nível derivadas generalizaram os dados em quantidades variadas. Mesmo apresentando o menor número de depressões espúrias, o MDE TIN removeu ou diminuiu significativamente alguns picos que estão presentes nas curvas de nível originais, formando grandes áreas planas nos topos de morros, devido à falta de pontos de elevação nestas áreas. Embora apresente uma boa concordância com as curvas originais é possível identificar a presença de várias curvas de nível que se cruzam.

A melhor concordância com as curvas de nível digitalizadas foi obtida pelo MDE CARTA, como pode ser observado na Figura 8. Os picos citados anteriormente para o MDE TIN foram mantidos e somente pequenas variações são notadas com relação às linhas originais, podendo o MDE CARTA ser considerado, portanto, superior aos demais para este critério.

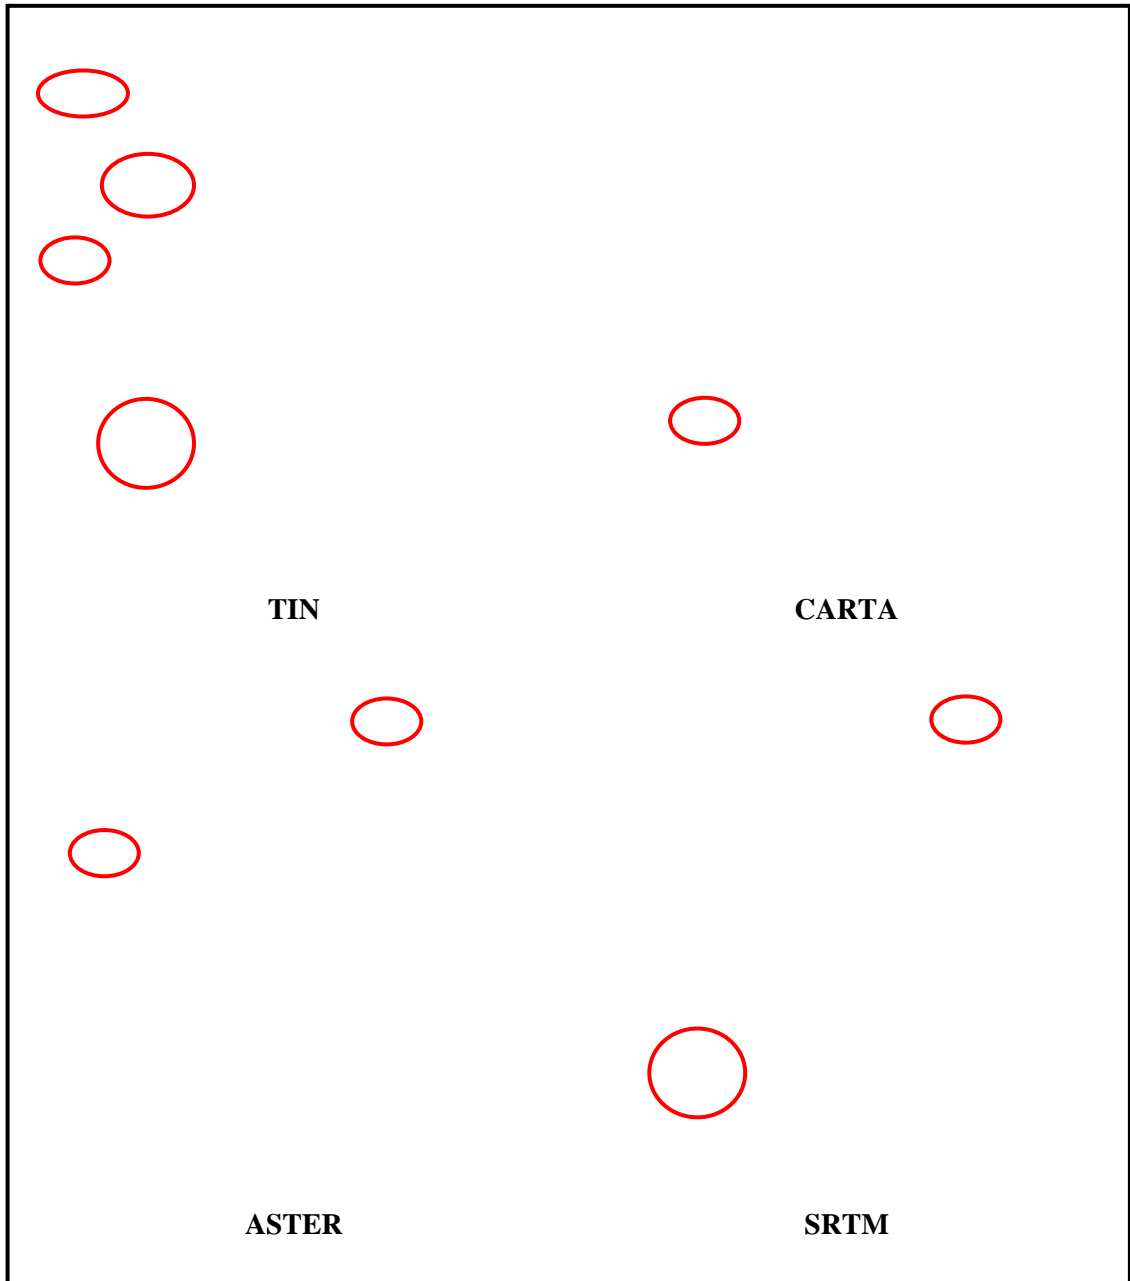
Os MDEs ASTER e SRTM mostraram resultados bastante semelhantes entre si, porém a concordância destes com as curvas de nível digitalizadas é muito baixa (Figura 8). Apesar disso, ambos não removeram significativamente os picos presentes nas curvas de nível originais, tal como ocorreu para o MDE TIN. Nestes também são verificadas curvas de nível que se cruzam e a ausência de uma curva de nível próxima da drenagem.



**FIGURA 8. Comparação entre as curvas de nível derivadas (vermelho) e a curvas de nível originais (preto), em parte dos MDEs avaliados.**

Para completar a avaliação qualitativa dos MDEs conforme proposto por Wise (2000), foram derivadas as bacias de contribuição de cada MDE, que são mostradas na Figura 9. A bacia do rio São Domingos digitalizada foi sobreposta para ilustrar as principais diferenças entre esta e a bacia correspondente, derivada pelos diferentes MDEs. Estas foram derivadas apenas pela identificação da direção do vizinho com valor mais baixo de cada pixel, e desta maneira, são sensíveis à presença de artefatos nos

dados. Pequenas diferenças na elevação entre pixels vizinhos podem causar aparentemente grandes mudanças na direção do fluxo e afetar conseqüentemente as bacias derivadas (Wise, 1998).



**FIGURA 9. Bacias de contribuição derivadas dos MDEs.**

De maneira geral, verifica-se uma boa concordância entre os MDEs avaliados com relação as bacias de contribuição derivadas. As diferenças mais relevantes são verificadas para o MDE TIN que apresenta uma maior subdivisão das bacias quando comparado aos demais MDEs. Também neste é observada a pior concordância entre a

bacia do rio São Domingos digitalizada e a correspondente derivada, conforme mostrado na Figura 9. As outras diferenças observadas entre este MDE e os demais estão concentradas, em grande parte, ao longo das divisas, e estão relacionadas com problemas na interpolação dos valores de elevação onde existe pouca informação disponível a partir das curvas de nível.

Os melhores resultados para esta avaliação foram obtidos para o MDE CARTA que mostra uma boa concordância com o limite digitalizado da bacia do rio São Domingos. A bacia do rio São Domingos derivada do MDE ASTER também mostra uma boa concordância com a digitalizada, já que nas avaliações anteriores este sempre apresentou os maiores problemas dentre os MDEs estudados. O MDE SRTM, igualmente, apresentou resultados bastante satisfatórios, sendo estes, ligeiramente inferiores aos MDEs CARTA e ASTER.

#### **4. CONCLUSÕES**

A avaliação realizada neste estudo mostrou que os MDEs derivados das curvas de nível apresentam qualidade superior aos MDEs derivados de sensores remotos, quantitativa e qualitativamente. Embora alguns estudos tenham mostrado que MDEs de boa qualidade podem ser gerados a partir de dados de sensores remotos, os resultados obtidos chamam a atenção para o uso indiscriminado destes dados sem uma análise prévia criteriosa, principalmente, para áreas de relevo movimentado. Neste sentido, todos os MDEs avaliados contêm artefatos e erros grosseiros que potencialmente podem afetar análises futuras e assim, devem ser checados para assegurar que satisfazem às expectativas. As várias críticas à utilização do RMSE como medida da qualidade de MDEs foram justificadas neste estudo, pois tal medida estatística não possibilitou a separação dos dois grupos, visto que os MDEs derivados de curvas de nível (MDE TIN e MDE CARTA) e o MDE SRTM apresentaram valores bastante próximos de RMSE, confirmando que o RMSE da elevação é uma medida pouco eficiente da qualidade de MDEs (Wise, 2000).



Além disso, somente o RMSE não foi suficiente para definir, entre estes MDEs, qual apresenta melhor qualidade. No entanto, a análise qualitativa mostrou que o MDE CARTA é superior ao MDE TIN e ao MDE SRTM, pois estes últimos apesar de possuírem um RMSE menor, apresentam artefatos e erros grosseiros relacionados com o interpolador linear utilizado pelo modelo TIN e com a técnica de interferometria utilizada pelo SRTM, que foram facilmente detectados pela análise da drenagem, curvas de nível e bacias de contribuição derivadas, confirmando, desta feita que esta medida estatística não deve ser utilizada isoladamente para estimar a qualidade de MDEs.

Os resultados obtidos pelo MDE ASTER não foram satisfatórios, apresentando valores de RMSE significativamente mais elevados do que os obtidos em outros estudos. De maneira geral, os MDEs ASTER e SRTM representam uma superfície mais elevada do que os pontos de referência utilizados e do que o MDE CARTA. No caso do MDE ASTER, a baixa qualidade foi atribuída à presença de nuvens nas imagens em porcentagens superiores ao recomendado; à falta de pontos de controle adequados para geração de um MDE absoluto; e a pouca experiência na utilização do software empregado para gerar o MDE a partir das imagens nível 1B do ASTER.

O MDE SRTM, por sua vez, apresentou resultados quantitativos (RMSE) significativamente melhores do que o MDE ASTER, mesmo considerando que este foi reamostrado para uma resolução espacial de 30m a partir dos dados originais de 90m, e semelhantes aos obtidos por outros estudos. Os problemas identificados no MDE SRTM estão relacionados com as características do terreno na área avaliada (relevo muito movimentado), aliado ao efeito do ângulo de incidência das imagens de radar originais usadas. Qualitativamente, os MDEs ASTER e SRTM mostraram-se bastante semelhantes, apresentando elevado número de depressões espúrias e baixíssima concordância com a drenagem e curvas de nível derivadas.

Considerando as avaliações realizadas, o MDE CARTA foi o que apresentou os melhores resultados e, deste modo, foi utilizado como fonte de informação básica nos capítulos seguintes deste estudo. Para tanto, os erros detectados durante esta avaliação foram corrigidos para torná-lo mais consistente e atingir os objetivos propostos.

## 5. LITERATURA CITADA

AL-ROUSAN, N. & PETRIE, G. System calibration, geometric accuracy testing and validation of DEM & orthoimage data extracted from SPOT stereopairs using commercially available image processing systems. **International Archives of Photogrammetry and Remote Sensing**, v.32, p.8-15, 1998.

BARROS, R. S. et al. Avaliação da qualidade vertical de DEMs do SRTM. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, SIMPÓSIO DE GEOTECNOLOGIAS PARA PETRÓLEO E XXI EXPOSICARTA, 22., 2005, Macaé. **Anais...** Macaé: Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto, 2005a. 1CD-ROM.

BARROS, R. S. et al. Avaliação do modelo digital de elevação do SRTM na ortorectificação de imagens Landsat 7 - Área de aplicação: Angra dos Reis - RJ. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 12., 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005b. p.3997-4004. 1 CD-ROM.

BOLCH, T. & KAMP, U. Quality analyses of digital ASTER elevation models of high mountain areas (Cerro Sillajhuay, Chile/Bolivia). **Kartographische Nachrichten**, v.5, p.224-230, 2003.

BOLSTAD, P. V. & STOWE, T. An evaluation of DEM accuracy - elevation, slope, and aspect. **Photogrammetric Engineering and Remote Sensing**, v.60, p.1327-1332, 1994.

BROWN, D. G. & BARA, T. J. Recognition and reduction of systematic error in elevation and derivative surfaces from 7.5 minute DEMs. **Photogrammetric Engineering and Remote Sensing**, v.60, p.189- 194, 1994.

BURROUGH, P. **Principles of geographical information systems for land resources assessment**. New York: Oxford University Press, 1986. 194p.

CARRARA, A.; BITELLI, G. & CARLA, R. Comparison of techniques for generating digital terrain models from contour lines. **International Journal of Geographical Information Science**, v.11, p.451-473, 1997.

CREPANI, E. & MEDEIROS, J. S. **Imagens fotográficas derivadas de MNT do projeto SRTM para fotointerpretação na geologia, geomorfologia e pedologia**. São José dos Campos: INPE, 2004. 40p. (INPE-11238-RPQ/761)

CUARTERO, A.; FELICÍSIMO, A. M. & ARIZA, F. J. Accuracy of DEM generation from Terra-Aster stereo data. **International Archives of Photogrammetry and Remote Sensing**, v.35, p.225-260, 2004.

DANTAS, M. E. **Geomorfologia do Estado do Rio de Janeiro**. Brasília: CPRM, 2000. 1CD-ROM.

DAY, T. & MULLER, J. P. Digital elevation model production by stereo-matching SPOT image-pairs: A comparison of algorithms. **Image and Vision Computing**, v.7, p.95-101, 1989.

DIXON, T. H. **SAR Interferometry and Surface Change Detection**. University of Miami, Rosenstiel School of Marine and Atmospheric Sciences, RASMAS TR 95-003, 1995.

DOBOS, E. et al. Use of combined digital elevation model and satellite radiometric data for regional soil mapping. **Geoderma**, v.97, p.367-391, 2000.

DRUZINA, A. G. S. et al. Estudo do erro de modelos digitais de elevação gerados a partir de imagens aster utilizando técnicas de processamento digital de imagens. CONGRESSO BRASILEIRO DE CARTOGRAFIA, SIMPÓSIO DE GEOTECNOLOGIAS PARA PETRÓLEO E XXI EXPOSICARTA, 22., Macaé. **Anais...**Macaé: Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto, 2005. 1CD-ROM.

ECKERT, S. & KELLENBERGER, T. Quality analysis of automatic generated DEMs from ASTER-Data. **Publikationen der Deutschen Gesellschaft für Photogrammetrie und Fernerkundung**, v.11, p.337-345, 2002.

ENVIRONMENTAL SYSTEM RESEARCH INSTITUTE - ESRI. **ARC/INFO v. 7.1.1. Redlands**, 1997. Programa de computador. 2 CD-ROM.

FALORNI, G. et al. Analysis, characterization and effects on hydrogeomorphic modeling of the vertical accuracy of Shuttle Radar Topography Mission digital elevation models. **Journal of Geophysical Research - Earth Surface**, 110(F2):F02005. doi: 10.1029/2003JF000113, 2005.

FARR, T.G. et al. The shuttle radar topography mission. In: CEOS SAR Workshop, 1999, Toulouse. **Proceedings...** Toulouse: ESA/CNES, 2000. p.361-363.

FELICÍSIMO, A. M. **Modelos digitais del terreno**: introducción aplicaciones en las ciencias ambientales. Oviedo: Universidad de Oviedo, 1994a. Disponível em: <<http://www.etsimo.uniovi.es/~feli>>. Acesso em: 07 de nov. 2005.

FELICÍSIMO, A. M. Parametric statistical method for error detection in digital elevation models. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.49, p.29-33, 1994b.

FERNANDES, M. C. & MENEZES, P. M. L. Comparação entre métodos para geração de MDE para a obtenção de observações em superfície real no maciço da Tijuca - RJ. **Revista Brasileira de Cartografia**, v.57, p.154-161, 2005.

FRYER, J. G.; CHANDLER, J. H. & COOPER, M. A. R. Short communication on the accuracy of heighting from aerial photographs and maps: Implications to process modellers. **Earth Surface Processes Landforms**, v.19, p.577-583, 1994.

GERSTENECKER, C. et al. Validation of digital elevation models around Merapi Volcano, Java, Indonesia. **Natural Hazards and Earth System Sciences**, v.5, p.863-876, 2005.

GLEYZES, J. P.; MEYGRET, A.; FRATTER, C.; PANEM, C.; BAILLARIN, S. & VALORGE, C. SPOT5: System overview and image ground segment. IGARSS 2003, Toulouse, France. **Proceedings...** Toulouse, 2003. 1CD-ROM.

HENGL, T.; GRUBER, S. & SHRESTHA, D. P. Reduction of errors in digital terrain parameters used in soil-landscape modelling. **International Journal of Applied Earth Observation and Geoinformation**, v.5, p.97-112, 2004.

HIRANO, A.; WELCH, R. & LANG, H. Mapping from ASTER stereo image data: DEM validation and accuracy assessment. **ISPRS Journal of Photogrammetry & Remote Sensing**, v.57, p.356-370, 2003.

HOLMES, K. W.; CHADWICK, O. A. & KYRIAKIDIS, P. C. Error in a USGS 30-meter digital elevation model and its impact on terrain modeling. **Journal of Hydrology**, v.233, p.154-173, 2000.

HUNTER, G. J. & GOODCHILD, M. F. Modeling the uncertainty of slope and aspect estimates derived from spatial databases. **Geographical Analysis**, v.29, p.35-49, 1997.

HUTCHINSON, M. F. & GALLANT, J. C. Digital elevation models and representation of terrain shape. In: WILSON, J. P. & GALLANT, J. C. (Eds.). **Terrain analysis: principles and applications**. New York: John Wiley & Sons, 2000. p.29-50.

HUTCHINSON, M. F. Development of a continent-wide DEM with applications to terrain and climate analysis. In: GOODCHILD, M. F. (Ed.). **Environmental Modeling with GIS**. New York: Oxford University Press, 1993. p.392-399.

JARVIS, A. et al. **Practical use of SRTM data in the tropics: comparisons with digital elevation models generated from cartographic data**. Cali, CO: Centro Internacional de Agricultura Tropical (CIAT), 2004. 32p. (Working document no. 198).

KÄÄB, A. et al. Glacier monitoring from ASTER imagery: accuracy and applications. In: **EARSel-LISSIG - Workshop Observing our Cryosphere from Space, 2.**, 2002, Bern. **Proceedings...** Bern: EARSel, 2002. p.43-53.

KAMP, U.; BOLCH, T. & OLSENHOLLER, J. DEM generation from ASTER satellite data for geomorphometric analysis of Cerro Sillajhuay, Chile/Bolivia. In: Annual Meeting Imaging and Geospatial Information Society (ASPRS), 2003, Anchorage, USA. Proceedings... Anchorage: ASPRS, 2003. Disponível em: <[http://www.pcigeomatics.com/services/support\\_center/tech\\_papers/dem\\_aster.pdf](http://www.pcigeomatics.com/services/support_center/tech_papers/dem_aster.pdf)>. Acesso em: 20 jan. 2006.

KAUFMAN, Y. J et al. Earth Observing System AMI Mission to Earth. **IEEE Transactions on Geoscience and Remote Sensing**, v.36, p.1045-1055, 1998.

KOCAK, G.; BÜYÜKSALIH, G. & JACOBSEN, K. Analysis of digital elevation models determined by high resolution space images. **International Archives of Photogrammetry and Remote Sensing**, v.35, p.636-641, 2004.

KOCH, A.; HEIPKE, C. & LOHMANN, P. Analysis of SRTM DTM - methodology and practical results. **International Archives of Photogrammetry and Remote Sensing**, v.34, p.470-475, 2002.

KOK, A. L.; BLAIS, J. A. R. & RANGAYYAN, R. M. Filtering of digitally correlated Gestalt elevation data. **Photogrammetric Engineering and Remote Sensing**, v.53, p.535-538, 1987.

LANG, H. & WELCH, R. **Algorithm theoretical basis document for ASTER digital elevation models, version 3.0**. Pasadena, CA: Jet Propulsion Laboratory, 1999. 69p.

LOPEZ, C. Locating some types of random errors in Digital Terrain Models. **International Journal of Geographical Information Science**, v.11, p.677-698, 1997.

NAMIKAWA, L. M. A method for triangular grid surface fitting using breaklines. **International Archives of Photogrammetry and Remote Sensing**, v.30, p.362-368, 1994.

NONIN, P. Performance analysis of DEM automatic extraction from SPOT 5 sensors. IGARSS 2003, Toulouse, France. **Proceedings...** Toulouse, 2003. 1CD-ROM.

POLI, D.; REMONDINO, F. & DOLCI, C. Use of satellite imagery for DEM extraction, landscape modeling and GIS applications. In: International Workshop on Processing and Visualization Using High-Resolution Imagery, 2004, Pitsanulok, Thailand. Proceedings... Pitsanulok: ISPRS, 2004. Disponível em: <[http://www.photogrammetry.ethz.ch/pitsanulok\\_workshop/papers/24.pdf](http://www.photogrammetry.ethz.ch/pitsanulok_workshop/papers/24.pdf)>. Acesso em: 20 jan. 2006.

RIBEIRO, C. A. S. **Apostila de curso ENF613**. Viçosa, MG: UFV, 2003. 22p.

RUDOWSKI, V. Altimetric restitution assessment of Spot 5 stereo pairs. IGARSS 2003, Toulouse, France. **Proceedings...** Toulouse, 2003. 1CD-ROM.

SANTOS, P. R. A.; GABOARDI, C. & OLIVEIRA, L. C. Avaliação da precisão vertical dos modelos SRTM em diferentes escalas: um estudo de caso na Amazônia. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, SIMPÓSIO DE GEOTECNOLOGIAS PARA PETRÓLEO E XXI EXPOCART, 22., 2005, Macaé. **Anais...** Macaé: Sociedade Brasileira de Cartografia, Geodésia, Fotogrametria e Sensoriamento Remoto, 2005. 1CD-ROM.

SAUNDERS, W. Preparation of DEMs for use in environmental modeling analysis. **ESRI International User Conference Proceedings**. San Diego, California: ESRI, July 26-30, 1999.

SUBRAMANIAN, K. S. S.; SINGH, A. & SUDHAKAR, M. **Evaluation of digital elevation models created from different satellite images**. 2005. Disponível em: <<http://www.gisdevelopment.net/technology/rs/mi03079pf.htm>>. Acesso em: nov. 2005.

TEMPFLI, K. Spectral analysis of terrain relief for the accuracy estimation of digital terrain models. **ITC Journal**, v.3, 478-510, 1980.

TOUTIN, T & GRAY, L. State-of-the-art of elevation extraction from satellite SAR data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.55, p.13-33, 2000.

UNITED STATES GEOLOGICAL SURVEY - USGS. **Shuttle Radar Topography Mission (SRTM)**. 2005. Disponível em: <<http://edc.usgs.gov/products/elevation/srtm>>. Acesso em: nov. 2005.

WECHSLER, S. P. Digital Elevation Model (DEM) uncertainty: evaluation and effect on topographic parameters. **ESRI International User Conference Proceedings**. San Diego, California: ESRI, July 26-30, 1999.

WILSON, J. P. & GALLANT, J. C. Digital terrain analysis. In: WILSON, J. P. & GALLANT, J. C. (eds.). **Terrain analysis: principles and applications**. New York: John Wiley & Sons, 2000. p.4-27.

WISE S. The Effect of GIS Interpolation Errors on the Use of Digital Elevation Models in Geomorphology. In: LANE, S. N.; RICHARDS, K. S. & CHANDLER, J. H. (Eds.) **Landform Monitoring, Modelling and Analysis**. New York: John Wiley and Sons, 1998. 300p.

WISE, S. Assessing the quality for hydrological applications of digital elevation models derived from contours. **Hydrological processes**, v.14, p.1909-1929, 2000.

WOOD, J. **The geomorphological characterization of digital elevation models**. 1996. 185f. (PhD thesis) - University of Leicester, Leicester, UK, 1996.

YAMAGUCHI, Y. et al. ASTER early image evaluation. **Advanced Space Research**, v.28, p.69-76, 2001.

YAMAGUCHI, Y. et al. Overview of advanced spaceborne thermal emission and reflection radiometer (ASTER). **IEEE Transactions on Geoscience and Remote Sensing**, v.36, p.1062-1071, 1998.

ZOCOLOTTI FILHO, C. A. & CENTENO, J. A. S. Análise da qualidade de informações altimétricas geradas pelo sistema ASTER. In: SIMPÓSIO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO - SIMGEO, 1., 2004, Recife. **Anais...** Recife: SIMGEO, 2004. v. 1, p.1-10.

## **CAPÍTULO 3**

### **RELAÇÕES GEOMORFOPEDOLÓGICAS EM UMA REGIÃO DO DOMÍNIO DE MAR DE MORROS E ALINHAMENTOS SERRANOS NO NOROESTE DO ESTADO DO RIO DE JANEIRO.**

#### **RESUMO**

O presente estudo teve como objetivo avaliar as relações existentes entre material de origem e atributos do terreno derivados de um modelo digital de elevação (MDE) na distribuição dos solos na bacia do rio São Domingos (BHSD), Noroeste do Estado do Rio de Janeiro. A partir de um modelo solo-paisagem preliminar, utilizado para estabelecer as interações entre os diferentes fatores de formação do solo e, com base na geologia e nos atributos geomorfológicos, foi desenvolvido um esquema de amostragem dos solos para definir e confirmar a natureza das relações geomorfopedológicas existentes. Dentre os atributos morfométricos avaliados, elevação, declividade, aspecto e plano de curvatura são os que mais influenciam a distribuição dos solos na área, e a sua utilização facilitou a identificação das diferentes interações que ocorrem na BHSD. A mudança textural abrupta, que está presente nos solos derivados dos migmatitos e milonitos gnaisses e ausente nos desenvolvidos dos granulitos ricos em máficos (granulitos noríticos), é a diferença mais marcante entre os solos originados destas rochas. Diferenças no grau de evolução dos solos são condicionadas pela curvatura do terreno, com áreas côncavas apresentando solos pouco evoluídos e solos evoluídos com caráter câmbico e as convexas apresentando solos mais evoluídos (B textural, B nítico e/ou B latossólico). Variações microclimáticas determinadas pela orientação das encostas foram importantes na diferenciação dos solos das encostas convexas, independente do tipo de material de origem. Assim, os solos derivados dos granulitos noríticos, que ocorrem nas encostas noroeste e nordeste (vermelhos) e sudoeste (vermelho-amarelos), que são mais quentes e secas, são eutróficos e sem horizonte B latossólico em profundidade (Argissolo típico), enquanto os das encostas voltadas para sudeste (relativamente mais frias e úmidas) são vermelho-amarelados, distróficos e com horizonte B latossólico em profundidade (Argissolo latossólico). Nos solos derivados dos migmatitos e milonitos gnaisses, a única diferença encontrada foi a



presença de horizonte Bw abaixo do Bt nas encostas voltadas para sudeste (Argissolo abrupto latossólico). A curvatura do terreno e a orientação da encosta não tiveram influência na diferenciação dos solos em áreas de relevo ondulado e suave ondulado, sendo a profundidade de ocorrência da rocha o principal fator responsável pelas diferenças, tanto nos granulitos quanto nos migmatitos e milonitos gnaisses. Nos sedimentos do Quaternário foram identificados Gleissolos e Cambissolos gleicos, ambos de argila de atividade alta ou baixa.

**Palavras-chave:** relações geomorfopedológicas.

## SUMMARY

The objective of the present study was to evaluate the relationships between parent material and terrain attributes, derived from a digital elevation model (DEM), in the soil distribution in São Domingos watershed (BHSD), northwest of Rio de Janeiro state. From a preliminary soil-landscape model, used to establish the interactions between the different soil formation factors, associated with the geological and geomorphological attributes a scheme of soil sampling was designed to define the nature of geomorphopedological relationships. Among the evaluated attributes, elevation, slope, aspect and plan curvature were those which had a greater influence on soil distribution, facilitating the identification of the different environmental interactions that occur in the BHSD. The abrupt textural change, as observed in soils derived from migmatites and milonites gneisses, is not found in the soils developed from mafic minerals (noritic granulites), being the main difference between the soils originated from these parent material. Differences in the degree of soil development are related to terrain curvature, in which concave areas present shallower soils, whereas convex slopes show more developed soils (argillic and oxic B horizon). Microclimatic variations associated with the aspect were important in soil differentiation of convex areas, regardless of the type of parent material. Thus, soils derived from noritic granulites, that occur in the facing northwest and northeast (red) and southwest (red-yellow), usually hotter and dryer, are eutrophic and without Bw horizon with depth (typical Argisols), while the Southeast facing slopes, relatively colder and wetter, are red-yellowish, dystrophic and with Bw horizons with depth (oxic Argisols). In soils derived from migmatites and milonites gneisses, the difference is basically the presence of a Bw horizon below the Bt, in Southeast facing slopes (abruptic oxic Argisols). The terrain curvature, the aspect or the slope did not influence the soils differentiation in areas between 3% to 20% of declivity, in which cases the parent material depth was the main factor accounting for the differences, in both granulites and migmatites and milonites gneisses. Quaternary sediments were totally associated with Gleisols and Cambisols, with either high or low activity clay.

**Keywords:** geomorphopedologic relationships

## 1. INTRODUÇÃO

As interações complexas entre os diferentes fatores de formação dos solos ocorrem em padrões repetitivos, levando à formação de combinações que são a base para definição, identificação e mapeamento de solos. O mapeamento na maioria dos levantamentos envolve o delineamento de segmentos da paisagem, o recorte de áreas geográficas e colocação de limites nos mapas-base. Neste processo, o conhecimento das características da paisagem tem importância fundamental, pois através do estudo dos padrões em imagens obtidas de sensores (normalmente fotografias aéreas), aliado com observações de campo e análises de laboratório, é possível conhecer as relações existentes entre os solos e os padrões obtidos nestas imagens, permitindo assim, traçar de maneira mais precisa e rápida os limites entre os solos de uma área, sem a necessidade de observação de toda a superfície do terreno (Estados Unidos, 1993).

O conhecimento dos processos geomorfológicos é de grande importância para o mapeamento de solos. Estes se baseiam em métodos geológicos e conceitos de superfícies geomórficas para entender as relações existentes entre os solos e os vários constituintes da paisagem. As superfícies geomórficas podem identificar elementos da paisagem e podem estabelecer como as diferentes formas do terreno e seus materiais se inter-relacionam (Estados Unidos, 1993). Gerrard (1981) destaca que o conhecimento dos processos geomorfológicos é fundamental para o entendimento da origem e desenvolvimento do sistema solo-paisagem em questão, enquanto as interações existentes entre os processos geomorfológicos e pedológicos são importantes para explicar como o sistema funciona.

No mapeamento de solos tradicional, os pedólogos primeiramente estabelecem as relações que ocorrem entre os solos e as diferentes unidades (modelo solo-paisagem) de uma determinada área por meio de investigações de campo, e depois traçam manualmente a distribuição espacial dos diferentes solos ou combinações de solos através da fotointerpretação. Esta abordagem qualitativa da paisagem, através da análise fisiográfica e/ou interpretação de fotografias aéreas tem sido bastante criticada, entre outras coisas, 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).

A crescente preocupação ambiental, nos últimos 30 anos, vem fazendo com que este caráter qualitativo dê lugar a uma abordagem mais quantitativa. Neste sentido, segundo Odeh et al. (1991), a análise digital do terreno apresenta algumas vantagens em relação ao método tradicional para a identificação de unidades, por ser uma alternativa rápida e econômica, que pode ser empregada para quantificar e classificar as formas do terreno, de maneira automática ou semi-automática.

Os modelos solo-paisagem mais quantitativos estão se tornando conhecidos como novo paradigma para o levantamento de solos, bem como para o entendimento e predição dos padrões naturais do solo e já fazem parte das novas tendências dos levantamentos (Hudson, 1992). Estes modelos estão sendo combinados com bancos de dados e sistemas de informações geográficas para predição da distribuição espacial e variação das propriedades dos solos (Petersen et al., 1991).

Para Moore et al. (1993), os levantamentos de solos podem ser melhorados através da utilização de atributos do terreno derivados de modelos digitais de elevação (MDE), fornecendo, assim, um método para geração de mapas de alta resolução, os quais são potencialmente importantes, pois possibilitam a identificação de aspectos da superfície do terreno que são difíceis de serem notados na interpretação de fotografias aéreas tradicionais (Klingebiel et al., 1987). Assim, o MDE pode ser manipulado para fornecer muitos tipos de dados que podem auxiliar o mapeamento de solos e a determinação da descrição quantitativa das formas do terreno e da variabilidade dos solos. Junto com informações sobre a geologia, o MDE pode ser empregado para predizer os tipos de solos.

Segundo Klingebiel et al. (1987), os atributos do terreno estão diretamente relacionados com os processos de formação do solo e possuem um grande potencial para serem utilizados na elaboração de levantamentos de solos. Estes podem ser divididos em atributos primários ou secundários (compostos). Os atributos primários são diretamente calculados a partir do MDE e incluem variáveis como elevação, declividade, orientação, plano e perfil de curvatura, comprimento do caminho do fluxo e área específica de contribuição (Moore et al., 1993). Dentre estes, elevação, declividade

e orientação, têm sido reconhecidos como os mais efetivos para a realização de levantamentos de solos de média escala (extensivos). Estes atributos são especialmente importantes em áreas de vegetação densa, onde mudanças na declividade são dificilmente percebidas, e em terrenos movimentados, onde a orientação e a elevação freqüentemente influenciam o tipo de solo e da vegetação.

Os atributos do terreno têm sido muito usados para predição das características dos solos (Moore et al., 1993; Bell et al., 1994; Gessler et al., 1995; Chaplot et al., 1998; Florinsky & Kuryakova, 1998). Um dos primeiros estudos a utilizar atributos ambientais para a predição do solo foi realizado por Troeh (1964), que analisou dados de elevação de duas catenas para derivar a declividade e perfil de curvatura. A partir destas informações ele observou que as classes de drenagem do solo poderiam ser estimadas através de uma equação. Walker et al. (1968) utilizaram a declividade, curvatura, aspecto e distância do topo, em combinação com regressão linear múltipla para predizer propriedades morfológicas do solo tais como: profundidade do horizonte A, profundidade do mosqueado e de carbonatos ao longo de um transecto.

O desenvolvimento do solo em muitas situações ocorre em resposta ao modo pelo qual a água se move através e sobre a paisagem. Os atributos do terreno podem caracterizar os caminhos do fluxo e as interações com os atributos do solo. Moore et al. (1993) realizaram um dos primeiros estudos utilizando um conjunto de atributos do terreno derivados de um MDE em um grid de 15m para predizer propriedades contínuas do solo, como espessura do horizonte A e pH para uma pequena bacia no Colorado. Neste estudo, os autores encontraram uma correlação significativa entre atributos do terreno quantificados e atributos do solo medidos. Declividade e índice de umidade foram os atributos mais altamente correlacionados com os atributos do solo, contribuindo para explicar aproximadamente metade da variabilidade na espessura do horizonte A, teor de matéria orgânica, pH, fósforo extraível e teores de silte e areia.

Gessler et al. (1995) desenvolveram um modelo solo-paisagem estatístico para predizer atributos dos solos, utilizando diferentes atributos do terreno, tais como: plano de curvatura e índice topográfico combinado para estimar a profundidade do horizonte A, profundidade do solum e a ausência ou presença de horizonte E em uma área com geologia e história geológica uniforme.


Dikau (1989) demonstrou como a análise digital do terreno poderia ser aplicada

## 2. MATERIAL E MÉTODOS

### 2.1. Caracterização da Área Estudada

O presente estudo foi desenvolvido na bacia hidrográfica do rio São Domingos, localizada conforme descrito no item 2.1 do Capítulo 2.

De acordo com a classificação climática de Köppen, a bacia do rio São Domingos apresenta clima do tipo Aw, ou seja, clima tropical, com inverno seco, apresentando estação chuvosa no verão, de novembro a abril, e nítida estação seca no inverno, de maio a outubro (julho é o mês mais seco). A temperatura média do mês mais frio é superior a 18°C e as precipitações são superiores a 750 mm anuais, atingindo 1800 mm. Segundo a classificação de Thornthwaite, a região enquadra-se na tipologia C1dA´a´, ou seja, clima subúmido a seco, pequeno excedente hídrico, megatérmico (EP > 1140 mm), chuvas de primavera/verão. O balanço hídrico de acordo com o método de Thornthwaite & Matter, para o município de Itaperuna, considerando-se a capacidade de armazenamento de água no solo (para fins climatológicos) de 100 mm, é mostrado na Figura 1.



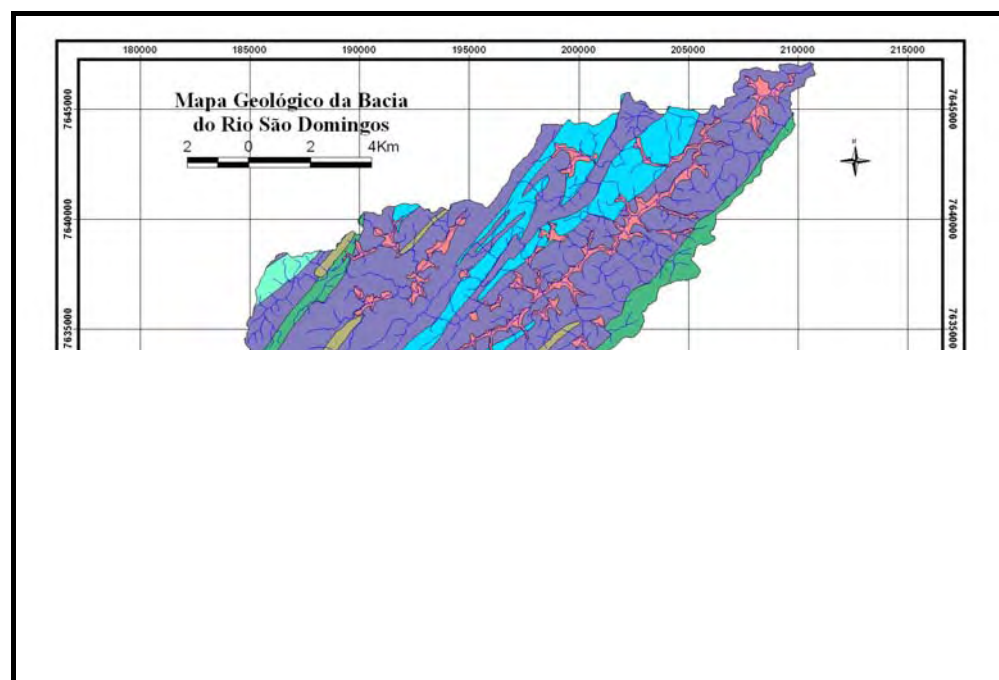
Fonte: INMET (2004).

**FIGURA 1. Balanço hídrico para o município de Itaperuna.**

A geologia da área é constituída por rochas metamórficas de alto grau. De acordo com o levantamento geológico das Folhas Miracema e São João do Paraíso, na escala de 1:50.000 (DRM, 1980), são identificadas na área da bacia (Figura 2) as seguintes unidades geológicas: Unidade Macuco (0,3%), Unidade Catalunha (2%),

Unidade São João do Paraíso (11%), Unidade Vista Alegre (16,7%), Unidade Santo Eduardo (1%), Unidade São José de Ubá (60%) e Sedimentos Aluvionares do Quaternário (9%).

Os granulitos noríticos da Unidade São José de Ubá apresentam coloração marrom acinzentada escura, são maciços e de granulação fina. Apresentam mineralogia composta basicamente por feldspatos potássicos, plagioclásios e quartzo, tendo como minerais menores piroxênio, biotita, granada, hornblenda, apatita, zircão e magnetita, entre outros (DRM, 1980).



Fonte: Adaptado de DRM (1980).

**FIGURA 2. Mapa geológico da bacia do rio São Domingos.**

A Unidade Vista Alegre ocorre de forma mais expressiva ao longo de todo o limite leste da bacia, associada à área dos Alinhamentos Serranos e Degraus Estruturais. Os migmatitos desta unidade formam uma complexa associação com metamorfitos, sendo extremamente heterogêneos, e são representados, principalmente, por granada - biotita - ortoclásio e microclina - plagioclásio - gnaisses.

A Unidade São João do Paraíso ocorre na forma de corpos alongados, na direção NE-SW. Os migmatitos desta unidade apresentam basicamente uma coloração cinza-azulada, exibindo uma estrutura dobrada, flebítica e estromática, e são constituídos de




granada - hornblenda - biotita - plagioclásio - microclina gnaisses e granada - biotita - plagioclásio - microclina gnaisses, geralmente porfiroblásticos, além de leptinitos.

Os migmatitos metatexíticos heterogêneos da Unidade Catalunha se apresentam caracteristicamente com silimanita e granada - sill - granada - biotita - cordierita - ortoclásio - plagioclásio - quartzo gnaisses (гнаisses kinzigíticos), coloração cinza arroxeada a amarelada, bem foliados, ou mesmo laminados, de granulação fina a média, equigranulares a porfiroblásticos.

A Unidade Santo Eduardo ocorre isolada no limite noroeste da bacia e é composta por milonito gnaiss e blastomilonito predominantes, geralmente bandeados, porfiroclásticos e porfiroblásticos, portando intercalações de variada litologia além de intercalações de anfibólio - biotita gnaiss migmatizado, interestratificado com quartzo xisto.

A notável diversificação do cenário geomorfológico do Estado do Rio de Janeiro deve ser compreendida através de uma singular interação entre aspectos tectônicos e climáticos, que delinearão sua atual morfologia. De acordo com o mapa geomorfológico do Estado do Rio de Janeiro, a bacia do rio São Domingos está inserida na unidade morfoestrutural Cinturão Orogênico do Atlântico. Essa unidade morfoestrutural compreende um conjunto diversificado de rochas metamórficas e ígneas de idade pré-cambriana a eopaleozóica. Por sua vez, esta unidade morfoestrutural é representada pela unidade morfoescultural Depressões Interplanálticas com Alinhamentos Serranos Escalonados, que representa os terrenos colinosos de baixa amplitude de relevo em alternância com alinhamentos de cristas serranas de elevada amplitude ao longo do interior do Estado do Rio de Janeiro (Dantas, 2000).

A Depressão Interplanáltica com Alinhamentos Serranos do Norte-Noroeste Fluminense constitui a principal unidade geomorfológica da bacia do rio São Domingos e está subdividida em três sistemas de relevo: Domínio Colinoso, Domínio de Colinas Dissecadas, Morrotes e Morros baixos e Alinhamentos Serranos e Degraus Estruturais (Figura 3).



Fonte: Adaptado de Dantas (2000).

**FIGURA 3. Sistemas de relevo da bacia do rio São Domingos.**

## **2.2. Modelo Solo-Paisagem**

Inicialmente, foi desenvolvido um modelo provisório com o objetivo de estabelecer como os diferentes fatores de formação do solo estão interagindo na área estudada, de modo a possibilitar a identificação das variáveis ambientais que influenciam a distribuição dos solos na paisagem. Este modelo é fundamentado na equação dos fatores de formação do solo, proposta por Jenny (1941) e no modelo solo-paisagem descrito por Hudson (1992), ambos largamente utilizados nos levantamentos de solos convencionais.

De acordo com McSweeney et al. (1994), os dados sobre os fatores de formação dos solos podem ser derivados usando técnicas de SIG. Deste modo, inicialmente foram selecionadas algumas variáveis ambientais passíveis de serem utilizadas para caracterizar as relações solo-paisagem na bacia do rio São Domingos (Tabela 1).

**TABELA 1. Variáveis ambientais inicialmente consideradas para auxiliar na predição da distribuição das classes de solos na bacia do rio São Domingos.**

<b>Fator de Formação</b>	<b>Variável Ambiental</b>	<b>Significância</b>
<b>Organismos (o)</b>	Tipo de cobertura vegetal e índices de vegetação obtidos a partir da análise de imagens de sensores remotos	Vegetação e regime de umidade do solo.
<b>Relevo (r)</b>	Elevação Declividade Orientação da encosta Plano de curvatura Perfil de curvatura Índice topográfico combinado (CTI) Radiação solar	Taxa intemperismo/erosão, variações climáticas, volume de escoamento superficial, teor de água no solo, características dos solos, etc.
<b>Material de Origem (p)</b>	Unidades Litológicas	Produtos do intemperismo, incluindo mineralogia e tamanho de partículas.

Fonte: adaptado de McKenzie & Ryan (1999).

De posse do levantamento geológico e das variáveis morfométricas obtidas a partir do MDE da bacia, auxiliadas por dados de perfis de solos coletados por outros projetos (projeto RADEMA, projeto CTHIDRO, projeto Carbono/FAPERJ e projeto Aquíferos), percorreu-se toda a área fazendo-se observações com o objetivo de selecionar aquelas variáveis que estavam diretamente relacionadas com a distribuição dos solos na bacia.

A análise dos dados mostrou que, dentre as variáveis inicialmente consideradas, as mais significativas para os objetivos do estudo foram: a geologia, elevação, declividade, orientação e a curvatura (especialmente o plano de curvatura). A partir de então, foi desenvolvido um esquema de amostragem dos solos para definir e confirmar a natureza das relações solo-paisagem. Assim, utilizou-se um esquema estratificado em dois estágios, tal como proposto por Brus & De Grujter (1997) e utilizado por McKenzie & Ryan (1999), tendo como variáveis ambientais estratificadoras a geologia, elevação, declividade, orientação da encosta e a curvatura, definidas com base no modelo pedogenético da área.

Neste esquema, a geologia foi utilizada como primeiro nível de estratificação. Em um segundo nível, a elevação, a declividade, a orientação das encostas e a curvatura do terreno foram combinadas para gerar a estratificação digital da área. Neste procedimento os ambientes que apresentaram pouca expressividade de área foram

eliminados e aqueles que apresentaram comportamento semelhante com relação ao tipo de solo foram fundidos.


### **2.3. Atributos Topográficos**

O MDE CARTA, definido na avaliação realizada no Capítulo 2 como o de melhor qualidade entre os MDEs, foi utilizado para derivar os atributos topográficos que, juntamente com a geologia, foram usados no estudo das relações geomorfopedológicas da bacia do rio São Domingos. Os atributos topográficos foram os seguintes: elevação, declividade, orientação da encosta, curvatura, perfil de curvatura, plano de curvatura e índice topográfico combinado (CTI), obtidos com o auxílio do software ArcGIS Desktop 9.0, e a radiação solar utilizando a extensão Solar Analyst 1.0 (Fu & Rich, 1999; HEMI, 2000) no software ArcView GIS.

A extensão Solar Analyst foi usada para computar a radiação global, para cada pixel do MDE dentro da bacia do rio São Domingos, conforme HEMI (2000). Este programa calcula a insolação potencial como uma função da latitude, declividade, orientação da encosta, sombreamento topográfico, mudanças diárias e sazonais no ângulo solar e atenuação atmosférica (Wilson & Gallant, 2000; HEMI, 2000).

### **2.4. Amostragem e Caracterização Analítica**

Inicialmente, foram utilizados os perfis de solo descritos nos levantamentos semidetalhados de duas microbacias representativas das condições gerais da bacia do rio São Domingos: a microbacia Santa Maria/Cambiocó e a microbacia Barro Branco. Além destes, foram ainda coletadas amostras suplementares em áreas importantes identificadas fora das microbacias, e utilizados os perfis coletados por outros projetos desenvolvidos na bacia, conforme Figura 4. Todos os locais foram georreferenciados utilizando-se um receptor GPS. Ao final do processo todos os sítios identificados foram contemplados com pelo menos duas observações (perfil completo e/ou amostra extra e/ou observação sem coleta de amostra), totalizando 138 observações de campo, sendo 72 perfis completos, 10 amostras extras e 56 observações sem coleta de amostras.



**FIGURA 4. Localização dos perfis e observações de campo realizadas para estabelecer a relação solo-paisagem na bacia do rio São Domingos.**

As amostras de solos coletadas foram analisadas no laboratório de solos da Embrapa Solos. Para a execução das análises, estas foram secas ao ar e passadas em peneira com malha de 2 mm, para obtenção da terra fina seca ao ar.

As análises efetuadas foram as seguintes: a composição granulométrica foi determinada utilizando-se NaOH como dispersante químico, agitação de alta rotação e sedimentação; a fração argila foi determinada por densimetria no sobrenadante, areia grossa e areia fina separadas por tamisação e silte calculado por diferença (Embrapa, 1997). Para a determinação da argila dispersa em água (ADA) foi empregada a mesma metodologia, porém sem fazer-se uso do dispersante químico. A densidade do solo ( $D_s$ ) foi determinada em amostras coletadas com anéis de Kopeck de volume conhecido (50ml), segundo método descrito por Blake & Hartge (1986), e a densidade de partículas ( $D_p$ ) determinada pelo método do balão volumétrico, utilizando álcool etílico (Embrapa, 1997).

Os valores de pH em  $H_2O$  e em KCl 1N foram medidos por eletrodo de vidro em suspensão solo- $H_2O$  ou solo-KCl na proporção solo-liquído de 1:2,5 (v/v). As bases trocáveis  $Ca^{2+}$  e  $Mg^{2+}$  foram extraídas com KCl 1N e tituladas por EDTA, e  $K^+$  e  $Na^+$

extraídos com HCl 0,05 N + H<sub>2</sub>SO<sub>4</sub> 0,025 N e determinadas por fotometria de chama (Embrapa, 1997). A acidez foi extraída com KCl 1N e titulada por NaOH 0,025 N com azul-bromotimol como indicador, sendo expressa como Al<sup>3+</sup> trocável. H<sup>+</sup> e Al<sup>3+</sup> extraídos com Ca(OAc)<sub>2</sub> 1N pH 7,0 e acidez titulada por NaOH 0,0606 N com fenolftaleína como indicador e H<sup>+</sup> calculado por diferença (Embrapa, 1997). O fósforo assimilável foi extraído com HCl 0,05 N + H<sub>2</sub>SO<sub>4</sub> 0,025 N e determinado por colorimetria. O carbono orgânico foi obtido por oxidação via úmida com K<sub>2</sub>Cr<sub>2</sub>O<sub>7</sub> 0,4 N e titulação pelo Fe(NH<sub>4</sub>)<sub>2</sub>(SO<sub>4</sub>)<sub>2</sub>.6H<sub>2</sub>O 0,1 N com difenilamina como indicador. O nitrogênio total (Kjeldahl) foi obtido por digestão com mistura ácida, difusão e titulação de NH<sub>3</sub> com HCl ou H<sub>2</sub>SO<sub>4</sub> 0,01 N (Embrapa, 1997).

Os óxidos do ataque sulfúrico foram obtidos por meio de tratamento por fervura da terra fina com solução de H<sub>2</sub>SO<sub>4</sub> 1:1 (v/v). No filtrado, ferro e alumínio foram extraídos e determinados complexometricamente por titulação e expressos na forma de Fe<sub>2</sub>O<sub>3</sub> e Al<sub>2</sub>O<sub>3</sub>; também no filtrado, titânio, manganês e fósforo foram determinados colorimetricamente por titulação e expressos na forma de TiO<sub>2</sub>, MnO e P<sub>2</sub>O<sub>5</sub>; no resíduo do ataque sulfúrico foi extraída a sílica com NaOH 0,8, determinada colorimetricamente e expressa na forma de SiO<sub>2</sub> (Embrapa, 1997). Finalizando, os solos foram classificados de acordo com o Sistema Brasileiro de Classificação de Solos até o 4º nível categórico (Embrapa, 1999).

### **3. RESULTADOS E DISCUSSÃO**

#### **3.1. Atributos Topográficos**

A distribuição espacial dos principais atributos topográficos utilizados é mostrada na Figura 5, enquanto que na Figura 6 está sumarizada a estatística de cada um. Os valores de elevação na bacia do rio São Domingos variam de aproximadamente 69 a 912 m, com uma média de 212,45 m. As áreas de menor altitude estão localizadas próximas ao encontro do rio São Domingos com o rio Muriaé e as áreas mais elevadas localizam-se nos extremos sul e sudoeste da bacia, conforme mostra a Figura 5.

Embora apresente grande variação altimétrica, 84,12% da área da bacia apresentam altitudes inferiores a 300 m. Estas áreas estão associadas em sua maior parte ao Domínio Colinoso de Mar de Morros, caracterizado por apresentar colinas com amplitude topográfica inferior a 100 m, com vertentes convexo-côncavas de gradiente suave e geometria dos topos alongada ou arredondada; e, em menor parte, ao Domínio de Colinas Dissecadas, Morrotes e Morros Baixos, que por sua vez, apresentam colinas, morrotes e morros baixos caracterizados pela amplitude de relevo entre 100 e 200 m, com vertentes convexo-côncavas ou retilíneas a côncavas, de gradiente suave a médio e topos alongados, arredondados ou aguçados (Figura 5).

As áreas com altitude superior a 300 m ocupam 15,88% da bacia, sendo que apenas 2,06% estão acima de 600 m. Estas áreas estão associadas aos Alinhamentos Serranos do Noroeste fluminense; apresentam direção preferencial NE-SW, e são caracterizadas por imponentes elevações de grande amplitude de relevo com vertentes íngremes e escarpadas, por vezes rochosas, de altos gradientes e topos aguçados de cristas alinhadas. Segundo Dantas (2000), estas consistem em relevos residuais associados a litologias mais resistentes à erosão diferencial ou foram soerguidas durante o evento tectônico extensional gerado durante fins do Cretáceo, e reativadas ao longo do Terciário, em decorrência da abertura do oceano Atlântico e do levantamento das cadeias montanhosas das serras do Mar e da Mantiqueira.

A declividade tem sido considerada um dos mais importantes atributos topográficos primários que controlam os processos pedogenéticos, pois afeta diretamente a velocidade do fluxo superficial e subsuperficial de água e conseqüentemente o teor de água no solo, o potencial de erosão/deposição, e muitos outros processos importantes (Gallant & Wilson, 2000). A elevada média estimada para a declividade (26,63%) expressa bem as características de relevo movimentado da bacia do rio São Domingos. Os maiores declives estão associados sempre com as áreas dos Alinhamentos Serranos e os menores com as áreas cobertas pelos Sedimentos do Quaternário. Tomando-se como referência a classificação adotada pela Embrapa (1999), verifica-se que 60,47% da área da bacia apresentam declividade superior a 20%, sendo que 43,81% em relevo forte ondulado (20 - 45%), 15,54% relevo montanhoso (45 - 75%) e apenas 1,12% apresenta relevo escarpado (> 75%). As áreas de relevo plano (0 - 3%) e suave ondulado (3 - 8%) ocupam 17,51% da bacia e estão relacionadas com os Sedimentos do Quaternário.

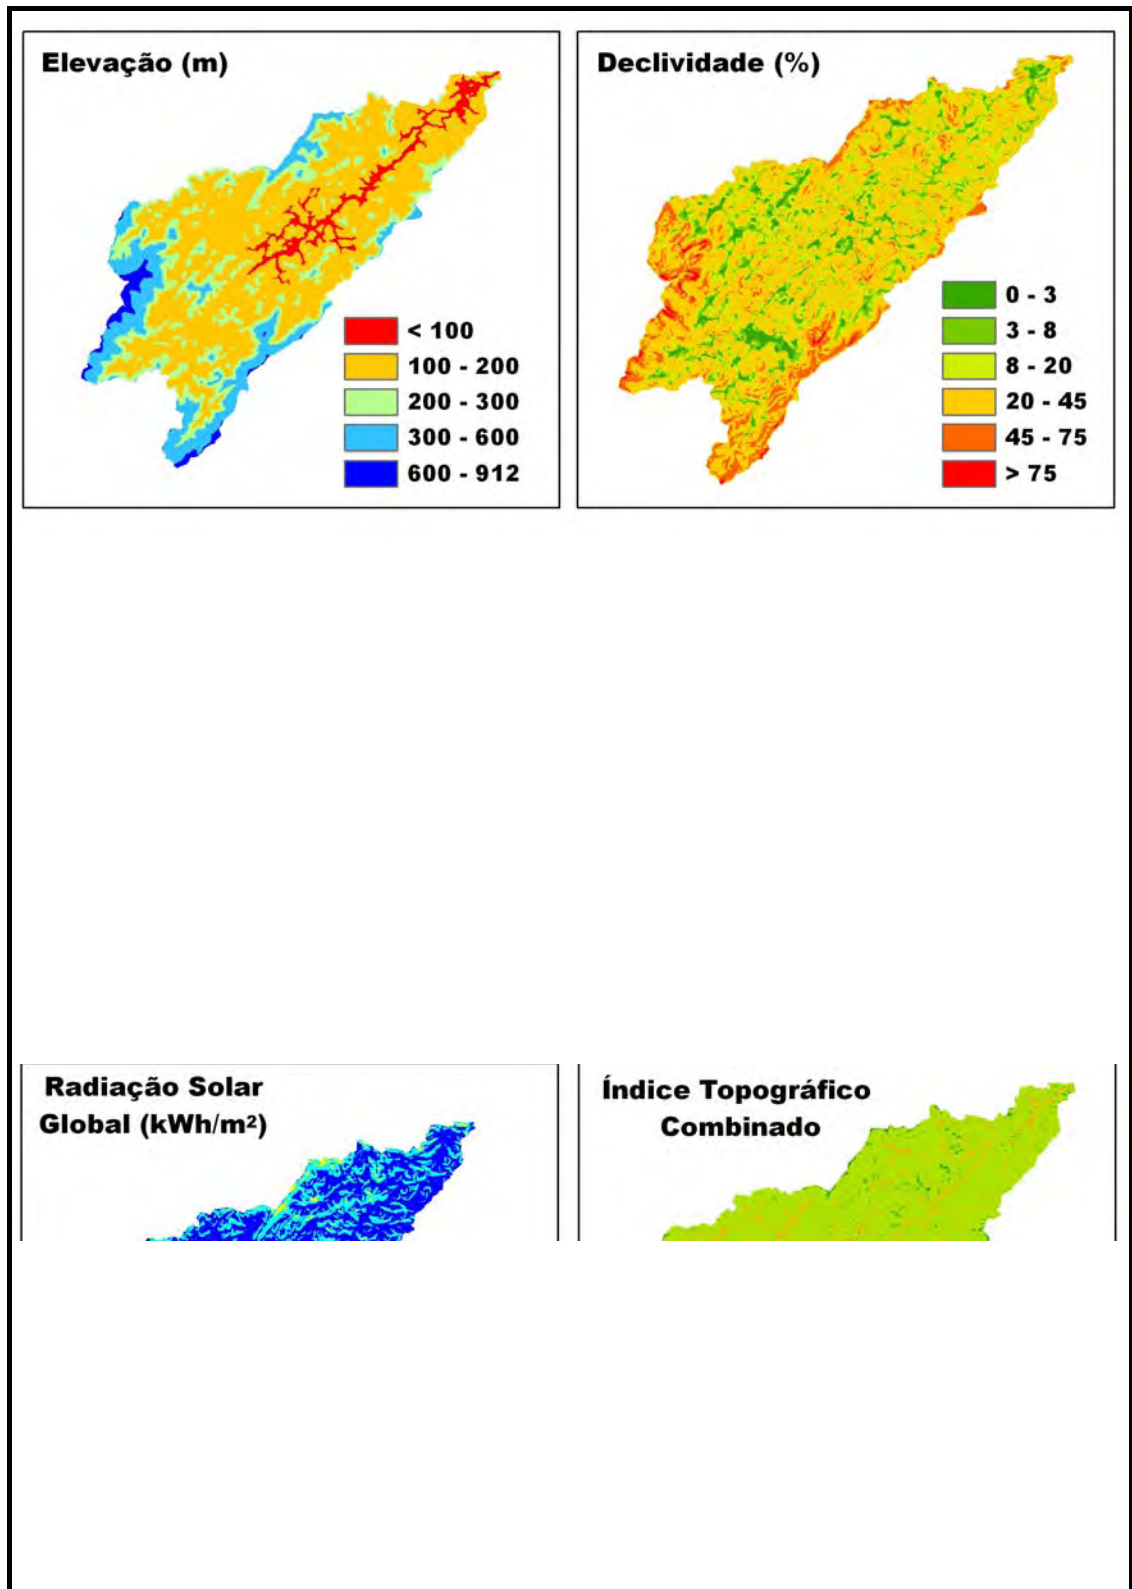


FIGURA 5. Distribuição espacial dos atributos do terreno da bacia do rio São Domingos.



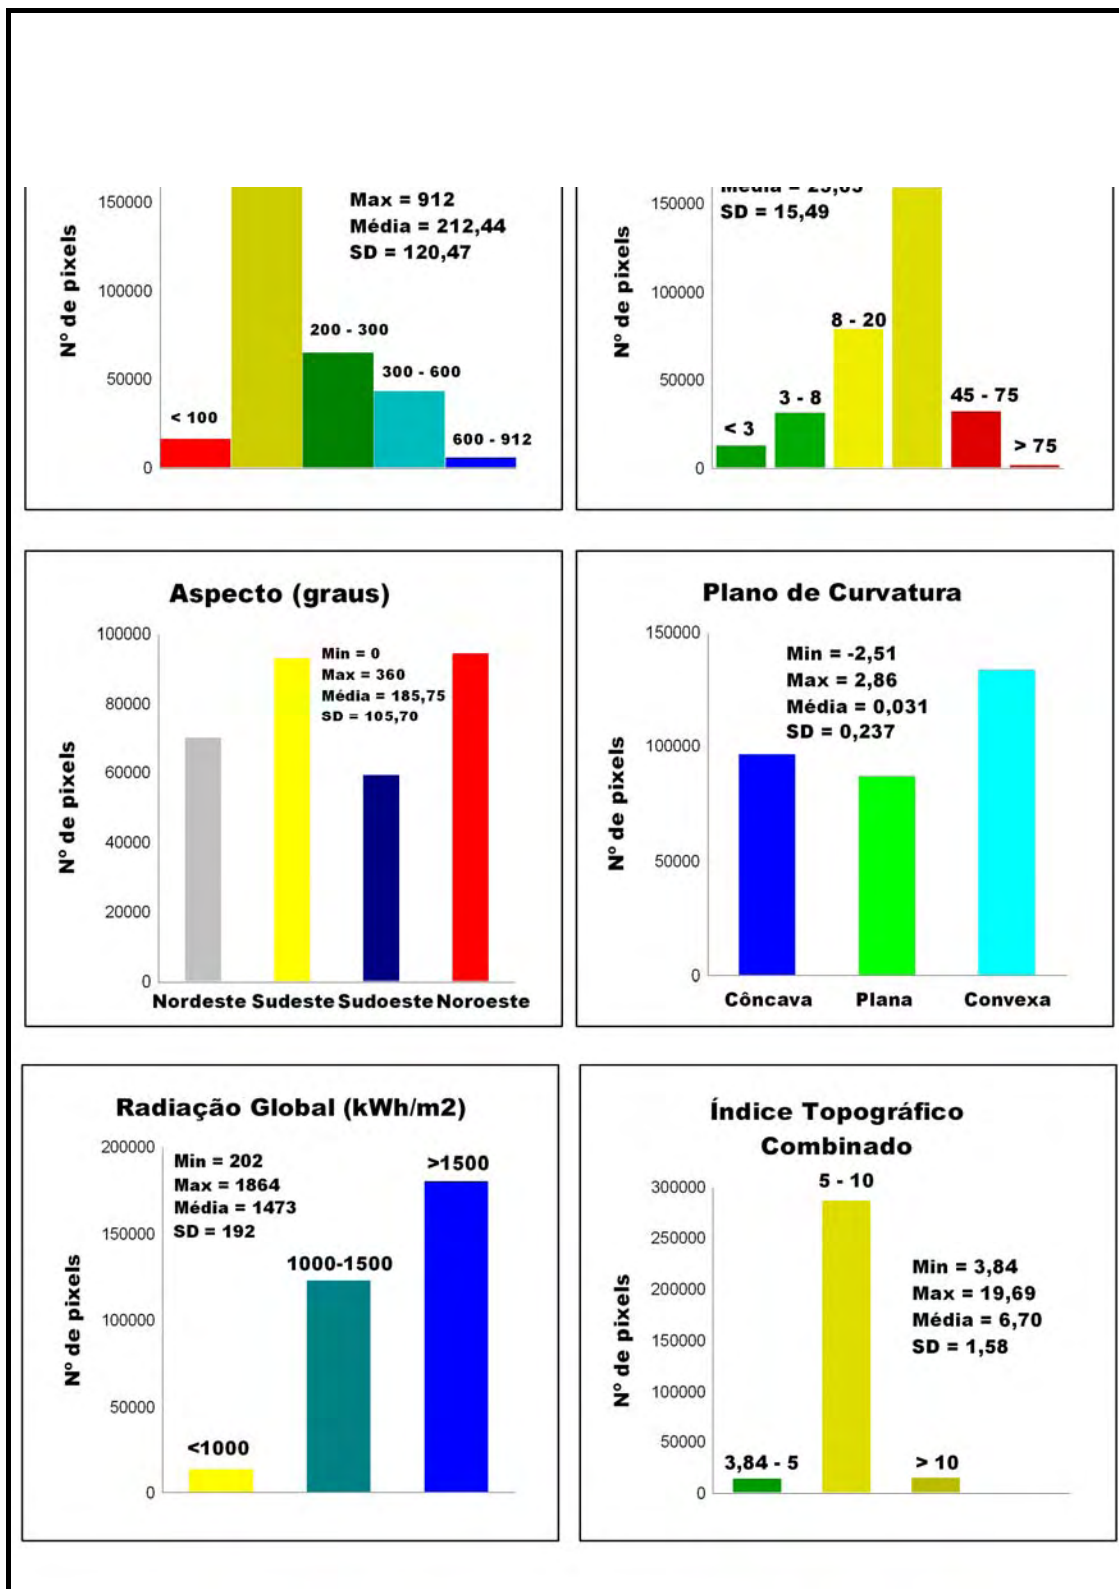


FIGURA 6. Histogramas mostrando os dados estatísticos dos atributos do terreno.

A orientação da encosta (aspecto) é um atributo topográfico primário muito pouco explorado nos estudos das relações solo-paisagem no Brasil, talvez devido à dificuldade de obtenção pelo método tradicional da fotointerpretação. Com o advento dos Sistemas de Informações Geográficas sua obtenção passou a ser um procedimento bastante simples. A orientação da encosta, que define a direção do fluxo de água, está relacionada diretamente com aspectos importantes como evapotranspiração, insolação, teor de água no solo e conseqüentemente sobre os atributos do solo e potencial agrícola (Moore et al., 1993; Wilson & Gallant, 2000). Juntamente com a declividade, pode ser usada para estimar a radiação solar, embora existam ferramentas mais sofisticadas para isto (Gallant & Wilson, 2000).

Neste estudo a orientação da encosta foi dividida, baseando-se nas observações de campo, em quatro classes: nordeste (0 - 90°), sudeste (90 - 180°), sudoeste (180 - 270°) e noroeste (270 - 360°). Os resultados mostram o predomínio das classes noroeste (29,55%) e sudeste (28,95%), contra 22,58% da classe de orientação nordeste e 18,92% da classe de orientação sudoeste. A predominância de encostas voltadas para noroeste e sudeste (58,50%) reflete o elevado controle estrutural disposto em um conjunto de falhas e fraturas geológicas com orientação NE-SW. Assim, o quadro morfológico reflete fortemente a estrutura e as litologias locais, com cristas e colinas orientadas neste sentido e padrão de drenagem do tipo dendrítico, indicando, ainda, forte assimetria das vertentes (Radambrasil, 1983).

A forma da curvatura de uma encosta pode influenciar grandemente a distribuição lateral dos processos pedológicos, hidrológicos e geomórficos e, por conseguinte, os solos que resultam das interações entre estes processos (Pennock et al., 1987). A influência sobre as propriedades dos solos tem sido relacionada, principalmente, ao controle que as formas côncava e convexa exercem sobre a distribuição de água e materiais solúveis das partes mais elevadas para as mais baixas.

As duas curvaturas mais comumente computadas são: plano de curvatura (taxa de variação do aspecto ao longo da curva de nível) e perfil de curvatura (taxa de variação da declividade ao longo da linha de fluxo). O perfil de curvatura é importante para caracterizar mudanças na velocidade do fluxo de água e processos relacionados ao transporte de sedimentos. Por sua vez, o plano de curvatura mede a propensão de a água convergir ou divergir à medida que atravessa o terreno (Gallant & Wilson, 2000).

Segundo Pennock et al. (1987), a configuração da encosta de acordo com o plano e perfil de curvatura pode ser usada para identificar áreas de diferentes regimes de umidade, permitindo uma avaliação mais acurada da distribuição dos solos na paisagem, já que o movimento e a distribuição de água na encosta são as principais razões para diferenças nos solos de uma paisagem (Hall, 1983).

Os resultados obtidos para o plano de curvatura mostram que 43,76% das encostas da bacia do rio São Domingos são convexas, 30,46% são côncavas e aproximadamente 24% da bacia constituem áreas planas, ou seja, áreas que apresentam valores próximos a zero. A média estimada para este atributo foi de 0,031, com o mínimo atingindo -2,51 e o máximo 2,86 (Figura 6). Valores razoáveis, tanto para o plano de curvatura como para o perfil de curvatura em áreas de relevo muito movimentado, como no caso da bacia do rio São Domingos, estão entre -4 e 4. Dessa maneira, os resultados obtidos para este atributo são bastante satisfatórios (Gallant & Wilson, 2000).

As áreas côncavas mais significativas são encontradas nos Alinhamentos Serranos, sempre ocorrendo associadas a relevo forte ondulado e montanhoso. Já na área dos Domínios Colinosos de Mar de Morros, as encostas côncavas são menos expressivas e mostram valores mais próximos de zero, ou seja, apresentam menor concavidade. Aqui também a associação com a declividade é importante, chegando ao extremo de serem encontrados Afloramentos de Rocha em encostas côncavas com relevo montanhoso, devido ao intenso processo de remoção que estas áreas sofreram e a natureza granulítica do substrato.

Verifica-se uma estreita relação entre o plano de curvatura e a espessura dos solos. Como regra geral, os solos mais profundos e mais evoluídos ocupam encostas convexas, enquanto os mais rasos (lépticos, líticos, saprolíticos e câmbicos) e menos evoluídos tendem a ocorrer em encostas côncavas. A ocorrência de solos mais rasos nestas condições está relacionada, juntamente com a elevada declividade, com um maior fluxo convergente de água nestas áreas, o que favorece a morfogênese, levando estes solos a um constante rejuvenescimento por erosão.

Os resultados obtidos para o perfil de curvatura também evidenciam a dominância das encostas convexas (45,76%) sobre as encostas côncavas (30,46%). As

áreas planas ocupam 23,78% e mostram um resultado semelhante àquele obtido para áreas planas do plano de curvatura (23,90%). A média estimada para este atributo foi de 0,031 e os valores mínimo e máximo foram respectivamente -3,49 e 2,86. Embora nenhuma relação explícita tenha sido detectada durante as observações de campo no que diz respeito à distribuição dos solos na paisagem, o perfil de curvatura foi utilizado para tentar melhorar a discriminação dos solos.

O índice topográfico combinado ou índice de umidade (CTI, sigla em inglês) é um atributo topográfico secundário, sendo definido como uma função da declividade e da área de contribuição por unidade de largura ortogonal à direção do fluxo. Este índice foi desenvolvido para ser utilizado em estudo de catenas em áreas declivosas, já que em áreas planas os valores de acumulação serão sempre muito elevados e neste caso o índice não será uma variável confiável. Moore et al. (1993) verificaram, em estudo realizado em uma topossequência no Colorado, que o índice de umidade (CTI) correlacionou-se altamente com muitos dos atributos dos solos medidos, tais como, espessura do horizonte A, pH, teor de matéria orgânica, teor de fósforo extraível e teor de silte e areia. O índice topográfico combinado é obtido conforme apresentado na equação 1:

$$cti = \ln \frac{A_s}{\tan \beta} \quad (1)$$

Onde,  $A_s$  é a área de contribuição (fluxo acumulado + 1) \* tamanho da célula do grid em  $m^2$ ) e  $\beta$  é a declividade expressa em radianos. Os valores obtidos para este índice na bacia do rio São Domingos variaram de 3,84 a 19,69, com um valor médio de 6,70, sendo que aproximadamente 95% das células do grid mostram valores inferiores a 10,0, conforme obtido por Moore et al. (1993) em seu estudo. Neste caso, valores elevados do índice CTI estão relacionados a áreas planas de baixada, onde são encontrados os Gleissolos, ou áreas côncavas, que favorecem o acúmulo de água no solo. De maneira geral, as áreas com declividades superiores a 8% apresentam valores de “CTI” que variam entre 5,0 e 10,0. Já os topos de morro mostram valores sempre inferiores a 5,0.

No presente estudo, este índice foi utilizado, principalmente, para possibilitar a separação dos Gleissolos, que ocorrem em relevo plano, de outras classes de solos que

ocorrem em áreas planas e suave onduladas nos topos dos morros, evitando, assim, uma classificação equivocada dos mesmos.

A radiação solar é a fonte primária para os processos físicos e biológicos que ocorrem em nosso planeta. No hemisfério sul, tradicionalmente, as encostas voltadas para o norte são reconhecidas como superfícies de elevada radiação. Entretanto, a orientação da encosta é considerada uma medida extremamente bruta da radiação solar (Dubayah & Rich, 1995).

Uma variedade de atividades humanas depende da insolação e a topografia é o principal fator que modifica sua distribuição, em nível de paisagem. Assim, a variabilidade na elevação, orientação da superfície (declividade e aspecto) e no sombreamento causado por feições topográficas cria fortes gradientes locais, que causam elevada heterogeneidade espacial e temporal na energia local e no balanço de água, o que influencia fatores, tais como: regime de temperatura do ar e do solo, evapotranspiração, umidade do solo e energia disponível para fotossíntese. Estes fatores, por sua vez, afetam o padrão espacial dos processos naturais, entre eles a distribuição das propriedades dos solos (Fu & Rich, 1999).

Neste estudo, a radiação solar foi utilizada, juntamente com o aspecto, para explicar as diferenças observadas na distribuição dos solos nas encostas convexas da bacia. O mapa de radiação global apresentado na Figura 5 mostra que existe uma considerável variação na insolação que chega à bacia do rio São Domingos. Os valores obtidos variaram de 202 kWh/m<sup>2</sup>/ano a 1864 kWh/m<sup>2</sup>/ano, com uma média aproximada de 1473 kWh/m<sup>2</sup>/ano, sendo que 56,97% das células do grid apresentam valores superiores a 1500 kWh/m<sup>2</sup>/ano. Neste caso, os valores mais elevados são encontrados nas áreas planas que recebem maior radiação direta e onde não existe o impedimento causado pelo sombreamento topográfico. As áreas de mais baixa radiação global, de maneira geral, são encontradas nas encostas com declividades elevadas e voltadas para o Sul.

Uma análise mais detalhada da radiação global que chega às diferentes encostas da bacia mostra que aquelas voltadas para nordeste e noroeste apresentam valores mais elevados (1535 e 1532 kWh/m<sup>2</sup>/ano, respectivamente) do que as encostas voltadas para sudoeste (1336 kWh/m<sup>2</sup>/ano) e sudeste (1302 kWh/m<sup>2</sup>/ano). A menor radiação solar

incidente nas encostas voltadas para sudeste se deve também ao maior efeito do sombreamento topográfico, em partes do dia, verificado nestas encostas. Os resultados obtidos para as radiações direta e difusa seguem a mesma tendência verificada para a radiação global, com as encostas nordeste e noroeste apresentando valores sempre superiores às encostas sudoeste e sudeste.

Na bacia do rio São Domingos a radiação solar, por afetar diretamente o regime de temperatura do ar e do solo, a evapotranspiração e a umidade do solo têm um efeito bastante significativo sobre a distribuição dos solos nas diferentes encostas. Assim, importantes características do solo são afetadas pela radiação solar, entre elas, a cor do solo, saturação de bases e presença de horizonte B latossólico em profundidade.

### **3.2. Relações Geomorfopedológicas**

A distribuição dos solos na paisagem em áreas de relevo movimentado reflete a influência de vários fatores de formação. A topografia, por modificar o fluxo de água e os processos de redistribuição de material no terreno, controla sobremaneira esta distribuição. Muitas das diferenças nos solos devido à topografia estão relacionadas com alguma combinação entre condições microclimáticas, pedogênese e processos geológicos superficiais (Birkeland, 1984).

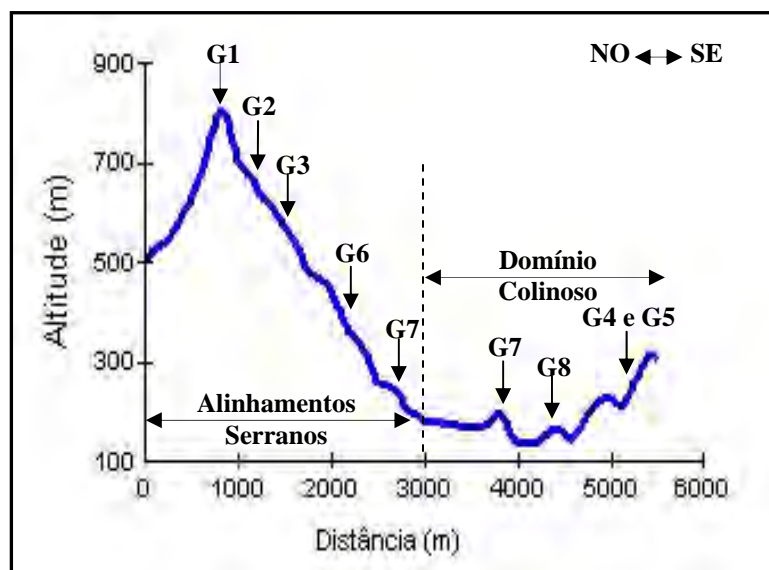
Neste estudo, buscou-se avaliar a influência que as diferentes litologias presentes na bacia rio São Domingos (BHSD) e os atributos topográficos considerados exercem sobre a distribuição dos solos na paisagem. As principais características morfológicas, físicas e químicas dos solos relacionados com estas litologias e suas relações com os atributos topográficos são apresentadas a seguir.

#### **3.2.1. Granulitos da Unidade São José de Ubá**

A partir da combinação entre os atributos topográficos foram identificadas diferentes condições na paisagem que levam à formação de solos com características distintas, conforme apresentado na Tabela 2. Na Figura 7 é apresentado um perfil topográfico típico com a localização de cada uma das unidades geomorfopedológicas identificadas.

**TABELA 2. Unidades geomorfopedológicas identificadas na Unidade São José de Ubá.**

Unidade	Elevação (m)	Relevo	Orientação	Plano de curvatura	Classes de solos	Perfis
G1	>400	Escarpado	Independente	Independente	Afloramentos de rocha	Observação
G2	>400	Forte ondulado e montanhoso	Independente	Côncava + montanhoso e convexa + forte ondulado	Neossolo Litólico Eutrófico típico e Cambissolo Háptico Tb Eutrófico típico e Cambissolo Húmico Tb Distrófico típico	Observação sem coleta de amostras e BHSD08
G3	<400	Forte ondulado	Independente	Côncava	Argissolo Vermelho ou Vermelho-Amarelo Eutrófico câmbico	BHSD 65 e 67
G4	<400	Forte ondulado e montanhoso	Noroeste e Nordeste	Convexa	Argissolo Vermelho Eutrófico típico Nitossolo Vermelho Eutrófico típico	BHSD 45, 07, 13, 41, 42, 47 e 52
G5	<400	Forte ondulado e montanhoso	Sudoeste	Convexa	Argissolo Vermelho-Amarelo Eutrófico típico	BHSD 05, 06, 35, 46 e 49
G6	<400	Forte ondulado e montanhoso	Sudeste	Convexa	Argissolo Vermelho-Amarelo Distrófico latossólico	BHSD 09, 10, 38, 40 e 64
G7	<400	Ondulado	Independente	Independente	Argissolo Vermelho-Amarelo Eutrófico típico ou câmbico e Argissolo Vermelho Eutrófico típico	BHSD 39 e 44
G8	<400	Suave ondulado	Independente	Independente	Argissolo Amarelo Eutrófico típico ou câmbico	Observação sem coleta de amostras



**FIGURA 7. Perfil topográfico mostrando a localização das unidades geomorfopedológicas pertencentes à Unidade São José de Ubá.**

Em áreas de relevo escarpado, em altitudes normalmente superiores a 400 m, são encontrados exclusivamente afloramentos de rocha (unidade G1). Estes afloramentos estão associados aos Alinhamentos Serranos do Noroeste Fluminense e são caracterizados por imponentes elevações de grande amplitude de relevo, declividades que podem ultrapassar os 100%, topos aguçados e cristas alinhadas.

Com ocorrência restrita na BHSD, a unidade G2 ocupa áreas com altitudes superiores a 400 m, sob relevo forte ondulado e montanhoso. O elevado gradiente do relevo acelera o processo erosivo provocando uma constante remoção dos horizontes superficiais do solo (processo de rejuvenescimento). Além disso, solos pouco espessos retêm pouca água e conseqüentemente exibem taxas de intemperismo muito baixas. Sob estas condições são encontrados solos rasos e pouco evoluídos sem horizonte diagnóstico (Neossolo Litólico Eutrófico típico) ou com horizonte B incipiente (Cambissolo Háptico Tb Eutrófico típico). Os primeiros são relacionados com áreas de relevo montanhoso e encostas côncavas e o Cambissolo, com áreas de relevo forte ondulado e encostas predominantemente convexas. As condições microclimáticas, mais úmidas e mais amenas devido à altitude, favorecem o acúmulo de matéria orgânica nas camadas superficiais destes solos. Em condições mais favoráveis podem ser encontrados Cambissolos Húmicos (Tabela 2).

Devido à dificuldade de acesso aos locais de ocorrência desta unidade e sua área pouco expressiva, não foram descritos perfis nem coletadas amostras de solos para confirmação de suas características. Assim, foram utilizadas as informações oriundas da legenda do mapa de solos do Estado do Rio de Janeiro (Embrapa, 2003), complementadas com observações de campo, para a definição das classes de solos pertencentes a esta unidade.

A maior parte da BHSD apresenta áreas com altitudes inferiores a 400 m, nas quais as classes de relevo forte ondulado e montanhoso são dominantes. Nestas condições, a curvatura do terreno e a orientação da encosta desempenham um papel fundamental na distribuição dos solos na paisagem.

De acordo com Hall & Olson (1991), a curvatura da encosta (côncava ou convexa) modifica a força erosiva do fluxo superficial de água e influencia o caminho do movimento desta através do solo. Desta forma, os solos tendem a se tornarem





latossólico em profundidade, todos com argila de atividade baixa, profundos ou muito profundos (150 cm). Nesta situação, a remoção de material pela erosão não foi suficiente para promover o rejuvenescimento destes solos.

Resultados divergentes foram obtidos por Gessler et al. (2000), que em condições de clima temperado verificaram que áreas côncavas, dominadas por processos de acumulação ou ganho de água e sedimentos, apresentavam solos mais evoluídos, enquanto nas áreas convexas a dominância dos processos de perda de água e sedimentos levou à formação de solos sem horizontes diagnósticos significativos ou horizontes fracamente desenvolvidos.

A orientação da encosta tem influência marcante sobre a pedogênese, devido ao controle que esta exerce sobre as condições microclimáticas locais e, conseqüentemente sobre o desenvolvimento da vegetação. Vários estudos têm mostrado esta influência sobre a distribuição dos solos na paisagem (Lotspeich & Smith, 1953; Finney et al., 1962; Birkeland, 1984; Thomas et al., 1999; Zhu et al., 2001). Segundo Birkeland (1984), a orientação afeta grandemente a distribuição de carbono orgânico do solo em profundidade, a presença ou ausência de horizonte E, pH e a porcentagem de bases trocáveis.

Conforme já mostrado, na BHSD, que possui uma direção preferencial NE-SW, nas partes convexas do terreno, as condições microclimáticas variam com a orientação da encosta. As encostas voltadas para nordeste e noroeste apresentam uma incidência maior de radiação solar (1535 e 1532 kWh/m<sup>2</sup>/ano, respectivamente), e conseqüentemente temperaturas mais elevadas do ar e do solo do que aquelas voltadas para sudoeste e sudeste (1336 e 1302 kWh/m<sup>2</sup>/ano, respectivamente), refletindo em diferenças nas características dos solos.

Os solos que ocupam as encostas voltadas para nordeste e noroeste apresentam uma coloração avermelhada (matiz 2,5YR ou mais vermelho), enquanto os solos das encostas sudoeste e sudeste são vermelho-amarelados (matiz mais amarelo que 2,5YR e igual ou mais vermelho que 5YR). Os solos que ocorrem nas encostas voltadas para sudeste, no entanto, são ligeiramente mais amarelados do que os solos das encostas sudoeste (5YR ou mais amarelo) (Tabela 4). A cor destes solos parece ser condicionada pela orientação da encosta.

A cor avermelhada do solo é dada pela presença de hematita, que usualmente coexiste com a goethita, sendo que o avermelhamento aumenta com o aumento do teor de hematita ou com o aumento da relação hematita/goethita (Bigham et al., 1978). Esta relação é governada por vários fatores, entre eles: teor e taxa de liberação de Fe da rocha, temperatura do solo, teor de matéria orgânica, pH, Al, sílica e umidade do solo. Esta última condicionando a decomposição da matéria orgânica e influenciando negativamente, quando elevada, na desidratação da ferrihidrita (Schwertmann & Kämpf, 1985).

O material de origem destes solos (granulitos noríticos) apresenta em sua composição vários minerais em cuja estrutura o ferro está presente, como: piroxênio, biotita, granada, e hornblenda, os quais constituem importante fonte para a formação de hematita no solo. A maior radiação solar incidente sobre as encostas nordeste e noroeste tornam-nas relativamente mais quentes e mais secas (maior evapotranspiração) do que as encostas sudoeste e sudeste. Por outro lado, as encostas sudeste são, ainda, relativamente mais frias e mais úmidas do que as encostas sudoeste. Portanto, as condições nas encostas mais quentes e secas são suficientes para favorecer a formação de hematita em relação à goethita, devido ao maior potencial redox e temperatura do solo mais elevada, a qual acelera a mineralização da matéria orgânica, originando maior disponibilidade de  $Fe^{3+}$  e favorecendo a desidratação da ferrihidrita à hematita (Kämpf & Schwertmann, 1983).

Segundo Tardy & Nahon (1985), o principal agente controlador do equilíbrio entre goethita e hematita no solo é a atividade da água: quando a atividade da água é pequena, a hematita torna-se o óxido de ferro predominante; o aumento da atividade da água propicia o aumento na participação da goethita. Desta maneira, nas encostas mais frias e úmidas, o microclima atual diferenciado favorece a transformação de hematita em goethita (xantização), conseqüentemente, os solos são mais amarelados do que aqueles das encostas mais quentes e secas.

Nas encostas nordeste e noroeste foram identificados Argissolos Vermelhos Eutróficos típicos e Nitossolos Vermelhos Eutróficos típicos, ambos ocorrendo indistintamente em relevo forte ondulado e montanhoso. Nas encostas com orientação sudoeste são encontrados Argissolos Vermelho-Amarelos Eutróficos típicos em relevo forte ondulado e montanhoso. Já nas encostas sudeste são encontrados Argissolos

Vermelho-Amarelos Distróficos latossólicos também em relevo forte ondulado e montanhoso. As características físicas e químicas de perfis representativos destes solos são apresentadas na Tabela 4.

**TABELA 4. Características físicas e químicas dos solos das unidades G4, G5 e G6.**

Nitossolo Vermelho Eutrófico típico (perfil BHSD 07) – G4																	
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	Silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>						
			Areia	Silte	Argila				Ds	Dp							
Ap	0-20	5YR 3/2	363	166	471	369	22	0,35	1,38	2,63	48						
BA	-36	5YR 4/4	251	132	617	0	100	0,21	1,24	2,67	54						
Bt1	-63	2,5YR 4/4	178	99	723	0	100	0,14	1,40	2,67	48						
Bt2	-100	2,5YR 4/6	117	90	793	0	100	0,11	1,28	2,70	53						
Bt3	-140	2,5YR 4/6	114	102	784	0	100	0,13	1,39	2,70	49						
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						Ataque sulfúrico g/kg				Relações moleculares				
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	V (%)	m (%)	C.O. (g/kg)	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	SiO <sub>2</sub> (Ki)	SiO <sub>2</sub> (Kr)
Ap	5,8	5,2	3,4	1,8	0,45	0,01	5,7	8,4	68	0	15,5	154	156	87	12,6	1,68	1,24
BA	5,9	5,2	2,3	1,2	0,21	0,02	3,7	5,8	64	0	8,3	200	203	98	11,5	1,67	1,28
Bt1	6,0	5,4	2,0	1,4	0,11	0,01	3,5	5,4	65	0	6,2	229	228	102	15,3	1,71	1,33
Bt2	6,2	5,6	1,6	2,2	0,14	0,02	4,0	5,7	70	0	4,7	259	254	108	12,0	1,73	1,36
Bt3	6,0	5,7	1,1	2,7	0,22	0,02	4,0	5,5	73	0	3,7	264	244	109	20,5	1,84	1,43
Argissolo Vermelho Eutrófico típico (perfil BHSD 45) – G4																	
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>						
			Areia	Silte	Argila				Ds	Dp							
Ap	0-15	5YR 4/3	536	160	304	263	13	0,53	1,48	1,62	9						
BA	-24	5YR 4/4	369	125	506	0	100	0,25	1,50	2,65	43						
Bt1	-57	2,5YR 3/4	319	113	568	0	100	0,20	1,46	2,75	47						
Bt2	-86	2,5YR 3/6	328	124	548	0	100	0,23	1,55	2,65	42						
Bt3	-150	2,5YR 4/6	236	93	671	0	100	0,14	1,36	2,67	49						
Bt4	-180	3,5YR 4/6	223	128	649	0	100	0,20	1,39	2,66	48						
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						Ataque sulfúrico g/kg				Relações moleculares				
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	V (%)	m (%)	C.O. (g/kg)	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	SiO <sub>2</sub> (Ki)	SiO <sub>2</sub> (Kr)
Ap	5,2	4,6	2,5	1,1	0,09	0,01	3,7	6,2	60	3	8,6	-	-	-	-	-	-
BA	5,6	4,8	2,6	1,1	0,05	0,02	3,8	5,8	66	0	5,2	160	165	77	14,6	1,65	1,27
Bt1	5,6	4,9	2,7	1,4	0,04	0,02	4,2	7,8	54	0	4,1	185	188	80	13,2	1,67	1,31
Bt2	5,4	4,5	1,6	1,4	0,03	0,04	3,1	5,6	55	3	3,2	166	182	79	13,2	1,55	1,21
Bt3	5,3	4,3	1,0	1,4	0,03	0,05	2,5	5,2	48	11	3,1	205	215	92	11,4	1,62	1,27
Bt4	5,1	4,3	0,7	1,2	0,03	0,05	2,0	5,6	36	17	2,9	211	225	96	10,3	1,59	1,25

TABELA 4. Continuação.

Argissolo Vermelho-Amarelo Eutrófico típico (perfil BHSD 46) – G5																		
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>							
			Areia	Silte	Argila				Ds	Dp								
Ap	0-10	5YR 3/4	613	145	242	201	17	0,60	1,61	2,67	40							
AB	-23	5YR 4/4	511	166	323	283	12	0,51	1,57	2,71	42							
BA	-36	3,5YR 3/6	404	151	445	142	68	0,34	1,44	2,70	47							
Bt1	-61	3,5YR 4/6	199	152	649	0	100	0,23	1,28	2,70	53							
Bt2	-94	3,5YR 4/8	191	98	711	0	100	0,14	1,31	2,69	51							
Bt3	-160	2,5R 4/6	193	157	650	0	100	0,24	1,43	2,72	47							
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						Ataque sulfúrico g/kg				Relações moleculares					
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	V (%)	m (%)	C.O. (g/kg)	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	SiO <sub>2</sub>	R <sub>2</sub> O <sub>3</sub>
Ap	5,5	4,8	1,6	0,8	0,26	0,01	2,7	5,9	46	4	9,1	-	-	-	-	-	-	-
AB	5,7	4,9	1,8	0,7	0,13	0,01	2,6	4,4	59	0	7,4	-	-	-	-	-	-	-
BA	6,1	5,3	1,7	1,0	0,06	0,01	2,8	4,1	68	0	5,8	142	150	75	11,0	1,61	1,22	
Bt1	6,3	5,7	2,3	1,3	0,07	0,02	3,7	5,0	74	0	5,5	223	225	98	11,3	1,68	1,32	
Bt2	6,5	5,9	1,5	1,8	0,03	0,02	3,3	4,5	73	0	4,1	224	229	97	12,0	1,66	1,31	
Bt3	6,3	5,8	0,6	2,2	0,08	0,02	2,9	4,1	71	0	3,0	227	227	106	17,2	1,70	1,31	
Argissolo Vermelho-Amarelo Distrófico latossólico (perfil BHSD 09) – G6																		
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>							
			Areia	Silte	Argila				Ds	Dp								
A1	0-8	5YR 3/3	660	117	223	182	18	0,52	1,19	-	-							
A2	-16	5YR 3/4	535	121	344	304	12	0,35	1,30	-	-							
BA	-30	5YR 5/6	396	97	507	467	8	0,19	1,42	-	-							
Bt1	-60	5YR 4/8	340	90	570	0	100	0,16	1,24	-	-							
Bt2	-97	5YR 4/8	317	94	589	0	100	0,16	1,33	-	-							
Bt3	-120	5YR 5/6	274	54	672	0	100	0,08	-	-	-							
Bw1	-150	5YR 5/8	308	62	630	0	100	0,10	-	-	-							
Bw2	-200	2,5YR 4/8	335	76	589	0	100	0,13	-	-	-							
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						Ataque sulfúrico g/kg				Relações moleculares					
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	V (%)	m (%)	C.O. (g/kg)	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	SiO <sub>2</sub>	R <sub>2</sub> O <sub>3</sub>
A1	5,1	4,2	2,5	1,1	0,17	0,03	3,8	9,0	42	5	19,4	92	78	49	9,4	2,01	1,43	
A2	4,8	3,9	1,2	0,7	0,10	0,03	2,0	7,1	28	20	12,5	121	106	59	9,7	1,94	1,43	
BA	5,0	4,1	0,9	1,1	0,07	0,03	2,1	5,6	37	12	8,0	165	159	70	11,8	1,76	1,38	
Bt1	5,0	4,1	0,2	0,9	0,03	0,04	1,2	3,8	32	33	4,4	181	171	81	12,2	1,80	1,38	
Bt2	4,9	4,0	0,4	0,08	0,02	0,5	3,6	14	64	3,3	195	193	80	10,7	1,72	1,36		
Bt3	5,0	4,1	0,3	0,15	0,05	0,5	3,6	14	62	2,8	230	206	92	10,9	1,90	1,48		
Bw1	5,0	4,1	0,3	0,13	0,05	0,5	3,6	14	62	2,4	207	195	85	10,9	1,80	1,41		
Bw2	4,9	4,2	0,3	0,08	0,04	0,4	2,9	14	60	6,8	201	190	84	10,5	1,80	1,40		

A textura parece não variar com os atributos topográficos, já que nenhuma tendência foi verificada entre os perfis analisados, que apresentam indistintamente textura média/argilosa, média/muito argilosa, argilosa ou argilosa/muito argilosa.

Assim, este atributo é controlado basicamente pelo material de origem que mostra potencialidade em fornecer quantidades expressivas de argila como produto do intemperismo.

Todos exibem gradiente textural mais ou menos elevado, com os Argissolos da unidade G5 apresentando gradiente mais elevado ( $>1,7$ ) do que os Nitossolos da mesma unidade. A perda diferencial de argila favorecida pelo elevado gradiente de relevo e o menor grau de flocculação nos horizontes superficiais parecem explicar o gradiente textural nestes solos (Nunes et al., 2001). Os solos da unidade G6 apresentam valores de gradiente textural entre 1,1 e 1,9, sendo que aqueles com baixo gradiente exibem estrutura e/ou cerosidade incompatíveis com aquelas exigidas para o enquadramento nas classes dos Latossolos ou Nitossolos.

Os Argissolos e Nitossolos da unidade G4 ocupam indistintamente a mesma posição dentro desta unidade, o que torna difícil a separação dos mesmos utilizando os atributos do terreno aqui considerados. A única diferença verificada entre eles é o gradiente textural, já que ambos apresentam cerosidade, que varia de comum e moderada a abundante e forte, e grau da estrutura moderada ou forte. Possíveis explicações para esta diferença são: *a*) variabilidade na composição textural do material inicial (são observadas no granulito variações texturais localizadas para tipos de granulação média a grosseira - norito), e *b*) perda por erosão das camadas superficiais do solo de textura mais grosseira e a formação de novo horizonte A, a partir de um horizonte B mais argiloso, no caso dos Nitossolos.

Os solos da unidade G5 apresentam as mesmas características dos Argissolos Vermelhos da unidade G4, diferindo destes somente quanto à coloração, conforme já mencionado. Por sua vez, os solos que ocupam as encostas voltadas para sudeste (unidade G6) apresentam diferenças com relação aos das unidades G4 e G5, sendo mais intemperizados, mais profundos, com menor relação silte/argila e menor saturação por bases, embora os valores do índice Ki sejam bem semelhantes entre eles. A ADA apresenta valores muito baixos nos horizontes subsuperficiais (Bt e Bw) e a baixa relação silte/argila (sempre inferior a 0,6), em todos os perfis das unidades G4, G5 e G6 analisados, está relacionada com a natureza do material de origem, formado essencialmente de feldspatos potássicos, plagioclásios e quartzo. Neste caso, devido a sua facilidade de intemperismo os feldspatos potássicos são rapidamente transformados

em partículas de argila, e deste modo os solos, mesmo aqueles menos intemperizados apresentam baixa relação silte/argila, a exemplo do descrito por Ibraimo et al. (2004).

Outra característica do solo que pode ser afetada pela orientação da encosta é a saturação por bases (Birkeland, 1984), o que foi efetivamente verificado na BHSD nas áreas dominadas por granulitos da unidade São José de Ubá. Os solos que ocupam as encostas mais quentes e secas (Argissolos Vermelhos típicos e Nitossolos da unidade G4 e Argissolos Vermelho-Amarelos da unidade G5) exibem elevada saturação por bases, aliada a baixa CTC (Tabela 4). A eutrofia, neste caso, é reflexo da menor lixiviação de bases nestas encostas quando comparado aos solos das encostas mais frias e úmidas. Os valores de pH, por sua vez, crescem gradualmente em profundidade, acompanhando o aumento da saturação por bases, que em alguns casos chega a 100% e nunca é inferior a 50%, com exceção do horizonte A do perfil BHSD 46 (Argissolo).

Por outro lado, os valores de saturação por bases dos perfis relacionados com as encostas voltadas para sudeste (Argissolos latossólicos) variam entre 14 e 57%, com média de 33%, sendo estes classificados como distróficos (Tabela 4). Embora apresentem valores medianos de saturação por bases, estes são significativamente inferiores àqueles dos Argissolos Vermelhos e Vermelho-Amarelos típicos e Nitossolos das unidades G4 e G5. Estes resultados podem ser atribuídos ao microclima mais úmido, que favorece o processo de intemperismo-lixiviação, levando a um empobrecimento relativo de bases e, conseqüente, enriquecimento de alumínio trocável. Acompanhando a tendência verificada para a saturação por bases, os valores de pH também são inferiores aos encontrados nos solos das unidades G4 e G5.

Finney et al. (1962) estudando o efeito da orientação da encosta sobre as características de solos temperados, mostraram que a orientação teve uma influência marcante no grau de evolução dos solos, com os mais evoluídos ocupando as encostas mais úmidas.

Em alguns perfis foi observado um desbalanço entre  $\text{Ca}^{2+}$  e  $\text{Mg}^{2+}$  no complexo de troca nos horizontes subsuperficiais, fato bastante comum em solos influenciados de rochas ultrabásicas magnesianas, e também verificado em solos derivados destas rochas em ambientes subtropicais do Rio Grande do Sul, sendo esta a principal característica química que diferencia rochas ultrabásicas das de outra origem (Pinto & Kämpf, 1996).

O desbalanço entre  $\text{Ca}^{2+}$  e  $\text{Mg}^{2+}$  verificado nestes solos pode estar relacionado com a influência de minerais magnesianos (ultrabásicos) associados com os granulitos noríticos, originando baixa relação  $\text{Ca}^{2+}/\text{Mg}^{2+}$ . Por sua vez, a maior relação  $\text{Ca}^{2+}/\text{Mg}^{2+}$  verificada nos horizontes superficiais pode ser atribuída à biociclagem, em função da maior utilização do  $\text{Ca}^{2+}$  pelas plantas, bem como às maiores perdas de  $\text{Mg}^{2+}$  por lixiviação (Alexander, 1988).

Os teores de  $\text{Fe}_2\text{O}_3$  do ataque sulfúrico no horizonte B dos solos das unidades G4 e G5 estão em torno 95g/kg, enquanto os Argissolos latossólicos da unidade G6 apresentam valores médios de 83g/kg (Tabela 4), o que os caracteriza como mesoférricos (Embrapa, 1999). Estes teores de  $\text{Fe}_2\text{O}_3$  refletem a natureza do material de origem, conforme já mencionado. Os teores relativamente menores verificados nos perfis dos Argissolos latossólicos, são provavelmente decorrentes da perda do ferro por ferrólise, facilitada pelas melhores condições de umidade. O teor médio de  $\text{TiO}_2$  no horizonte B dos solos é de 12,6g/kg, não sendo observada diferença significativa nos valores entre os Argissolos e os Nitossolos das unidades G4 e G5, e entre estes e os solos da unidade G6. Quanto aos valores de Ki também não se verificam diferenças expressivas entre os perfis apresentados na Tabela 4. Estes variaram entre 1,35 no horizonte Bw3 do perfil BHSD 40 e 1,9 no horizonte Bt3 do perfil BHSD 09.

As áreas de relevo ondulado ocupam porções expressivas na BHSD, ocorrendo em encostas isoladas de baixa amplitude ou em posição de terço inferior próximas aos cursos d'água (Figura 6). Nestas condições, verifica-se uma forte influência do material de origem e quase nenhuma evidência da influência da curvatura do terreno e da orientação da encosta sobre as características dos solos.

A curvatura do terreno desempenha um papel limitado, devido ao baixo gradiente de relevo, de maneira que o processo de rejuvenescimento não se expressa com a mesma magnitude com que ocorre nas áreas mais acidentadas e côncavas. Assim, estas áreas são predominantemente convexas ou apresentam valores muito baixos de concavidade.

A orientação da encosta também tem sua importância reduzida nestas áreas. Segundo Mitasova & Hofierka (1993), esta se torna menos significativa quando a declividade é pequena, pois células com declividade menor do que um valor mínimo



podem ser consideradas como tendo orientação indefinida, exercendo pouca ou quase nenhuma influência na diferenciação dos solos.

Nestas áreas foram identificados Argissolos Vermelho-Amarelos Eutróficos típicos ou câmbicos e Argissolos Vermelhos Eutróficos típicos. Nas bordas do relevo próximo ao limite com os Gleissolos é comum a ocorrência de afloramentos de rocha, e a distância para estes afloramentos é um fator determinante na distribuição dos solos nestas áreas. As características físicas e químicas de perfis representativos destes solos são apresentadas na Tabela 5.

Os solos da unidade G7 ocupam indistintamente as mesmas posições na paisagem, sendo difícil a sua separação, no nível de detalhe considerado neste estudo. A principal diferença verificada é a cor que varia de 5YR a 3,5YR nos Argissolos Vermelho-Amarelos e nos Argissolos Vermelhos é 2,5YR. Tais diferenças são normais nesta unidade e provavelmente estão relacionadas com diferenças no regime de umidade do solo causado pela variabilidade no material de origem.

**TABELA 5. Características físicas e químicas dos solos identificados na unidade G7.**

Argissolo Vermelho-Amarelo Eutrófico típico (perfil BHSD 39)																
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>					
			Areia	Silte	Argila				Ds	Dp						
Ap	0-18	5YR 3/2	481	174	345	325	6	0,50	1,45	2,61	44					
AB	-28	5YR 3/3	429	165	406	20	95	0,41	1,47	2,68	45					
BA	-39	5YR 4/4	340	150	510	0	100	0,29	1,42	2,70	47					
Bt1	-73	4YR 4/6	184	99	717	0	100	0,14	1,43	2,64	46					
Bt2	-110	3,5YR 4/8	196	129	675	0	100	0,19	1,42	2,70	47					
Bt3	-150	2,5YR 4/8	226	224	550	0	100	0,41	-	2,66	-					
Bt4	-180	2,5YR 4/8	254	236	510	0	100	0,46	-	2,69	-					
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)				V (%)	m (%)	C.O. (g/kg)	Ataque sulfúrico g/kg				Relações moleculares		
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>				S	T	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	SiO <sub>2</sub> (Ki)
Ap	5,6	4,7	1,9	1,0	0,31	0,02	3,2	6,0	53	6	9,9	-	-	-	-	-
AB	5,3	4,7	1,1	0,7	0,09	0,02	1,9	4,4	43	5	6,4	-	-	-	-	-
BA	5,3	4,9	1,7	0,9	0,05	0,02	2,7	5,2	52	40	6,2	167	177	140	17,0	1,60
Bt1	5,7	5,5	2,4	2,2	0,03	0,05	4,7	6,8	69	23	5,0	230	224	109	12,3	1,75
Bt2	5,3	5,2	0,6	1,9	0,02	0,04	2,6	4,4	59	0	3,4	231	224	103	9,5	1,75
Bt3	5,0	4,7	0,1	1,3	0,03	0,03	1,5	3,8	39	6	2,1	224	223	100	8,3	1,71
Bt4	5,0	4,8	0,1	1,1	0,03	0,03	1,3	3,6	36	7	2,6	212	220	114	9,1	1,64

Nos Argissolos de terço inferior, o acréscimo de sílica via fluxo superficial e/ou subsuperficial, carregada dos solos das cotas mais elevadas e/ou a proximidade da rocha sã (afloramentos de rocha são muito comuns no terço inferior das encostas), contribui como fonte de sílica e nutrientes para o sistema e pode estar retardando o intemperismo (ressilicatização) nestas porções das encostas (Curi & Franzmeier, 1984).

A textura destes solos é média/muito argilosa e argilosa/muito argilosa. Todos apresentam gradiente textural mais ou menos elevado ( $>1,6$ ), não se verificando, no entanto, mudança textural abrupta. A ausência de mudança textural abrupta é uma característica bastante marcante dos solos derivados dos granulitos noríticos da unidade São José de Ubá, estando relacionada com a granulação fina a média destas rochas. Acompanhando a tendência verificada nos solos das demais unidades, os valores de ADA são muito baixos nos horizontes subsuperficiais, bem como, a relação silte/argila, inferior a 0,3 em todos os perfis analisados.

Os solos desta unidade também apresentam elevada saturação por bases, alcançando os 100% no Argissolo Vermelho-Amarelo, e baixa CTC. Nos solos desta unidade também é verificado um desbalanço entre  $\text{Ca}^{2+}$  e  $\text{Mg}^{2+}$  no complexo de troca nos horizontes subsuperficiais de alguns perfis, conforme verificado anteriormente. Os teores de  $\text{Fe}_2\text{O}_3$  e de  $\text{TiO}_2$  do ataque sulfúrico no horizonte B, assim como, os valores de Ki acompanham a tendência verificada nos solos das demais unidades (Tabela 5).

Em áreas de relevo suave ondulado foram identificados Argissolos Amarelos Eutróficos típicos ou câmbicos relacionados com a Unidade G8. De maneira geral, apresentam as mesmas características dos Argissolos da Unidade G7, diferenciando-se destes apenas por apresentarem coloração do horizonte B mais amarelada do que 5YR. Esta unidade ocupa áreas suavemente onduladas que constituem pequenas elevações isoladas com baixíssima amplitude de relevo, próximo das várzeas. A ocorrência de afloramentos de rocha e a distância para estes afloramentos é que condiciona a maior ou menor espessura do sólum nestas áreas.

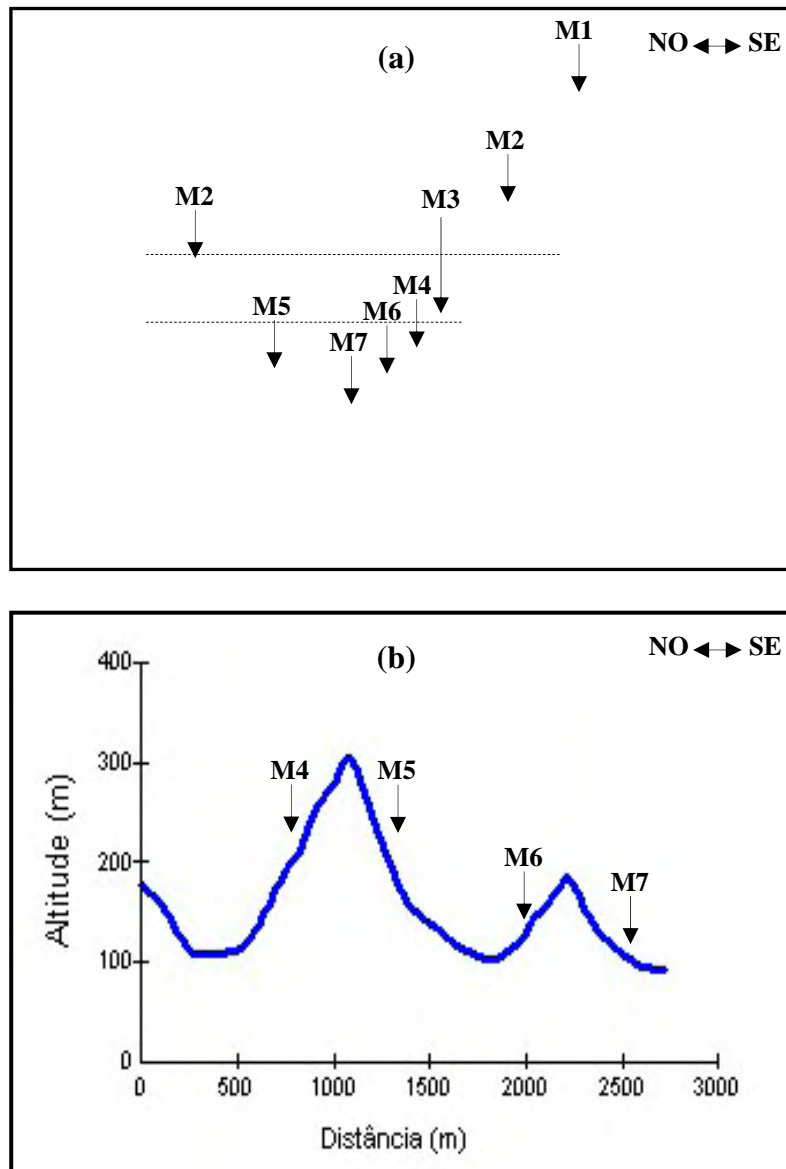
### 3.2.2. Migmatitos das Unidades Vista Alegre, São João do Paraíso e Catalunha e Milonito gnaisse da Unidade Santo Eduardo

Embora apresentem características que os diferenciam, verificou-se por ocasião dos trabalhos de campo que os solos derivados destes materiais apresentam, no geral, características morfológicas bastante semelhantes. Além disso, os resultados analíticos realizados em vários perfis também comprovaram que estes são física e quimicamente bastante parecidos. Deste modo, estas unidades foram agrupadas. As diferentes condições ambientais encontradas nestas unidades litológicas são apresentadas na Tabela 6 e na Figura 8 são apresentados os perfis topográficos típicos destas unidades.

Áreas com altitudes superiores a 400 m são encontradas nas unidades Vista Alegre, São João do Paraíso e Santo Eduardo, onde são observados grandes afloramentos de rocha (unidade M1) associados aos Alinhamentos Serranos do Noroeste Fluminense, caracterizados por imponentes elevações com declividades fortes, topos aguçados e cristas alinhadas.

**TABELA 6. Unidades geomorfopedológicas identificadas nas Unidades Vista Alegre, São João do Paraíso, Catalunha e Santo Eduardo.**

Unidades	Elevação (m)	Relevo	Orientação	Plano de curvatura	Classes de solos	Perfis
M1	>400	Escarpado	Independente	Independente	Afloramentos de rocha	Observação sem coleta de amostras
M2	>400	Forte ondulado e montanhoso	Independente	Independente	Neossolo Litólico Eutrófico típico e Cambissolo Háptico Ta ou Tb Eutrófico típico ou léptico	Observação sem coleta de amostras
M3	<400	Forte ondulado ou montanhoso	Independente	Côncava	Cambissolo Háptico Ta ou Tb Eutrófico típico ou léptico ou lítico	BHSD 01, 11, 15, 19, 20, 21, 22, 33, 37 e 66
M4	<400	Forte ondulado e montanhoso	Noroeste, nordeste e sudoeste	Convexa	Argissolo Vermelho Eutrófico abrupto ou abrupto chernossólico	BHSD 12, 28, 48, 54 e 60
M5	<400	Forte ondulado e montanhoso	Sudeste	Convexa	Argissolo Vermelho Eutrófico abrupto latossólico e Luvisso Háptico Órtico típico ou léptico (Inclusão de Argissolo Vermelho-Amarelo Eutrófico abrupto)	BHSD 03, 17, 18, 31, 32, 34, 51, 55, 58 e 63
M6	<300	Ondulado	Independente	Independente	Argissolo Vermelho e Vermelho-Amarelo Eutrófico abrupto	BHSD 04, 57 e 62
M7	<200	Suave ondulado	Independente	Independente	Argissolo Amarelo Eutrófico abrupto ou abrupto câmbico	BHSD 68 e 69



**FIGURA 8.** Perfil topográfico mostrando a localização das unidades geomorfológicas pertencentes a Unidade Vista Alegre (a) e Unidade São João do Paraíso (b).

Também em cotas superiores a 400 m, principalmente nas unidades Vista Alegre e São João do Paraíso e associadas com relevo forte ondulado e montanhoso foi identificada a unidade M2. Nesta, o elevado gradiente do relevo, favorecendo a constante remoção dos horizontes superficiais do solo (rejuvenescimento) é o principal responsável pela ocorrência de Neossolos Litólicos Eutróficos típicos em relevo montanhoso e Cambissolos Háplicos Ta ou Tb Eutrófico típico ou léptico em relevo forte ondulado, intimamente associados com áreas onde a rocha está exposta.

Do mesmo modo, como ocorre na Unidade São José de Ubá, a curvatura do terreno e a orientação da encosta também desempenham um papel importante na distribuição dos solos nestas unidades litológicas. Assim, em áreas inferiores a 400 m, sob relevo forte ondulado, associados às encostas côncavas foram identificados Cambissolos Háplicos Ta ou Tb Eutróficos típicos, lépticos, líticos e argissólicos, na unidade M3. A intensa remoção do material do solo, através do fluxo superficial de água convergente, e em menor proporção pelo movimento de massa são os principais responsáveis pela limitação continuada de desenvolvimento destes solos (Phillips et al., 2001). Neste sentido, Grossman (1983) afirmou que estas formas de erosão removem material superficial dos solos, de modo tão ou mais rápido do que os horizontes pedogênicos podem se formar. Este processo de rejuvenescimento é tanto maior quanto maiores são a declividade e a concavidade do terreno. Deste modo, os solos são pouco profundos ou rasos (< 100 cm) e nos casos mais drásticos de remoção do solo as rochas foram expostas.

Na Tabela 7 são apresentadas as características físicas e químicas de perfis representativos desta unidade. A textura destes solos é média ou média/argilosa. Os valores de ADA e da relação silte/argila mais elevados estão condizentes com o grau de evolução destes solos (solos pouco evoluídos), embora alguns perfis apresentem valores inferiores a 0,6. A densidade de partículas nos perfis analisados variou de 2,50 a 2,65 g.cm<sup>-3</sup>.

Os solos desta unidade apresentam elevada saturação por bases, com valores médios no horizonte A superiores a 61% e no horizonte B maiores do que 66%. Os Cambissolos desenvolvidos dos migmatitos e milonitos gnaisses exibem, mais frequentemente, uma CTC elevada, com valores médios superiores a 30 cmol<sub>c</sub>/kg, sendo, portanto, classificados como solos de argila de atividade alta (Tabela 7). Esta elevada CTC é condicionada pela maior riqueza relativa em minerais ferromagnesianos presentes na constituição dos migmatitos e milonitos gnaisses, quando comparados aos granulitos, e ao menor intemperismo destes solos.

TABELA 7. Características físicas e químicas dos solos identificados na unidade M3.

Cambissolo Háplico Ta Eutrófico típico (perfil BHSD 33)																	
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>						
			Areia	Silte	Argila				Ds	Dp							
Ap	0-32	7,5YR 3/3	564	212	224	183	18	0,95	1,30	2,56	49						
BA	-48	5YR 4/3	529	246	225	204	9	1,09	1,38	2,50	45						
Bi1	-66	5YR 4/4	434	280	286	245	14	0,98	1,41	2,60	46						
Bi2	-85	5YR 4/6	451	223	326	306	6	0,68	1,35	2,56	47						
C1	-125	7,5YR 5/3	470	266	264	20	92	1,01	1,41	2,56	45						
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						Ataque sulfúrico g/kg				Relações moleculares				
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	V (%)	m (%)	C.O. (g/kg)	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	SiO <sub>2</sub> (Ki)	SiO <sub>2</sub> (Kr)
Ap	5,7	4,7	3,5	1,8	0,10	0,04	5,4	8,8	61	0	11,2	110	110	63	8,8	1,70	1,24
BA	6,4	5,1	3,4	3,3	0,04	0,07	6,8	9,4	72	0	6,1	145	151	83	7,5	1,63	1,21
Bi1	5,8	4,8	2,8	3,6	0,04	0,07	6,5	9,7	67	0	6,9	143	150	74	6,9	1,62	1,23
Bi2	6,2	4,8	2,1	4,6	0,04	0,08	6,8	9,3	73	0	4,2	150	116	80	6,3	2,20	1,53
C1	6,1	4,9	1,3	4,6	0,05	0,11	6,1	7,7	79	0	2,2	143	101	61	5,6	2,41	1,74
Cambissolo Háplico Tb Eutrófico típico (perfil BHSD 21)																	
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>						
			Areia	Silte	Argila				Ds	Dp							
A	0-20	5YR 3/3	636	142	222	0	100	0,64	1,37	2,53	46						
BA	-37	5YR 4/3	606	131	263	121	54	0,50	1,32	2,53	48						
Bi	-62	5YR 4/4	507	108	385	203	47	0,28	1,36	2,60	48						
C1	-86	5YR 4/6	504	111	385	142	63	0,29	1,36	2,60	48						
C2	-103	5YR 4/6	461	92	447	0	100	0,21	1,32	2,60	49						
C3	-130	7,5YR 5/6	376	54	570	0	100	0,09	1,23	2,56	52						
C4	-155	7,5YR 5/6	342	68	590	0	100	0,12	1,24	2,60	52						
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						Ataque sulfúrico g/kg				Relações moleculares				
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	V (%)	m (%)	C.O. (g/kg)	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	SiO <sub>2</sub> (Ki)	SiO <sub>2</sub> (Kr)
A	5,9	5,1	3,1	1,4	0,10	0,02	4,6	7,6	61	0	12,1	-	-	-	-	-	-
BA	5,8	5,0	2,8	0,5	0,03	0,03	3,4	5,7	60	0	6,3	-	-	-	-	-	-
Bi	5,8	5,1	2,8	0,8	0,02	0,05	3,7	5,7	65	0	4,5	-	-	-	-	-	-
C1	6,4	5,4	2,2	1,0	0,01	0,05	3,3	4,8	69	0	2,5	-	-	-	-	-	-
C2	6,6	5,8	2,1	1,4	0,01	0,05	3,6	4,8	75	0	2,3	-	-	-	-	-	-
C3	6,5	5,8	1,9	1,7	0,02	0,03	3,6	4,6	78	0	2,5	-	-	-	-	-	-
C4	6,7	6,0	1,5	1,8	0,03	0,02	3,3	4,3	77	0	2,2	-	-	-	-	-	-

**TABELA 7. Continuação.**

Cambissolo Háptico Ta Eutrófico léptico (perfil BHSD 01)																	
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>						
			Areia	Silte	Argila				Ds	Dp							
Ap	0-20	7,5YR 3/2	621	175	204	163	20	0,86	1,59	2,60	39						
BA	-30	7,5YR 4/4	603	173	224	224	0	0,77	1,77	2,63	33						
Bi	-60	7,5YR 5/4	563	213	224	224	0	0,95	1,82	2,67	32						
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)				V (%)	m (%)	C.O. (g/kg)	Ataque sulfúrico g/kg				Relações moleculares			
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>				S	T	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub> (Ki)	SiO <sub>2</sub> R <sub>2</sub> O <sub>3</sub> (Kr)
Ap	5,7	4,5	5,1	3,3	0,13	0,08	8,6	12,3	70	1	13,3	87	56	63	9,4	2,64	1,54
BA	6,0	4,6	4,1	3,6	0,09	0,15	7,9	10,5	75	1	6,7	98	69	65	17,0	2,41	1,51
Bi	6,4	4,7	3,9	4,9	0,10	0,33	9,2	11,2	82	1	3,7	112	80	70	15,5	2,38	1,53

Diferentemente do observado nas encostas côncavas, nas encostas convexas foram identificados solos bem desenvolvidos que apresentam horizonte B textural com argila de atividade baixa. Aqui também a forma da encosta desempenha um papel importante na distribuição dos solos, pois a natureza convexa destas encostas é responsável por uma menor remoção de material pelos agentes erosivos, por isso os solos apresentam um maior desenvolvimento pedogenético do que os solos que ocupam as encostas côncavas.

A influência que a orientação da encosta tem sobre a pedogênese também está presente nestas unidades litológicas. Embora as condições microclimáticas variem com a orientação da encosta, estas se mostraram menos determinantes na diferenciação das características dos solos destas unidades do que nos solos derivados de granulitos noríticos. Assim, apesar da diferença na incidência de radiação solar entre as diferentes encostas (nordeste - 1535 kWh/m<sup>2</sup>/ano, noroeste - 1532 kWh/m<sup>2</sup>/ano, sudoeste - 1336 kWh/m<sup>2</sup>/ano e sudeste - 1302 kWh/m<sup>2</sup>/ano), não se verificaram mudanças significativas em algumas características dos solos em função da orientação, sugerindo que as variações na radiação solar incidente sobre estas faces e conseqüentemente sobre a temperatura do solo não foram suficientes para determinar diferenças nas características avaliadas.

Uma destas é a cor do solo, que ao contrário do que ocorre nos granulitos noríticos, não variou. Deste modo, todos os solos descritos apresentam coloração

avermelhada (matiz 2,5YR ou mais vermelho), independentemente da encosta que ocupam. Neste caso, por serem mais jovem, o material de origem exerce uma influência maior na determinação da cor do solo, o que sobrepuja a influência exercida pela orientação da encosta.

Como a cor avermelhada do solo é dada pela hematita e a sua presença é governada entre outros fatores pelo teor e taxa de liberação de Fe da rocha (Schwertmann & Kämpf, 1985), provavelmente, a maior riqueza em minerais ricos em ferro como: granada, biotita, cordierita, piroxênios e anfibólios (hornblenda) presentes nos migmatitos e a facilidade de intemperismo destes minerais resulte em uma taxa de liberação de ferro mais elevada do que aquela verificada nos granulitos, favorecendo, desta maneira, a formação de hematita, mesmo em condições de umidade relativamente mais elevada, como se verifica nas encostas voltadas para sudeste.

Entretanto, foram identificados perfis de Luvisolos Háplicos de coloração vermelho-amarelada (5YR) em encostas voltadas para sudeste. Neste caso, tanto a coloração quanto a maior atividade da argila (Ta) destes solos parecem estar mais relacionadas com a variabilidade do material de origem nestas áreas, já que a unidade Vista Alegre, onde foram identificados, é formada por uma associação complexa de migmatitos e metamorfitos extremamente heterogêneos (DRM, 1980), aliada às condições microclimáticas específicas devidas à orientação da encosta.

A saturação por bases, que na unidade São José de Ubá, variou em função da orientação da encosta, foi outra característica que não mudou nos solos derivados dos migmatitos e milonitos gnaisses. Assim, todos os perfis analisados são eutróficos, independente da orientação, com valores entre 52 e 100%, demonstrando a riqueza do material de origem.

Embora as condições microclimáticas relativamente menos quentes e mais úmidas nas encostas voltadas para sudeste tenham afetado pouco a cor do solo, ao contrário do que se verifica nos solos derivados de granulitos noríticos (vermelho-amarelados), foram suficientes para favorecer o desenvolvimento de um horizonte B latossólico abaixo do horizonte diagnóstico B textural, dentro de 200 cm de profundidade. Por outro lado, não foram suficientes para promover uma remoção mais intensa das bases trocáveis, daí os solos serem eutróficos, mesmo no horizonte B



latossólico. A morfologia, determinada pela estrutura fraca a moderada em blocos subangulares que se desfazem em forte muito pequena granular e pela ausência de cerosidade, é a única diferença entre os horizontes Bt e Bw destes solos, já que as demais características são muito semelhantes (Tabela 8).

Em função da presença ou ausência de horizonte B latossólico em profundidade, os solos destas unidades foram classificados como Argissolos Vermelhos Eutróficos abruptos ou abruptos chernossólicos, ocorrendo nas encostas voltadas para noroeste, nordeste e sudoeste (unidade M4), enquanto nas encostas com orientação sudeste foram classificados como Argissolos Vermelhos ou Vermelho-Amarelos Eutróficos abruptos latossólicos, ambos em relevo forte ondulado e montanhoso (unidade M5). Em condições particulares, conforme descrito anteriormente, são encontrados Luvisolos Hápticos Órticos típicos ou lépticos, também em relevo forte ondulado e montanhoso (unidade M5). As características físicas e químicas de perfis representativos destes solos são apresentadas na Tabela 8.

Nenhuma tendência foi verificada entre os perfis analisados com relação a uma variação da textura em função da orientação da encosta. Apresentam textura média/argilosa, média/muito argilosa ou argilosa/muito argilosa, sendo esta controlada exclusivamente pelo material de origem. Exibem gradiente textural bastante variado ( $>1,3$  e  $<2,3$ ), com mudança textural abrupta, sendo esta a principal característica que os distingue dos solos derivados dos granulitos. Aqui a perda diferencial de argila, favorecida pelo elevado gradiente de relevo e o menor grau de floculação nos horizontes superficiais, é provavelmente, maximizada pela granulação mais grosseira do material de origem.

TABELA 8. Características físicas e químicas dos solos das unidades M4 e M5.

Argissolo Vermelho Eutrófico abruptico (perfil BHSD 28) – M4																	
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>						
			Areia	Silte	Argila				Ds	Dp							
Ap	0-10	7,5YR3/2	487	289	224	122	46	1,29	1,28	2,41	47						
A2	-34	5YR 3/3	433	281	286	204	29	0,98	1,40	2,47	43						
Bt1	-53	2,5YR3/4	307	182	511	450	12	0,36	1,37	2,56	46						
Bt2	-118	2,5YR3/4	214	127	659	556	16	0,19	1,33	2,60	49						
C	-135	-	541	173	286	82	71	0,60	1,47	2,60	43						
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						Ataque sulfúrico g/kg				Relações moleculares				
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	V (%)	m (%)	C.O. (g/kg)	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	SiO <sub>2</sub> / Al <sub>2</sub> O <sub>3</sub> (Ki)	SiO <sub>2</sub> / R <sub>2</sub> O <sub>3</sub> (Kr)
Ap	6,6	5,6	5,6	1,8	1,58	0,03	9,0	11,5	78	0	16,0	85	49	56	12,0	2,95	1,70
A2	6,7	5,6	6,8	1,3	0,58	0,02	8,7	10,5	83	0	8,7	97	68	57	12,1	2,42	1,58
Bt1	7,1	5,6	9,2	1,4	0,26	0,03	10,9	10,9	100	0	6,9	160	148	80	10,7	1,84	1,37
Bt2	7,0	5,8	10,3	1,4	0,09	0,05	11,8	11,8	100	0	5,9	202	203	85	9,5	1,69	1,33
C	7,1	5,7	8,0	1,5	0,09	0,04	9,6	9,6	100	0	2,6	126	118	64	7,8	1,82	1,35
Argissolo Vermelho Eutrófico abruptico latossólico (perfil BHSD 51) – M5																	
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>						
			Areia	Silte	Argila				Ds	Dp							
Ap	0-23	5YR 3/4	522	154	324	284	12	0,48	1,43	2,61	45						
AB	-37	2,5YR 3/6	420	165	416	344	17	0,39	1,38	2,70	49						
BA	-55	2,5YR 4/6	251	117	632	0	100	0,19	1,27	2,68	53						
Bt1	-83	2,5YR 4/5	218	130	652	0	100	0,20	1,22	2,72	55						
Bt2	-150	2,5YR 4/6	273	239	488	0	100	0,49	1,31	2,70	51						
Bw	-200	3,5YR 4/7	522	154	324	284	12	0,48	1,43	2,61	45						
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						Ataque sulfúrico g/kg				Relações moleculares				
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	V (%)	m (%)	C.O. (g/kg)	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	SiO <sub>2</sub> / Al <sub>2</sub> O <sub>3</sub> (Ki)	SiO <sub>2</sub> / R <sub>2</sub> O <sub>3</sub> (Kr)
Ap	6,7	6,0	2,8	1,2	0,53	0,01	4,5	6,0	75	0	12,5	106	116	68	12,9	1,55	1,13
AB	6,7	5,6	1,5	0,5	0,45	0,01	2,5	4,0	62	0	6,5	128	142	78	12,1	1,53	1,13
BA	6,6	5,7	1,6	0,5	0,33	0,01	2,4	3,9	62	0	5,0	152	166	90	11,2	1,56	1,16
Bt1	6,5	5,7	2,2	0,4	0,19	0,01	2,8	4,1	68	0	3,7	200	212	103	10,0	1,60	1,22
Bt2	6,9	6,1	1,9	0,6	0,07	0,01	2,6	3,6	72	0	2,3	216	228	105	8,7	1,61	1,24
Bw	6,7	6,3	1,2	0,8	0,03	0,01	2,0	2,8	71	0	12,5	203	214	105	8,9	1,61	1,23

Nos perfis das unidades M4 e M5 analisados os valores de ADA e a relação silte/argila são muito baixos (sempre inferior a 0,3) nos horizontes subsuperficiais (Bt e Bw), do mesmo modo como verificado para os solos derivados dos granulitos noríticos.

A saturação por bases é bem elevada nos solos das unidades M4 e M5, com os Argissolos apresentando CTC inferior a 20 cmol<sub>c</sub>/kg no horizonte B (Tabela 8), enquanto os Luvisolos apresentam CTC superior a 42 cmol<sub>c</sub>/kg no horizonte A e 29

cmol/kg no horizonte B (não mostrados). O desbalanço entre  $\text{Ca}^{2+}$  e  $\text{Mg}^{2+}$  bastante comum nos horizontes subsuperficiais dos perfis relacionados com os granulitos (relação  $\text{Ca/Mg} < 1$ ), foi pouco observado nos solos relacionados com as unidades M4 e M5. No entanto, não foi verificada nenhuma tendência para os resultados obtidos.

Os teores de  $\text{Fe}_2\text{O}_3$  do ataque sulfúrico no horizonte B dos solos destas unidades estão em torno de 85g/kg, com alguns apresentando teores inferiores a 80 g/kg (perfis BHSD 12, 48, 58, 60 e 63), enquanto os demais perfis mostram valores médios no horizonte B superiores a 84g/kg (perfis BHSD 03, 28, 51 e 55), o que caracteriza o primeiro grupo como hipoférrico e o segundo como mesoférrico (Embrapa, 1999). Com relação aos teores de  $\text{Fe}_2\text{O}_3$  do ataque sulfúrico também não se verificam diferenças entre os solos que ocupam as encostas noroeste, nordeste e sudoeste (unidade M4) e aqueles que ocorrem na encosta sudeste (unidade M5), visto que solos hipoférricos e mesoférricos estão indistintamente presentes nestas encostas.

Comparando-se os teores de  $\text{Fe}_2\text{O}_3$  encontrados para os solos destas unidades com os solos derivados dos granulitos (unidades G4, G5 e G6) observa-se que, embora tenham sido identificados solos hipoférricos nas unidades M4 e M5, a diferença nesses teores é pouco significativa entre os solos derivados destes materiais. Tendência similar ao  $\text{Fe}_2\text{O}_3$  do ataque sulfúrico também se observa para os teores de  $\text{TiO}_2$ .

Quanto ao índice Ki verifica-se uma pequena distinção entre os solos da unidade M4 (Argissolos abrupticos) dos solos da unidade M5 (Argissolos latossólicos). A média obtida para este índice, no horizonte B dos Argissolos abrupticos, foi de aproximadamente 1,80, enquanto que, para os Argissolos latossólicos, foi de 1,60. Assim, estes valores juntamente com a presença de horizonte B latossólico atestam o grau mais evoluído dos Argissolos latossólicos quando comparados aos Argissolos abrupticos.

A unidade M6 ocorre em situação similar àquela da unidade G7, ou seja, em áreas de relevo ondulado, em encostas isoladas de baixa amplitude ou em posição de terço inferior próximas aos cursos d'água (Figura 6). Nestas condições, também se verifica uma forte influência do material de origem e pouca ou quase nenhuma da curvatura do terreno e da orientação da encosta sobre as características dos solos.

Nestas áreas foram identificados Argissolos Vermelhos Eutróficos abrupticos e Argissolos Vermelho-Amarelos Eutróficos abrupticos. Nas bordas do relevo próximo ao limite com os solos hidromórficos é comum a ocorrência de variedades destes Argissolos mais rasos (abrupticos câmbicos) e afloramentos de rocha. A distância para estes afloramentos é o principal fator a determinar a espessura dos solos nestas áreas: quanto mais próximos dos afloramentos, mais rasos são estes solos. Neste aspecto, os solos desta unidade são menos espessos que os das unidades M4 e M5, justamente devido à proximidade da rocha sã. As características físicas e químicas de perfis representativos destes solos são apresentadas na Tabela 9.

**TABELA 9. Características físicas e químicas dos solos identificados na unidade M6.**

Argissolo Vermelho Eutrófico abruptico (perfil BHSD 57)																	
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>						
			Areia	Silte	Argila				Ds	Dp							
Ap	0-18	5YR 3/4	559	177	264	203	23	0,67	-	-	-						
Bt2	58-94	2,5YR 4/7	236	107	657	0	100	0,16	-	-	-						
BC	-135	2,5YR 4/6 7,5YR 4/6	237	125	638	0	100	0,20	-	-	-						
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						Ataque sulfúrico g/kg				Relações moleculares				
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	V (%)	m (%)	C.O. (g/kg)	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	SiO <sub>2</sub> / Al <sub>2</sub> O <sub>3</sub> (Ki)	SiO <sub>2</sub> / R <sub>2</sub> O <sub>3</sub> (Kr)
Ap	5,8	4,8	3,8	1,4	0,27	0,02	5,5	7,0	79	0	11,8	88	86	53	12,1	1,74	1,25
Bt2	6,3	5,5	4,2	2,2	0,06	0,02	6,5	7,0	93	0	5,8	209	210	104	11,4	1,69	1,28
BC	6,1	5,6	3,6	2,8	0,05	0,02	6,5	6,8	96	0	4,5	206	211	103	10,8	1,66	1,26
Argissolo Vermelho-Amarelo Eutrófico abruptico (perfil BHSD 04)																	
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>						
			Areia	Silte	Argila				Ds	Dp							
Ap	0-29	7,5YR3/1	591	226	183	142	22	1,23	1,32	2,60	49						
Bt1	-57	5YR 3/4	227	153	620	0	100	0,25	1,08	2,60	58						
Bt2	-88	5YR 4/4	278	166	556	0	100	0,30	1,33	2,60	49						
CB	-118	7,5YR5/6	324	221	455	0	100	0,49		2,60							
Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						Ataque sulfúrico g/kg				Relações moleculares				
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	V (%)	m (%)	C.O. (g/kg)	SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	SiO <sub>2</sub> / Al <sub>2</sub> O <sub>3</sub> (Ki)	SiO <sub>2</sub> / R <sub>2</sub> O <sub>3</sub> (Kr)
Ap	5,4	4,6	2,6	1,4	0,10	0,01	4,1	7,2	57	2	12,6	79	52	45	19,6	2,58	1,66
Bt1	5,7	4,6	3,8	2,1	0,06	0,12	6,1	9,2	66	2	7,1	227	208	90	14,3	1,86	1,45
Bt2	5,2	3,9	1,4	1,6	0,07	0,13	3,2	8,3	39	33	4,5	214	194	82	11,3	1,88	1,48
CB	5,4	4,0	1,2	2,1	0,09	0,16	3,5	7,9	44	24	3,5	233	204	97	11,1	1,94	1,49

A principal diferença verificada entre os solos desta unidade é a cor, que varia de 5YR a 3,5YR nos Argissolos Vermelho-Amarelos e de 2,5YR para mais vermelho nos Argissolos Vermelhos. A textura varia entre média/muito argilosa e média/argilosa, apresentando gradiente textural muito elevado, com mudança textural abrupta. Conforme já comentado a mudança textural abrupta é uma característica dos solos derivados dos migmatitos e milonitos gnaisses.

Os valores de ADA são muito baixos nos horizontes subsuperficiais, assim como a relação silte/argila, sempre inferior a 0,3 em todos os perfis analisados. Esta é uma tendência bastante generalizada nos Argissolos da BHSD, independente do tipo de material de origem dos solos.

A saturação por bases também é elevada, variando entre 39% (horizonte Bt2 do perfil BHSD 04) e 96% (horizonte BC do perfil BHSD 57). As demais características seguem a tendência verificada nos Argissolos Vermelhos e Vermelho-Amarelos abruptos da unidade M4.

Do mesmo modo como verificado na Unidade São José de Ubá, nas Unidades Vista Alegre, Catalunha, São João do Paraíso e Santo Eduardo, em áreas de relevo suave ondulado foram identificados solos amarelados, classificados como Argissolos Amarelos Eutróficos abruptos ou abruptos câmbicos relacionados com a Unidade M7. Estes apresentam, de maneira geral, as mesmas características dos Argissolos Amarelos da Unidade G8, diferenciando-se destes apenas por apresentarem caráter abrupto. Esta unidade ocupa áreas suavemente onduladas que constituem pequenas elevações isoladas com baixíssima amplitude de relevo, próximo das várzeas. Aqui, a ocorrência de afloramentos de rocha e a distância para estes afloramentos também condiciona a presença ou ausência do caráter câmbico nestes solos. As características físicas e químicas de um perfil representativo destes solos são apresentadas na Tabela 10.

**TABELA 10. Características físicas e químicas dos solos identificados na unidade M7.**

Argissolo Amarelo Eutrófico abruptico (perfil BHSD 68)											
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>
			Areia	Silte	Argila				Ds	Dp	
Ap	0-15	10YR 4/2	568	168	264	142	46	0,64	1,43	2,56	44
BA	-33	7,5YR4/4	392	120	488	427	12	0,25	1,23	2,63	53
Bt1	-62	7,5YR4/6	258	108	634	0	100	0,17	1,23	2,56	52
Bt2	-91	7,5YR5/6	250	116	634	0	100	0,18	1,25	2,63	52
Bt3	-116	7,5YR5/8	275	154	571	0	100	0,27	1,23	2,60	53
Bt4	-160	7,5YR5/8	245	184	571	0	100	0,32	1,25	2,60	52

Horizonte	pH (1:2,5)		Complexo sortivo (cmol/kg)							V (%)	m (%)	C.O. (g/kg)	Ataque sulfúrico g/kg				Relações moleculares	
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T	SiO <sub>2</sub>				Al <sub>2</sub> O <sub>3</sub>	Fe <sub>2</sub> O <sub>3</sub>	TiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	SiO <sub>2</sub> (Ki)	SiO <sub>2</sub> R <sub>2</sub> O <sub>3</sub> (Kr)
	Ap	6,1	5,2	3,3	1,5	0,72	0,02	5,5	8,5	65	0	9,8	-	-	-	-	-	-
BA	5,6	4,8	4,0	1,6	0,24	0,04	5,9	9,1	65	0	7,1	-	-	-	-	-	-	
Bt1	6,2	5,5	4,8	1,5	0,15	0,04	6,5	8,6	76	0	4,5	-	-	-	-	-	-	
Bt2	6,8	5,9	4,5	1,7	0,06	0,05	6,3	7,9	80	0	4,6	-	-	-	-	-	-	
Bt3	6,9	6,1	4,0	2,1	0,09	0,06	6,2	7,7	81	0	2,4	-	-	-	-	-	-	
Bt4	6,9	6,1	3,9	2,5	0,19	0,06	6,6	7,8	85	0	2,3	-	-	-	-	-	-	

### 3.2.3. Sedimentos do Quaternário

Também bastante expressivos na bacia do rio São Domingos são os Sedimentos Aluvionares do Quaternário, que ocorrem exclusivamente ao longo dos córregos que compõem a bacia. Tais sedimentos, formados sob condições de inundação, são compostos por areias e argilas e depósitos de várzea (DRM, 1980). Esses fundos de vales estão delimitados pelo relevo colinoso característico da depressão interplanáltica do norte-noroeste fluminense e foram originados a partir do entulhamento/deposição de sedimentos aluviais provenientes da bacia de drenagem do rio São Domingos (Dantas, 2000), o que, ainda, é verificado atualmente. Na BHSD somente uma unidade, diferenciada com base na declividade, está relacionada com os sedimentos recentes do Quaternário (Tabela 11).

**TABELA 11. Unidade geomorfopedológica relacionada com os Sedimentos do Quaternário.**

Unidades	Elevação (m)	Relevo	Orientação	Plano de curvatura	Classes de solos	Perfis
Q	<200	plano	Independente	Independente	Gleissolo Háptico Ta ou Tb Eutrófico solódico ou típico ou Cambissolo Háptico Ta ou Tb Eutrófico gleico (inclusão de Planossolo Háptico Eutrófico solódico)	BHSD 02, 16, 23, 30, 43, 56 e 61.

Os solos relacionados com os sedimentos do Quaternário foram classificados como Gleissolo Háptico Ta ou Tb Eutrófico solódico ou típico ou Cambissolo Háptico Ta e Tb Eutrófico gleico e Planossolo Háptico Eutrófico solódico, todos ocorrendo em relevo plano. As características físicas e químicas dos perfis representativos destes solos são apresentadas nas Tabelas 12 e 13.

Os Gleissolos apresentam matiz variando de 10YR (maioria) a 2,5Y, indicando um processo pouco intenso de gleização, ainda que estes solos apresentem lençol freático elevado. Os valores da cor situam-se ao redor de 5 e o croma em todos os perfis é 1, indicando uma desferrificação expressiva (Campos et al., 2003). Todos os perfis apresentam mosqueados comuns e abundantes, sugerindo uma boa mobilidade de Fe no sistema.

**TABELA 12. Características físicas e químicas dos Gleissolos identificados na unidade Q.**

<b>Gleissolo Háptico Ta Eutrófico solódico (perfil BHSD 02)</b>												
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>	
			Areia	Silte	Argila				Ds	Dp		
Ap	0-22	10YR 3/1	110	413	477	291	39	0,87	1,19	2,47	52	
Big	-38	10YR 4/1	145	335	520	458	12	0,64	1,42	2,50	43	
Cg	-75	7,5YR 5/1	458	296	246	123	50	1,20	1,28	2,60	51	
Cgn1	-100	2,5Y 5/1	498	236	266	0	100	0,89	1,54	2,63	41	
Horizonte	pH (1:2,5)		Complexo sortivo (cmol/kg)					V (%)	m (%)	C.O. (g/kg)	100.Na <sup>+</sup>	
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S				T	T %
Ap	5,4	4,6	7,9	4,6	0,32	0,27	13,1	17,6	74	0	15,8	2
Big	6,0	4,9	9,4	4,6	0,14	0,44	14,6	17,5	83	0	11,6	3
Cg	6,3	5,1	4,3	3,9	0,07	0,46	8,7	10,0	87	0	2,9	5
Cgn1	6,1	4,8	3,0	4,1	0,07	0,83	8,0	9,3	86	0	2,5	9

Estes solos apresentam textura bastante variada (média, média/argilosa, média/argilosa/muito argilosa, argilosa/muito argilosa/média e argilosa). Tal variação, comum nos solos de várzea, reflete a natureza do material depositado e o tipo de deposição desses sedimentos, mais calmo ou mais agitado.

A saturação por bases nos Gleissolos é sempre elevada, com valores entre 53 e 100%. Além disso, exibem uma CTC elevada, com valores superiores a 30 cmol<sub>c</sub>/kg, sendo caracterizados, portanto, como solos de argila de atividade alta (Tabela 12). A eutrofia destes solos está relacionada com a natureza dos sedimentos depositados, provenientes de áreas adjacentes dominadas por granulitos e migmatitos ricos em

minerais ferromagnesianos, além do fato de serem ambientes concentradores. A elevada CTC, por sua vez, pode ser atribuída a uma massiva neoformação de minerais de argila 2:1 a partir de compostos solúveis liberados pelo intemperismo geoquímico, provenientes dos solos da parte superior das encostas e acumulados nestas áreas (Duchaufour, 1998).

Alguns solos apresentam caráter solódico em profundidade, isto é, saturação por sódio ( $100\text{Na}^+/\text{T}$ ) entre 6 e 15%. A presença deste caráter nos Gleissolos é proveniente do acúmulo do  $\text{Na}^+$  liberado, principalmente pelo intemperismo dos plagioclásios, comuns nos granulitos e migmatitos. Além do mais, este é um ambiente conservador, já que os córregos têm uma vazão muito limitada, o que dificulta a remoção deste cátion para fora do sistema. A separação dos Gleissolos solódicos dos não solódicos (típicos) através da utilização de algum atributo do terreno é bastante limitada, visto que a ocorrência deste caráter parece ser aleatória, não obedecendo a nenhuma tendência observável.

Os Cambissolos ocorrem exclusivamente em áreas com declividade levemente superior a dos Gleissolos em uma posição intermediária entre estes e os solos que ocupam o terço inferior das encostas. Esta posição na paisagem levemente mais elevada foi suficiente para permitir a formação de horizonte B incipiente acima da zona de flutuação do lençol freático. Porém, dentro desta zona, estão presentes horizontes gleizados, em decorrência do regime de umidade redutor; daí os solos desta unidade serem classificados como Cambissolos Háplicos Ta Eutróficos gleicos (Tabela 13).

Estes solos apresentam cor nos matizes 7,5YR e 10YR no horizonte Bi, e 10YR e 2,5Y nos horizontes gleizados. Estes últimos apresentando cromas inferiores a 1, indicando uma desferrificação expressiva em função da flutuação do lençol freático, além do que, apresentam mosqueados comuns e abundantes. A textura é média e média/argilosa, sem gradiente textural elevado.



**TABELA 13. Características físicas e químicas dos Cambissolos da unidade Q.**

Cambissolo Háptico Ta Eutrófico gleico (perfil BHSD 30)												
Horizonte	Prof. (cm)	Cor úmida	Textura (g/kg)			ADA g/kg	GF %	silte/ argila	Densidade g/cm <sup>3</sup>		Porosidade cm <sup>3</sup> /100cm <sup>3</sup>	
			Areia	Silte	Argila				Ds	Dp		
Ap	0-14	10YR 3/1	662	136	202	142	30	0,67	1,42	2,56	45	
A2	-30	10YR 4/1	640	158	202	162	20	0,78	1,41	2,53	44	
Bi	-54	7,5YR 3,5/4	621	135	244	183	25	0,55	1,34	2,56	48	
C1g	-84	7,5YR 3/4	622	134	244	163	33	0,55	1,39	2,56	46	
C2g	-133	7,5YR 3/4	612	145	243	61	75	0,60	1,42	2,56	45	
C3g	-160	7,5YR 4/4	651	126	223	61	73	0,56	1,46	2,53	42	

Horizonte	pH (1:2,5)		Complexo sortivo (cmol <sub>c</sub> /kg)						V (%)	m (%)	C.O. (g/kg)	100.Na <sup>+</sup> T %
	H <sub>2</sub> O	KCl	Ca <sup>2+</sup>	Mg <sup>2+</sup>	K <sup>+</sup>	Na <sup>+</sup>	S	T				
Ap	6,6	5,7	3,8	1,4	1,48	0,02	6,7	7,7	87	0	8,5	<1
A2	6,5	5,9	4,4	1,7	0,59	0,04	6,7	8,2	82	0	8,6	<1
Bi	5,9	5,1	4,1	1,6	0,14	0,09	5,9	7,7	77	0	4,5	1
C1g	6,5	5,4	4,9	1,4	0,06	0,10	6,5	7,8	83	0	3,4	1
C2g	6,5	5,4	4,0	1,5	0,05	0,11	5,7	6,9	83	0	2,6	2
C3g	6,4	5,3	3,2	1,4	0,04	0,10	4,7	5,9	80	0	2,2	2

Da mesma maneira como nos Gleissolos, a saturação por bases é alta, sendo todos eutróficos. Alguns destes solos apresentam argila de atividade alta (Tabela 13) e

que permitiram o delineamento de segmentos da paisagem, que por sua vez, foram utilizados como base para a definição de um padrão de amostragem otimizado, fundamental para explicar as relações existentes entre os solos, as diferentes litologias e os atributos do terreno utilizados. Os resultados mostraram claramente a importância da combinação entre estes temas, não sendo esta apenas uma sobreposição de informações em um SIG, pois acima de tudo requer a formulação de uma hipótese pedogenética.

A forte influência do material de origem e dos atributos do terreno é bem conhecida na literatura e foi confirmada neste estudo. Além da litologia, os atributos do terreno que afetam mais significativamente a distribuição dos solos na paisagem são: elevação, declividade, orientação da encosta (aspecto), curvatura e posição na encosta.

O tipo de material de origem do solo, além de influenciar características importantes como textura, saturação por bases, CTC, entre outras, teve influência marcante na ausência ou presença de mudança textural abrupta nos solos da BHSD, sendo esta a principal diferença entre os Argissolos derivados de granulitos (sem mudança textural abrupta) dos Argissolos derivados dos migmatitos e dos milonitos gnáisses (com mudança textural abrupta).

A curvatura do terreno que controla o fluxo superficial de água no solo é o principal fator que determina diferenças no grau de evolução dos solos da BHSD. Nas encostas côncavas foram identificados solos com horizonte B textural (Argissolos câmbicos), horizonte B incipiente (Cambissolos) ou sem horizonte B diagnóstico (Neossolos Litólicos), enquanto nas encostas convexas são encontrados solos mais evoluídos com horizonte B textural, B nítico e B latossólico em profundidade.

Variações microclimáticas condicionadas pela orientação das encostas foram determinantes na diferenciação dos solos nas encostas convexas, tanto nos solos derivados de granulitos quanto naqueles derivados dos migmatitos e milonitos gnáisses.

Nos granulitos noríticos, os solos das encostas noroeste e nordeste apresentam cor avermelhada, são eutróficos e não apresentam horizonte B latossólico em profundidade (Argissolo Vermelho Eutrófico típico). Nas encostas voltadas para sudeste, que recebem menor radiação solar, os solos são de cor vermelho-amarelada, distróficos e apresentam horizonte B latossólico em profundidade (Argissolo Vermelho-Amarelo Distrófico latossólico). Nas encostas sudeste, que recebem radiação solar

intermediária, os solos são de coloração vermelho-amarelada, porém são eutróficos e não apresentam horizonte B latossólico em profundidade (Argissolo Vermelho-Amarelo Eutrófico típico).

Nos solos derivados dos migmatitos e milonitos gnaisses a única diferença encontrada é a presença de horizonte B latossólico em profundidade nas encostas voltadas para sudeste (Argissolo Vermelho Eutrófico abruptico latossólico). Entretanto, a cor e saturação por bases não diferiram em função da orientação das encostas.

As áreas de relevo ondulado e suave ondulado não sofreram influência da curvatura e da orientação da encosta, sendo os solos condicionados apenas pelo tipo e profundidade de ocorrência do material de origem. Assim, são encontrados Argissolos típicos e Argissolos câmbicos derivados de granulitos e, Argissolos abrupticos e abrupticos câmbicos derivados de migmatitos e milonitos gnaisses, além de Afloramentos de rocha.

Nas áreas dos Sedimentos do Quaternário foram identificados Gleissolos e Cambissolos gleicos, mais freqüentemente apresentando argila de atividade alta. A ocorrência de solos Ta nestas áreas se deve, principalmente, à neoformação de minerais de argila 2:1 a partir de compostos solúveis liberados pelo intemperismo geoquímico, provenientes dos solos da parte superior das encostas.

## 5. LITERATURA CITADA

ALEXANDER, E. B. Morphology, fertility and classification of productive soils on serpentized peridotite in California (USA). **Geoderma**, v.41, p.337-351, 1988.

BELL, J. C.; CUNNINGHAM, R .L. & HAVENS, M. W. Soil drainage class probability mapping using a soil-landscape model. **Soil Science Society of America Journal**, v.58, p.464-470, 1994.

BIGHAM, J. M. et al. Iron oxide mineralogy of well drained Ultisols and Oxisols: II. Influence on color, surface area, and phosphate retention. **Soil Science Society of American Journal**, v.42, p.825-830, 1978.

BIRKELAND, P. W. **Soils and geomorphology**. New York: Oxford University Press, 1984. 430p.

BLAKE, G. R. & HARTGE, K. H. Bulk density. In: KLUTE, A. (Ed.). **Methods of soil analysis**. Madison: American Society of Agronomy, 1986. v.1, p.363-375.

BRASIL. Ministério de Minas e Energia. Secretaria-Geral. Projeto RADAMBRASIL. **Folha SF. 23/24 Rio de Janeiro**; geologia, geomorfologia, pedologia, vegetação e uso potencial da terra. Rio de Janeiro, 1983. 780p.

BRUS, D. J. & De GRUIJTER, J. J. Random sampling or geostatistical modelling? Choosing between design-based and model-based sampling strategies for soil. **Geoderma**, v.80, p.1-59, 1997.

CAMPOS, C. E. B. et al. Indicadores de campo para solos hidromórficos na região de viçosa (MG). **Revista Brasileira de Ciência do Solo**, v.27, p.1057-1066, 2003.

CHAPLOT, V.; WALTER, C. & CURMI, P. Modeling soil spatial distribution: sensitivity to DEM resolutions and pedological data availability. In: **World Congress of Soil Science**, 16., 1998, Montpellier, France. **Proceedings ... Montpellier: IUSS**, 1998. 1 CD-ROM.

CURI, N. & FRANZMEIER, D. P. Toposequence of oxisols from the Central Plateau of Brazil. **Soil Science Society of American Journal**, v.48, p.341-346, 1984.

DANTAS, M. E. **Geomorfologia do Estado do Rio de Janeiro**. Brasília: CPRM, 2000. 1CD-ROM.

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.

DIKAU, R. The application of a digital relief model to landform analysis in geomorphology. In: RAPER, J. (Ed.). **Three dimensional applications in geographic information systems**. New York: Taylor and Francis, 1989. p.51-77.

DUBAYAH, R. & RICH, P. M. Topographic solar radiation models for GIS. **International Journal of Geographic Information Systems**, v.9, p.405-413, 1995.

DUCHAUFOR, P. **Handbook of pedology: soils, vegetation and environment**. Brookfield: Balkema Publishers, 1998. 264p.

EMBRAPA. Centro Nacional de Pesquisa de Solos. **Levantamento de reconhecimento de baixa intensidade dos solos do Estado do Rio de Janeiro**. Rio de Janeiro: Embrapa Solos, 2003. 182p. (Embrapa Solos. Boletim de Pesquisa e Desenvolvimento, 32).

EMBRAPA. Centro Nacional de Pesquisa de Solos. **Manual de métodos de análise do solo**. 2. ed. rev. e atual. Rio de Janeiro: EMBRAPA-CNPS, 1997. 212p. (EMBRAPA-CNPS. Documentos, 1).

EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação de Solos**. Brasília: Embrapa Produção de Informação; Rio de Janeiro: Embrapa Solos, 1999. 412 p.

ENVIRONMENTAL SYSTEM RESEARCH INSTITUTE. ESRI. **ARC/INFO v. 7.1.1. Redlands**, 1997. Programa de computador. 2 CD-ROM.

ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE - ESRI. **ArcView GIS**. The Geographic Information System for everyone. New York, 1996.

ESTADOS UNIDOS. Department of Agriculture. Soil Survey Division. Soil Conservation Service. Soil Survey Staff. **Soil survey manual**: revised. Washington: Enlarg. Ed., 1993. 437p. (USDA. Agriculture handbook, 18).

FINNEY, H. R.; HOLOWAYCHUK, N. & HEDDLESON, M. R. The influence of microclimate on the morphology of certain soils of the Allegheny plateau of Ohio. **Soil Science Society of American Proceedings**, v.26, p.287-292, 1962.

FLORINSKY, I. & KURYAKOVA, G. Determination of grid size for digital terrain models in soil investigations. In: World Congress of Soil Science, 16., 1998, Montpellier, France. **Proceedings ... Montpellier**: IUSS, 1998. 1 CD-ROM.

FU, P. & RICH, P. M. Design and Implementation of the Solar Analyst: An ArcView Extension for Modeling Solar Radiation at Landscape Scales. **ESRI International User Conference Proceedings**. San Diego, California: ESRI, July 26-30, 1999.

GALLANT, J. C. & WILSON, J. P. Primary topographic attributes. In: WILSON, J. P. & GALLANT, J. C. (Eds.). **Terrain Analysis: Principles and applications**. New York: John Wiley & Sons, 2000. p.51-85.

GERRARD, A. J. **Soils and landforms**: an integration of Geomorphology and pedology. London: George Allen & Unwin Publishers, 1981. 219p.

GESSLER, P. E. et al. Modeling soil-landscape and ecosystem properties using terrain attributes. **Soil Science Society of American Journal**, v.64, p.2046-2056, 2000.

GESSLER, P. E. et al. Soil landscape modelling and spatial prediction of soil attributes. **International Journal of Geographic Information System**, v.9, p.421- 432, 1995.

GROSSMAN, R. B. Entisols. In: WILDING, L. P.; SMECK, N. E. & HALL, G. F. (Eds.). Pedogenesis and soil taxonomy. II. The soil orders. **Developments in soil science**. New York: Elsevier, 1983. v.11b, p.55-86.

HALL, G. F. & OLSON, C. G. Predicting variability of soils from landscape models. In: MAUSBACH, M. J. & WILDING, L. P. (Eds.). **Spatial variabilities of soils and landforms**. Madison, Wisconsin: Soil Science Society of America, 1991. p.9-24. (SSSA Special Publication; n° 28)

HALL, G. F. Pedology and geomorphology. In: WILDING, L. P.; SMECK, N. E. & HALL, G. F. (Eds.). Pedogenesis and soil taxonomy. II. The soil orders. **Developments in soil science**. New York: Elsevier, 1983. v.11b, p.118-140.

HELIOS ENVIRONMENTAL MODELING INSTITUTE. HEMI. The Solar Analyst 1.0: User Manual, 2000. Disponível em: <<http://www.hemisoft.com>>. Acesso em: 12 abr. 2006.

HENGL, T. & ROSSITER, D. G. Supervised landform classification to enhance and replace photo-interpretation in semi-detailed soil survey. **Soil Science Society of American Journal**, v.67, p.1810-1822, 2003.

HENGL, T.; GRUBER, S. & SHRESTHA, D. P. Reduction of errors in digital terrain parameters used in soil-landscape modelling. **International Journal of Applied Earth Observation and Geoinformation**, v.5, p.97-112, 2004.

HUDSON, B. D. The soil survey as a paradigm-based science. **Soil Science Society of America Journal**, v.56, p.836-841, 1992.

HUTCHINSON, M. F. A locally adaptive approach to the interpolation of digital elevation models. In: INTERNATIONAL CONFERENCE/WORKSHOP ON INTEGRATING GIS AND ENVIRONMENTAL MODELING, 1996, Santa Barbara. **Proceedings...** Santa Barbara: National Center for Geographic Information and Analysis, University of California, 1996. 1 CD-ROM.

HUTCHINSON, M. F. Development of a continent-wide DEM with applications to terrain and climate analysis. In: GOODCHILD, M. F. (Ed.). **Environmental Modeling with GIS**. New York: Oxford University Press, 1993. p.392-399.

IBRAIMO, M. M.; SCHAEFER, C. E. G. R.; KER, J. C.; LANI, J. L.; ROLIM-NETO, F. C.; ALBUQUERQUE, M. A. & MIRANDA, V. J. Gênese e micromorfologia de solos sob vegetação xeromórfica (caatinga) na região dos Lagos (RJ). *Revista Brasileira de Ciência do Solo*, v.28, p.695-712, 2004.

JENNY, H. **Factors of soil formation; a system of quantitative pedology**

KLINGEBIEL, A. A. et al. Use of slope, aspect, and elevation maps derived from digital elevation model data in making soil surveys. In: REYBOLD, W. U. & PETERSEN, G. W. **Soil survey techniques**. Madison, Wisconsin: Soil Science Society of America, 1987. p.77-90. (SSSA Special Publication; n° 20)

LOTSPEICH, F. B. & SMITH, H. W. Soils of the Palouse loess: I. The Palouse Catena. **Soil Science**, v.76, p.467-480, 1953.

MARK, D. M. Geomorphometric parameters: a review and classification, **Geografiska Annaler**, v.57, p.165-177, 1975.

McBRATNEY, A. B. et al. An overview of pedometric techniques for use in soil survey. **Geoderma**, v.97, p.293-327, 2000.

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

McSWEENEY, K. et al. Towards a new framework for modeling the soil-landscape continuum. In: AMUNDSEN, R. G.; HARDEN, J. & SINGER, M. (Eds.). **Factors of soil formation: a fiftieth anniversary perspective**. Madison, Wisconsin: Soil Science Society of America, 1994. p.127-145. (SSSA Special Publication; n° 33)

MITASOVA, H. & HOFIERKA, J. Interpolation by Regularized Spline with Tension: II. Application to Terrain Modeling and Surface Geometry Analysis. **Mathematical Geology**, v.25, p.657-671, 1993.

MOORE, I. D. et al. Soil attribute prediction using terrain analysis. **Soil Science Society of America Journal**, v.57, p.443-452, 1993.

NUNES, W. A. G. A. et al. Relação solo-paisagem-material de origem e gênese de alguns solos no domínio do “mar de morros”, Minas Gerais. **Revista Brasileira de Ciência do Solo**, v.25, p.341-354, 2001.

ODEH, I. O. A.; CHITTLEBOROUGH, D. J. & McBRATNEY, A. B. Elucidation of soil-landform interrelationships by canonical ordination analysis. **Geoderma**, v.49, p.1-32, 1991.

ODEH, I. O. A.; McBRATNEY, A. B. & CHITTLEBOROUGH, D. J. Spatial prediction of soil properties from landform attributes derived from a digital elevation model. **Geoderma**, v.63, p.197-214, 1994.

PENNOCK, D. J.; ZEBARTH, B. J. & DE JONG, E. Landform classification and soil distribution in hummocky terrain, Saskatchewan, Canada. **Geoderma**, v.40, p.297-315, 1987.

PETERSEN, G. W.; NIELSEN, G. A. & WILDING, L. P. Geographic information system and remote sensing in land resource analysis and management. **Suelo y Planta**, v.1, p.531-543, 1991.

PHILLIPS, D. H. et al. Soil-landscape relationships at the lower reaches of a watershed at Bear Creek near Oak Ridge, Tennessee. **Catena**, v.44, p.205-222, 2001.

PINTO, L. F. S. & KÄMPF, N. Solos derivados de rochas ultrabásicas no ambiente subtropical do Rio Grande do Sul. **Revista Brasileira de Ciência do Solo**, v.20, p.447-458, 1996.

SCHWERTMANN, U. & KÄMPF, N. Properties of goethite and hematite in kaolinitic soils of Southern and Central Brazil. **Soil Science**, v.139, p.344-350, 1985.

SHARY, P. A.; SHARAYAB, L. S. & MITUSOV, A. V. Fundamental quantitative methods of land surface analysis. **Geoderma**, v.107, p.1-32, 2002.

TARDY, Y. & NAHON, D. Geochemistry of laterites, stability of Al-goethite, Al-hematite, and Fe<sup>3+</sup>-kaolinite in bauxites and ferricretes: an approach to the mechanism of concretion formation. **American Journal of Science**, v.285, p.865-903, 1985.

THOMAS, A. L. et al. Predicting soil classes with parameters derived from relief and geologic materials in a sandstone region of the Vosges Mountains (Northeastern France). **Geoderma**, v.90, p.291-305, 1999.

TROEH, F. R. Landform parameters correlated to soil drainage. **Soil Science Society of America Proceedings**, v.28, p.808-812, 1964.

WALKER, P. H.; HALL, G. F. & PROTZ, R. Relation between landform parameters and soil properties. **Soil Science Society of America Proceedings**, v.32, p.101-104, 1968.

WILSON, J. P. & GALLANT, J. C. Digital terrain analysis. In: WILSON, J. P. & GALLANT, J. C. (eds.). **Terrain analysis: principles and applications**. New York: John Wiley & Sons, 2000. p. 1-27.

ZHU, A. X. et al. Soil mapping using GIS, expert knowledge, and fuzzy logic. **Soil Science Society American Journal**, v.65, p.1463-1472, 2001.



## **CAPÍTULO 4**

### **UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS PARA PREDIÇÃO DAS CLASSES DE SOLOS EM UMA REGIÃO DO DOMÍNIO DE MAR DE MORROS E ALINHAMENTOS SERRANOS NO NOROESTE DO ESTADO DO RIO DE JANEIRO**

#### **RESUMO**

O levantamento de solos no Brasil, produzido pelo método convencional, é a principal fonte de informação espacial sobre solos para diferentes usos, principalmente o uso agrícola. No entanto, a continuidade desta atividade tem sido grandemente comprometida pela falta de recursos financeiros e pela falta de pedólogos experientes. Para tentar contornar este problema e tornar o levantamento de solos uma atividade mais científica foi realizada neste estudo uma avaliação da utilização de redes neurais para a predição de classes de solos em uma região do Domínio de mar de morros e alinhamentos serranos no Noroeste Fluminense. Esta abordagem, baseada no clássico conceito solo-paisagem, utilizou nove variáveis ambientais discriminantes: geologia, elevação, declividade, aspecto, plano de curvatura, índice de umidade (CTI) e três índices derivados de uma imagem do sensor ETM<sup>+</sup> do LANDSAT 7, que foram combinadas e avaliadas quanto à capacidade de discriminação das classes de solo. O simulador de redes neurais utilizado foi o “Java Neural Network Simulator” baseado no Stuttgart Neural Network Simulator 4.2 Kernel e o algoritmo de aprendizado foi o “backpropagation”. Adicionalmente, foi realizada uma classificação utilizando o algoritmo de máxima verossimilhança (MAXVER). Uma vez, treinadas e validadas, as redes neurais, juntamente com o algoritmo MAXVER, foram utilizadas para a predição das classes de solo da área estudada. Dentre os conjuntos de variáveis ambientais testados os melhores resultados, para classificação pelas redes neurais, foram obtidos quando foram utilizadas todas as variáveis (atributos do terreno e índices do sensor ETM<sup>+</sup> do LANDSAT 7), tanto para a Área 1 (granulitos da Unidade São José de Ubá) quanto para a Área 2 (migmatitos e milonitos gnáisses das Unidades Vista Alegre, São João do Paraíso, Catalunha e Santo Eduardo). Na classificação pelo MAXVER o melhor desempenho para a Área 1 foi obtido quando foram utilizadas todas as variáveis

ambientais e para a Área 2 utilizando-se somente os atributos do terreno. De acordo com os testes estatísticos realizados o classificador baseado nas redes neurais produziu uma maior exatidão do que o classificador clássico da máxima verossimilhança. Os mapas produzidos pelos classificadores tiveram uma baixa concordância entre si, assim como com o mapa convencional. As principais causas destas discordâncias foram: limitação de escala do mapa convencional; dificuldade e inexatidão dos limites das unidades de mapeamento do mapa convencional; heterogeneidade geológica da área; profundidade do contato lítico e/ou exposição da rocha; e problemas com o modelo de correlação ambiental utilizado. A comparação com pontos de observação coletados no campo mostrou que o mapa produzido pela abordagem por redes neurais teve um desempenho superior (70,83% de concordância) aos mapas produzidos pela abordagem convencional (52,77%) e pelo classificador MAXVER (50,69%). O presente estudo mostrou que a utilização dos atributos do terreno e dos dados de sensores remotos em uma abordagem por redes neurais pode contribuir grandemente para tornar o mapeamento de solos no Brasil mais quantitativo e confiável, principalmente em função da disponibilidade de dados de sensores remotos a custos mais baixos e da facilidade de obtenção dos atributos do terreno em um SIG comercial.

**Palavras-chave:** Levantamento de solos; redes neurais; MAXVER.

## SUMMARY

Soils surveys in Brazil by conventional methods are the main source of soil spatial information to different users, mainly for agricultural purposes. However, this activity has been seriously constrained by funding shortage and lack of trained pedologists. In order to solve this problem, aiming to make soil survey a more scientific activity, the present study used a neural network evaluation to predict soil classes in a highly dissect mountain region in the northwest of Rio de Janeiro state. This approach, based on the soil-landscape classic concept, used nine basic environmental variables in combination: geology, elevation, slope, aspect, plan curvature, CTI index and three indices derived from an LANDSAT 7 image, assessing the capacity for soil classes identification. The “Neural Java Network Simulator” based on the Neural Stuttgart Network Simulator 4,2 Kernel was used, with the learning algorithm of backpropagation. Additionally, the maximum likelihood algorithm (MAXVER) was also used to make the classification. The neural network was trained and validated, together with the MAXVER algorithm, using for soil classes prediction. Among the environmental data sets tested, the best results for neural network classification, was accomplished using all variables (terrain attributes and LANDSAT 7 indexes), in both Area 1 (granulites of São Jose de Uba unit) and Area 2 (migmatites and milonites gneisses of Vista Alegre, Sao João do Paraiso, Catalunha and Santo Eduardo units). For the MAXVER classification Area 1 best performance was attained using all environmental variables, whereas Area 2 only the terrain attributes. According to the statistical tests carried out, the neural network classifier produced a greater accuracy than the MAXVER. The maps produced by the classifiers and conventional mapping show low agreement. The main causes for the discrepancies were: conventional map scale limitation; low accuracy of the limits in conventional map units; geologic heterogeneity of the area; depth of the parent material contact; and problems with the environmental correlation model used. The comparison with control points sampled showed that the map produced by the neural network approach had a higher performance (70.83% of agreement) compared with maps produced by conventional approach (52.77%) and by the MAXVER (50.69%). The present study showed that the use of terrain attributes and the remote sensing data by neural network simulator can greatly contribute to soil mapping in Brazil, allowing a greater reliability quantitative

analysis. This is particularly applied at the present, due to availability of remote sensing data at low cost and the easiness to obtain terrain attributes using commercial SIGs.

**Keywords:** soil survey; neural networks, maximum likelihood.

## 1. INTRODUÇÃO

O sistema nervoso é composto por células altamente diferenciadas denominadas neurônios, que possuem a habilidade de receber informações de seu próprio corpo celular ou do ambiente externo, integrando a informação e transmitindo-a para outras células. Cada neurônio possui um corpo celular, dentro do qual se encontra a maioria dos seus orgânulos. Do corpo celular de cada neurônio partem prolongamentos que podem ser funcionalmente divididos em dendritos e axônios (Wasserman, 1989).

Baseados no paradigma biológico, pesquisadores desenvolveram modelos de redes neurais artificiais para servir como ferramenta de apoio à tomada de decisão. Assim, a rede neural artificial tenta construir um modelo matemático que supostamente trabalha de maneira análoga ao cérebro humano. Já há algum tempo tem sido reconhecido que uma abordagem matemática baseada nas ações dos neurônios biológicos pode ser implementada para processar e interpretar muitos tipos diferentes de dados digitais. Enquanto não é possível ou desejável reproduzir a complexidade do cérebro humano em um computador, as redes neurais artificiais, que são baseadas na arquitetura de elementos processadores simples como os neurônios, estão sendo usadas com sucesso para uma variedade de aplicações (Atkinson & Tatnall, 1997).

Redes neurais são uma técnica de inteligência artificial e, conseqüentemente, vêm da mesma família dos sistemas especialistas e abordagens baseadas em conhecimento para aprendizagem (Key et al., 1989). Entretanto, enquanto os sistemas especialistas são baseados na representação simbólica do conhecimento e, conseqüentemente, incorporam dados qualitativos na estimativa, através da programação *a priori* do algoritmo de aprendizagem, as redes neurais empregam uma abordagem conexionista (Hepner et al., 1990).

Atkinson & Tatnall (1997) destacam que o rápido crescimento na utilização de redes neurais, principalmente no que diz respeito ao sensoriamento remoto deve-se a: *a*) sua maior precisão quando comparada a outras técnicas como classificadores estatísticos, particularmente quando as feições não são linearmente separáveis e/ou as classes informacionais têm distribuições estatísticas diferentes da assumida (Benediktsson et al., 1990; 1993; Schalkoff, 1992); *b*) sua maior rapidez depois de

treinada (Côte & Tatnall, 1995); *c*) sua habilidade para incorporar um conhecimento a priori e limitações físicas realísticas na análise; *d*) sua habilidade para incorporar diferentes tipos de dados, facilitando os estudos sinérgicos (Benediktsson et al., 1993; Benediktsson & Sveinsson, 1997), e *e*) sua maior capacidade de generalizar, isto é, apresentar bons resultados para padrões não usados durante o treinamento (Vieira, 2000).

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 o uso de redes neurais para a classificação de dados de sensoriamento remoto e dados geográficos são que as redes neurais são independentes do tipo de distribuição, diferentemente da abordagem estatística paramétrica tradicional, que assume que os dados possuem uma distribuição normal; e habilidade para manipular dados adquiridos a diferentes níveis de precisão e ruídos. Visto que os dados de diferentes fontes são em geral de diferentes origens (nominais, numéricos, entre outros), e realmente podem ter distribuições estatísticas diferentes (Peddle et al., 1994; Atkinson & Tatnall, 1997; Benediktsson & Sveinsson, 1997).

Uma rede neural é composta por um elevado número de elementos processadores ou unidades de processamento, conectados entre si. Cada uma das conexões interliga somente dois elementos processadores, geralmente em um único sentido, e possui um valor que determina o grau de conectividade entre estes, denominado peso da conexão. Frequentemente, uma camada de entrada está ligada a uma camada de saída, via uma ou mais camadas internas (Schalkoff, 1992; Atkinson & Tatnall, 1997).

Segundo Master (1993), a estrutura de uma rede neural, ou seja, o número de camadas e o número de neurônios em cada camada são específicos para cada caso. Para a maioria dos problemas um modelo de três camadas deve ser suficiente, a menos que o problema seja altamente complexo. O número de neurônios na camada de entrada deve ser igual ao número de variáveis discriminantes usadas para uma aplicação específica e o número de neurônios na camada de saída igual ao número de classes informacionais. O número de neurônios da camada interna (ou escondida) depende da complexidade do problema. Quanto mais simples é o problema, menos neurônios na camada interna são necessários para a convergência da rede. O número exato de camadas internas e o

número de neurônios por camada para um determinado problema é freqüentemente determinado experimentalmente através de tentativas e erros.

Normalmente, são necessárias três fases na aplicação de redes neurais para resolução de um determinado problema. Na primeira fase, ou treinamento, ensina-se a rede a resolver um conjunto de padrões de saída associados aos padrões de entrada. Na segunda fase, ou teste, são apresentados padrões de entrada à rede, e as saídas obtidas são comparadas às saídas desejadas. Na terceira fase, ou aplicação, a rede aprovada na fase anterior é utilizada na resolução do problema. A primeira fase é a única em que há aprendizado, e o processo como um todo pode repetir-se até que a rede obtenha resultados satisfatórios, ou seja, até convergir para valores de erros aceitáveis pelo especialista (Master, 1993).

Nas últimas décadas, as redes neurais têm experimentado uma explosão de interesse e têm sido aplicadas com sucesso em várias áreas da ciência, tais como: reconhecimento de padrões de imagens de satélite, medicina, biologia molecular e, mais recentemente, ciências ecológicas e ambientais. Algumas recentes utilizações das redes neurais nas ciências ambientais são os modelos para a estimativa da distribuição de espécies, abundância ou diversidade em função de variáveis ambientais, danos em cultivos agrícolas, riscos de enchentes, parâmetros de qualidade do ar e características de ecossistemas a partir de dados de sensoriamento remoto (Mas et al., 2004).

Com relação ao sensoriamento remoto, onde as redes têm uma ampla possibilidade de aplicação, grande atenção tem sido dada ao reconhecimento de padrões (Liu & Xiao, 1991; Chen et al., 1995). Neste sentido, 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). Vários estudos (Benediktsson et al., 1990; Peddle et al., 1994; Key et al., 1989) têm comprovado a grande vantagem das redes neurais em trabalhar com dados de diferentes fontes para uma mesma classificação ou estimativa.

Yang et al. (1998) examinaram os efeitos da utilização de diferentes imagens sobre o desempenho de uma rede neural no mapeamento litológico de uma área no Canadá. Os resultados encontrados mostram que os dados geofísicos, particularmente medidas de radiação, que fornecem informações subsuperficiais, foram essenciais para o

mapeamento preciso da litologia. A reflectância na região espectral do infravermelho médio foi a medida de sensoriamento remoto mais relevante.

As redes neurais estão sendo amplamente utilizadas na ciência do solo, principalmente para estimativa de atributos do solo. A aplicação como função de pedotransferência para estimativa de propriedades hidráulicas do solo tem sido a mais comum (McBratney et al., 2003). Esta aplicação pode ser encontrada em muitos estudos, tal como, em Minasny & McBratney (2002). Chang & Islam (2000) exploraram a possibilidade de estimativa de propriedades físicas do solo (textura) a partir de mapas de temperatura obtidos por sensoriamento remoto multitemporal e mapas de umidade do solo usando redes neurais.

Daniel et al. (2003) implementaram uma rede neural para estimar a matéria orgânica do solo, fósforo e potássio, a partir da análise de reflectância de 41 amostras de solo da província de Lop Buri na Tailândia. A rede foi treinada utilizando-se 7 bandas, nas regiões do visível e infravermelho próximo (400-1100 nm), derivadas de um espectrorradiômetro de laboratório e um fotômetro (Nikon, modelo 2703) (in situ). Os resultados obtidos confirmaram a capacidade da rede neural para estimar macronutrientes no solo pela eliminação das dificuldades provenientes das elevadas correlações entre bandas espectrais prevalentes nas técnicas estatísticas convencionais.

Lee et al. (2004) avaliaram a utilização de métodos de probabilidade (regressão) e redes neurais artificiais na estimativa de suscetibilidade de deslizamento de terra em uma região da Coreia. A localização dos deslizamentos de terra e fatores relacionados aos deslizamentos, tais como: declividade, curvatura, textura do solo, drenagem do solo, espessura efetiva, tipo de vegetação arbórea e diâmetro do caule foram usados para analisar a suscetibilidade de deslizamento. Um método de probabilidade foi usado para calcular a taxa de importância relativa de cada fator à ocorrência de deslizamentos. Para isto, uma rede neural foi desenvolvida. Desta maneira, foi calculado o índice de suscetibilidade ao deslizamento usando a taxa e o peso estimado, e foi produzido um mapa de suscetibilidade ao deslizamento utilizando este índice. Os resultados da análise de suscetibilidade ao deslizamento, com e sem os pesos, foram confirmados pela comparação com os dados de localização de deslizamentos.



Licznar & Nearing (2003) investigaram a aplicabilidade do uso de redes neurais para estimar quantitativamente a perda de solo em parcelas de escoamento natural. Dados de 2879 eventos de erosão de oito locais nos Estados Unidos foram utilizados. Os resultados indicaram que as redes neurais funcionaram geralmente melhor do que o modelo de predição de erosão da água (WEPP) na estimativa do volume de escoamento superficial e da quantidade de solo perdida. Os coeficientes de correlação linear ( $r$ ) para os resultados obtidos pelas redes neurais versus valores medidos variaram de 0,7 a 0,9. As redes que estimaram o escoamento superficial e a perda de solo individualmente tiveram rendimento menor do que as redes que estimaram juntas estas variáveis. O tipo de função de transferência e o número de neurônios usados na estrutura da rede não fizeram diferença na qualidade dos resultados. Os resultados deste estudo sugerem a possibilidade do uso de redes neurais para estimar a erosão do solo pela água ao nível de parcela para locais com suficientes dados de monitoramento de erosão.

Brown et al. (1998) testaram a habilidade de medidas geomórficas (elevação, relevo relativo, enrugamento superficial e declividade) derivadas de um modelo digital de elevação para diferenciar paisagens glaciais em Michigan, usando o classificador de máxima verossimilhança e redes neurais artificiais. Os métodos automatizados foram treinados e validados usando um mapa geológico existente e uma interpretação manual das curvas de nível retratadas em uma carta topográfica. Os métodos tradicionais para identificação das diferentes paisagens têm sido baseados em mapas topográficos e têm sido muito efetivos, porém consomem muito tempo. Os mapas resultantes de quatro tentativas de classificação supervisionada tiveram entre 51% e 61% de concordância com o mapa geológico. O resultado do classificador de máxima verossimilhança teve concordância levemente mais alta do que o da rede neural, o que foi atribuído à inerente generalização no mapa geológico comparado com a natureza do classificador para a rede neural. Esta, entretanto, identificou detalhes significantes e relações não-lineares entre os dados de entrada e as classes resultantes.

Medidas diretas de propriedades hidráulicas do solo consomem muito tempo, apresentam custo elevado e algumas vezes não são confiáveis devido à grande heterogeneidade do solo e aos erros experimentais. Por outro lado, estas propriedades podem ser estimadas a partir de dados como textura e densidade do solo, utilizando funções de pedotransferência (PTFs). Assim, Schaap & Leij (1998) utilizaram uma rede

neural como função de pedotransferência para prever a retenção de água do solo e propriedades hidráulicas do solo saturado e não saturado de um conjunto limitado de propriedades do solo. Neste estudo, de maneira geral, a exatidão da predição aumentou à medida que mais dados de entrada eram utilizados, mas houve sempre uma considerável diferença entre as predições e os dados medidos.

Fidêncio et al. (2001) utilizaram dois tipos de redes neurais (“*counterpropagation neural network* - CPANN” e “*radial basis function network* - RBFN”) para classificar amostras de Latossolos e Argissolos de diferentes regiões geográficas do Estado de São Paulo, através do significado de seus espectros na região do infravermelho próximo (reflectância difusa). Segundo os autores, os resultados obtidos foram melhores quando se utilizou a CPANN, com um erro de classificação de 8,6%, do que quando se utilizou a RBFN, cujo erro de classificação foi de 11%.

Uma abordagem por rede neural 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. 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 são escassos na literatura mundial. No Brasil, nenhum outro registro foi encontrado além do trabalho de Fidêncio et al. (2001), citado anteriormente. Desta maneira, 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, 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

Os resultados obtidos nos capítulos anteriores (2 e 3) foram utilizados para a predição das classes de solos da bacia do Rio São Domingos utilizando-se uma abordagem por redes neurais, conforme Zhu (2000) e ilustrado na Figura 1.

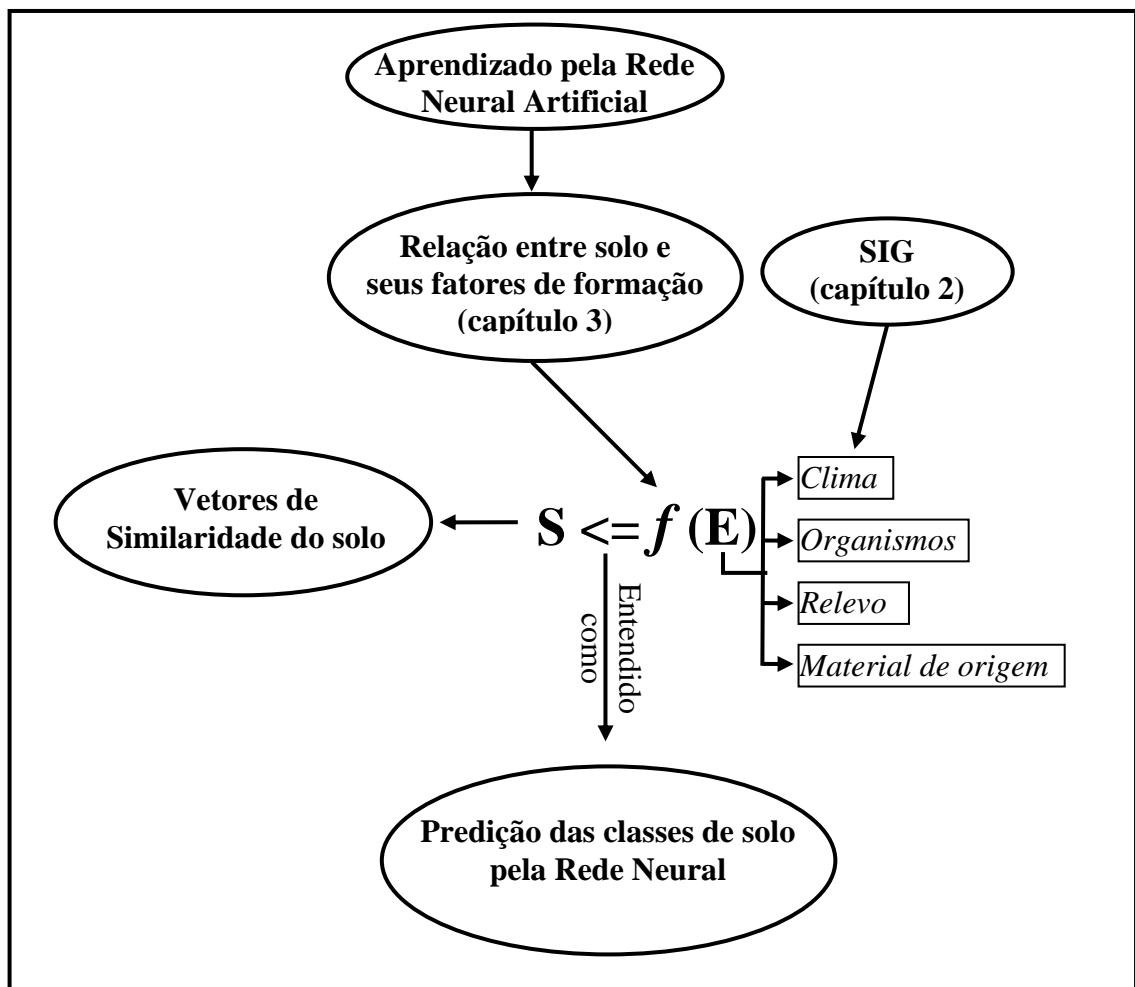


FIGURA 1. Predição das classes de solos baseada na abordagem por redes neurais.

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). As diferentes interações entre os solos da bacia do rio São Domingos e seus fatores de formação foram estabelecidas conforme apresentado no Capítulo 3.

No modelo de similaridade descrito por Zhu (2000), os solos em uma determinada área são representados por uma malha de pixels, com o solo em cada um dos pixels sendo considerado como um vetor de similaridade (Figura 1). Deste modo, a variação espacial do solo pode ser representada como um continuum nos domínios espacial e dos parâmetros.

## **2.1. Variáveis Discriminantes**

O estudo das relações geomorfopedológicas, realizado no Capítulo 3, permitiu a identificação das principais variáveis ambientais que condicionam as diferentes classes de solos na bacia do rio São Domingos. Assim, ao todo foram avaliadas nove variáveis como fonte de dados para auxiliar na predição das classes de solos, tais como: elevação, declividade, aspecto, curvatura, índice topográfico combinado (CTI), geologia e três índices derivados de uma imagem do sensor ETM+ do LANDSAT 7. As cinco primeiras variáveis, descritas no Capítulo 3, foram usadas para caracterizar as condições topográficas na bacia e foram obtidas a partir do modelo digital de elevação com resolução espacial de 30m, obtido conforme descrito no Capítulo 2 desta Tese.

O mapa geológico digital da bacia, na escala de 1:50.000, cedido pelo Departamento de Recursos Minerais do Estado do Rio de Janeiro (DRM, 1980) foi utilizado para dar informações sobre o material de origem dos solos.

Embora os organismos tenham um papel importante na formação dos solos, nenhuma estimativa direta das condições locais da vegetação foi realizada, pois a vegetação original na bacia foi quase que completamente removida para dar lugar a pastagens. Entretanto, dados da vegetação local foram aproximados através da utilização do índice de vegetação (índice de vegetação da diferença normalizada -

NDVI, sigla em inglês) derivado de uma imagem do sensor ETM+ do LANDSAT 7, obtida em agosto de 1999.

As bandas do sensor ETM+ do LANDSAT 7, originalmente geradas com uma resolução espacial de 28,5m foram reamostradas para uma resolução espacial final de 30m. Em seguida, foram corrigidas geometricamente com base nas cartas topográficas do IBGE, para o sistema de coordenadas UTM (Universal Transversa de Mercator), *datum* Córrego Alegre, zona 24S, para possibilitar sua utilização juntamente com os atributos do terreno. A transformação geométrica foi realizada utilizando-se o modelo polinomial, a partir de 15 pontos de controle retirados de cartas topográficas do IBGE. O método de reamostragem empregado foi o vizinho mais próximo e o RMS obtido foi de 0,32. O software empregado nestes procedimentos foi o ERDAS Imagine, versão 8.5.

Os índices de vegetação são medidas quantitativas que tentam medir a biomassa ou o vigor da vegetação. Usualmente, são formados a partir da combinação de vários valores espectrais que são somados, divididos ou multiplicados de modo a produzir um único valor que indica a quantidade ou vigor da vegetação dentro de um pixel (Campbell, 1987). Assim, para a imagem do sensor ETM+ do LANDSAT 7 o índice NDVI foi obtido da seguinte forma:

$$NDVI = \frac{IVP - V}{IVP + V} \quad (1),$$

onde *IVP* = infravermelho próximo e *V* = vermelho.

De acordo com Moreira (2003), os índices de vegetação foram criados para tentar diminuir o trabalho de análise dos dados, através da maximização de informações espectrais da vegetação no menor número de bandas de operação dos sensores. As variações espacial e temporal no índice NDVI têm sido estudadas por vários pesquisadores que mostraram a ligação deste índice com os regimes de temperatura e precipitação (Di et al., 1994; Yang et al., 1997), umidade do solo na zona das raízes (Narasimha et al., 1993) e propriedades físicas do solo (Lozano-Garcia et al., 1991; Yang et al., 1997).

O índice de vegetação foi testado como uma variável adicional, já que não possui relação direta com a formação dos solos. Porém, como muitas das características

da vegetação são influenciadas pelas características dos solos e vice e versa, este índice foi empregado na tentativa de melhorar a performance da classificação na abordagem por redes neurais e na classificação pelo algoritmo MAXVER (máxima verossimilhança).

Além do índice NDVI, foram também utilizados dois outros índices obtidos através da relação entre diferentes bandas deste sensor. Estes índices são obtidos pela divisão entre medidas de reflectância em porções separadas do espectro e são empregados para aumentar ou revelar informações latentes quando existe uma relação inversa entre duas respostas espectrais para um mesmo fenômeno biofísico. Se duas feições apresentam o mesmo comportamento espectral, estas relações fornecem pouca informação adicional. Por outro lado, se elas têm respostas espectrais bastante diferentes, as relações entre dois valores fornecem um único valor que expressa concisamente o contraste entre duas reflectâncias (Campbell, 1987).

Os índices utilizados foram o “clay minerals” e o “iron oxide”, originalmente desenvolvidos para o sensor TM do Landsat. O índice “clay minerals” foi obtido pela divisão da banda 5 (1,55 - 1,75  $\mu\text{m}$ ) pela banda 7 (2,08 - 2,35  $\mu\text{m}$ ) e o índice “iron oxide” pela divisão da banda 3 (0,63 - 0,69  $\mu\text{m}$ ) pela banda 1 (0,45 - 0,52  $\mu\text{m}$ ).

Os índices “clay minerals” e “iron oxide”, segundo Sabins (1997) são muito empregados no sensoriamento remoto geológico e podem ser utilizados para auxiliar na distinção de solos com características físicas e mineralógicas diferentes. De acordo com Sabins (1997), o índice “clay minerals” pode ser utilizado para quantificar e enfatizar certas propriedades da superfície do solo, em particular, minerais de argila (caulinita, illita e esmectita), que no LANDSAT 7 possuem alta reflectância na banda 5 e baixa reflectância na banda 7. Esta relação também é útil para distinguir solos de áreas de rochas inalteradas. Ambos têm valores de reflectância similares na banda 5. No entanto, nas rochas inalteradas, as reflectâncias nas bandas 5 e 7 são similares, sendo, conseqüentemente, a relação entre estas bandas próxima de 1. Por sua vez, os solos possuem mais baixa reflectância na banda 7 devido ao aumento de absorção de água pelas partículas do solo, e neste caso, a relação é sempre maior do que 1.

Minerais de ferro como goethita e hematita têm baixos valores de reflectância na banda 1 e elevados valores na banda 3 do LANDSAT 7, conseqüentemente, os solos

tendem a apresentar elevados valores da relação entre as bandas 3 e 1, que varia de acordo com a composição mineralógica do solo.

Os solos da bacia do rio São Domingos apresentam características distintas, tais como: atividade da fração argila, tipo de argila, teor de argila nos horizontes superficiais e teor de óxido de ferro. Deste modo, estes índices foram utilizados como variáveis adicionais para auxiliar na discriminação dos solos da bacia. Todos os índices avaliados foram obtidos com a utilização do ERDAS Imagine 8.5.

Kanellopoulos & Wilkinson (1997) destacam que o uso de variáveis extras tem efeito benéfico sobre o desempenho da classificação por redes neurais, desde que a variável utilizada forneça informação adicional útil. Assim, não é garantido que estas variáveis irão aumentar a exatidão de uma classificação e algumas vezes, até mesmo degradam a precisão (fenômeno de Hugues). Por outro lado, como tais variáveis aumentam a dimensionalidade dos dados e a complexidade da rede, isto pode tornar o treinamento da rede mais difícil e demorado. Nos casos onde existe considerável redundância entre as novas variáveis e os dados originais, é possível que a adição de variáveis extras reduza o desempenho geral da classificação, além de aumentar o tempo de treinamento.

Os fatores climáticos, igualmente importantes no processo de formação dos solos, também não foram utilizados diretamente, devido à falta de informações climáticas adequadas na área da bacia. No entanto, diferenças microclimáticas na bacia são bastante evidentes e foram expressas pelas variações nos atributos topográficos elevação e aspecto e confirmadas pela quantificação da radiação solar incidente nas diferentes encostas.

As variáveis discriminantes utilizadas foram combinadas e avaliadas quanto à capacidade de discriminação dos solos da bacia do rio São Domingos. Os conjuntos de variáveis testados foram: 1 - atributos do terreno (elevação, declividade, aspecto, curvatura e CTI) + todos os índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7 (“clay minerals”, “iron oxide” e NDVI); 2 - atributos do terreno + índice “clay minerals” + índice “iron oxide”; 3 - atributos do terreno + índice “clay minerals” + índice NDVI; 4 - atributos do terreno + índice “iron oxide” + índice NDVI; 5 -

atributos do terreno + índice “clay minerals”; 6 - atributos do terreno + índice “iron oxide”; 7 - atributos do terreno + índice NDVI; e 8 - somente os atributos do terreno.

Após definidas as variáveis discriminantes que seriam utilizadas como dados de entrada na rede neural, os valores referentes a estas variáveis foram devidamente re-escalados para o intervalo entre 0 e 1, para facilitar o processo de treinamento da rede e simplificar sua estrutura. Este procedimento é necessário para evitar a saturação da rede, pois valores muito grandes poderiam impedir a solução do problema (convergência da rede), e para prevenir que grandes variações de uma variável pouco importante inibam pequenas mais importantes variações em outras variáveis. Embora não existam limites teóricos sobre os valores de entrada das redes neurais, sua estabilidade é usualmente melhorada quando são usados limites comparáveis entre estas variáveis (Master, 1993). Este procedimento foi realizado no ArcGIS Desktop 9.0, no caso dos dados referentes aos atributos do terreno e no ERDAS Imagine 8.5 no caso das imagens de sensores remotos.



## 2.2. Classes Informacionais de Solos

As classes de solo, no 4º nível categórico do Sistema Brasileiro de Classificação de Solos (Embrapa, 1999), utilizadas na abordagem por redes neurais são as classes identificadas e descritas no capítulo anterior desta tese e são apresentadas na Tabela 1.

**TABELA 1. Classes de solos identificadas na bacia do rio São Domingos.**

<b>Granulitos da Unidade São José de Ubá (Área 1)</b>	
<b>Unidade</b>	<b>Descrição</b>
<b>G1</b>	Afloramentos de Rocha
<b>G2</b>	Neossolo Litólico Eutrófico típico relevo montanhoso
<b>G3</b>	Cambissolo Háptico Tb Eutrófico típico relevo forte ondulado
<b>G4</b>	Argissolo Vermelho ou Vermelho-Amarelo Eutrófico câmbico relevo forte ondulado e montanhoso
<b>G5</b>	Argissolo Vermelho Eutrófico típico relevo forte ondulado e montanhoso
<b>G6</b>	Nitossolo Vermelho Eutrófico típico relevo forte ondulado e montanhoso
<b>G7</b>	Argissolo Vermelho-Amarelo Eutrófico típico relevo forte ondulado e montanhoso
<b>G8</b>	Argissolo Vermelho-Amarelo Distrófico latossólico relevo forte ondulado e montanhoso
<b>G9</b>	Argissolo Vermelho Eutrófico típico ou Argissolo Vermelho-Amarelo Eutrófico típico ou câmbico relevo ondulado
<b>G10</b>	Latossolo Vermelho-Amarelo Distrófico típico relevo ondulado
<b>G11</b>	Gleissolo Háptico Ta ou Tb Eutrófico solódico ou típico ou Cambissolo Háptico Tb Eutrófico gleico relevo plano
<b>G12</b>	Argissolo Amarelo Eutrófico típico ou câmbico relevo suave ondulado
<b>Migmatitos das Unidades Vista Alegre, Catalunha e São João do Paraíso e Milonitognaisse da Unidade Santo Eduardo (Área 2)</b>	
<b>M1</b>	Afloramentos de Rocha
<b>M2</b>	Neossolo Litólico Eutrófico típico relevo montanhoso substrato migmatitos
<b>M3</b>	Cambissolo Háptico Ta ou Tb Eutrófico típico relevo forte ondulado substrato migmatitos
<b>M4</b>	Cambissolo Háptico Ta ou Tb Eutrófico típico ou léptico relevo forte ondulado e montanhoso
<b>M5</b>	Argissolo Vermelho Eutrófico abráptico relevo forte ondulado e montanhoso
<b>M6</b>	Argissolo Vermelho Eutrófico abráptico latossólico ou Luvisolo Hipocrômico Órtico típico relevo forte ondulado e montanhoso
<b>M7</b>	Argissolo Vermelho Eutrófico abráptico ou abráptico câmbico relevo ondulado
<b>M8</b>	Latossolo Vermelho Distrófico típico relevo ondulado
<b>M9</b>	Gleissolo Háptico Ta Eutrófico solódico ou típico ou Cambissolo Háptico Ta Eutrófico gleico ou Planossolo Háptico Eutrófico solódico ou típico relevo plano
<b>M10</b>	Argissolo Amarelo Eutrófico abráptico ou abráptico câmbico relevo suave ondulado

### **2.3. Classificação Supervisionada Utilizando-se Redes Neurais e o Classificador de Máxima Verossimilhança (MAXVER)**

O simulador de redes neurais utilizado foi o “Java Neural Network Simulator” desenvolvido pelo Instituto Wilhem-Schickard para Ciência da Computação (WSI) em Tübingen, Alemanha. Este simulador é baseado no Stuttgart Neural Network Simulator 4.2 Kernel (Zell et al., 1996), com uma nova interface gráfica. O algoritmo de aprendizado utilizado foi o “backpropagation” desenvolvido nos anos 80, que é um algoritmo de classificação supervisionada, o que significa que para cada padrão de entrada na rede existe um padrão de saída estabelecido. O algoritmo de aprendizado é baseado na modificação dos pesos de conexão dos neurônios, de modo a se obter o comportamento desejado do sistema. Esta modificação é frequentemente baseada na regra de Hebb (Hebb, 1949). De acordo com esta regra, uma ligação entre duas unidades é fortalecida se ambas as unidades estão ativas ao mesmo tempo (Vieira, 2000).

A utilização de redes neurais evita o problema de dedução de fórmulas ou estabelecimento de regras para solução de um determinado problema e somente requerem o conhecimento de qual informação é relevante para solução do problema. Assim, os dados devem ser representativos das classes com as quais estão associados.

A utilização de uma rede neural se inicia com o processo de treinamento da rede. Para tanto, inicialmente foram coletados dois conjuntos de amostras, um para treinamento da rede e outro para validação ou teste, coletados de modo independente um do outro. Além disso, um conjunto selecionado aleatoriamente, pode enfatizar demais certas relações e negligenciar outras. Assim, é preferível utilizar opiniões de especialistas para selecionar uma variedade maior de padrões.

No caso da classificação pelo MAXVER, Swain (1978) e Mather (1999) recomendam que uma amostra de treinamento representativa, para o caso multivariado, deve ter pelo menos 30 vezes o número de variáveis discriminantes por classe. Sendo assim, o número de amostras para treinamento foi estipulado em 300 para cada classe, ou seja, mais do que 30 vezes o número de variáveis discriminantes (8) utilizadas, tanto para classificação pelas redes neurais quanto para a classificação pelo MAXVER. Por sua vez, o tamanho do conjunto de validação foi determinado em 150 amostras,

conforme sugerido por Zhu (2000). A coleta das amostras foi realizada no software ERDAS Imagine 8.5 e estas foram distribuídas aleatoriamente na área da bacia (amostra estratificada), sempre buscando capturar um conjunto que representasse o máximo possível as características de cada classe.

Após este procedimento, foram realizados o treinamento e a validação propriamente ditos das amostras pelo classificador por redes neurais. Diferentes arquiteturas foram testadas: variando o número de neurônios na camada de entrada, correspondentes ao número de variáveis discriminantes utilizadas; variando o número de neurônios na camada interna e/ou números de camadas internas; e todas tendo o mesmo número de neurônios na camada de saída (12 classes de solo para a Área 1 e 10 para a Área 2).

O número de neurônios da(s) camada(s) interna(s) foi determinado através de tentativa e erro, conforme sugerido por Hirose et al. (1991). Este procedimento começa com uma rede pequena composta de uma camada de entrada e uma de saída, as quais definem, respectivamente o número de variáveis discriminantes e o número de classes informacionais envolvidas em um determinado problema, com somente um neurônio na camada interna. O critério utilizado para adicionar neurônios na camada interna é baseado no comportamento do erro durante a fase de treinamento. Desta maneira, o erro do treinamento foi usado como critério para avaliar o desempenho da rede. O erro do treinamento mede a diferença entre os valores estimados e os valores desejados para o conjunto de treinamento.

O treinamento das redes utilizando um aprendizado supervisionado consistiu dos seguintes procedimentos:

a) alocação aleatória dos pesos interneurônios. Os pesos foram inicializados com valores aleatórios pequenos (entre -0,5 e 0,5) para evitar o problema de que a rede neural seja saturada com valores grandes, ou a dificuldade da rede não aprender, devido à presença de valores homogêneos (Vieira, 2000);

b) Se os padrões estudados não são muito distintos, eles podem não ser classificados de acordo com os resultados desejados, o que resultará em menor valor na taxa de aprendizado ( $\eta$ ). Por outro lado, isto implicará em um treinamento mais lento, porém estável, sem grandes oscilações dos valores dos erros. Valores grandes de  $\eta$  são

esperados quando todos os padrões de treinamento são completamente distintos, ou seja, quando existe um padrão de cada tipo no conjunto de dados de treinamento (Vieira, 2000). A determinação da taxa de aprendizado para um problema específico não é uma tarefa simples. Valores típicos de  $\eta$  estão na faixa de 0,1 a 1,0. Poucos são os exemplos onde o treinamento é mais rápido, com valores acima de 1,0. Algumas vezes o valor de  $\eta$  apropriado para começar o treinamento é inapropriado quando uma rede alcança pontos mais próximos ao seu mínimo global ao término do treinamento (Cauldill, 1991).

c) utilização de uma taxa de aprendizado de 0,2, considerando 10.000 ciclos de aprendizagem.

Por último, ao final de todo o processo de treinamento, as redes foram submetidas à validação para escolha daquela(s) que seria(m) utilizada(s) na discriminação dos solos da área estudada.

Finalmente, a rede escolhida em cada unidade litológica considerada foi utilizada na predição das classes de solos da bacia do rio São Domingos. Para computar a classe de solo que ocorre em um determinado pixel, os valores das variáveis discriminantes para aquele pixel foram introduzidos na rede treinada como dados de entrada. A rede, então, computou o resultado correspondente contendo os níveis de ativação no neurônio de saída. Assim, quando todos os pixels foram visitados pela rede, foi produzida uma representação das classes de solos identificadas na bacia do rio São Domingos.

Na abordagem por redes neurais, o resultado final da avaliação atribuído a um determinado pixel é dado em termos de porcentagem de este pixel pertencer a uma das classes de solos identificadas na bacia. Deste modo, o mapa de solos obtido por esta abordagem foi produzido através da conversão da representação de similaridade (Zhu, 2000) para uma representação booleana. Esta conversão foi feita adicionando-se a cada pixel o valor correspondente à classe que apresentou a maior porcentagem entre todas as envolvidas (Zhu, 1997).

A fim de permitir uma comparação entre classificadores distintos, as mesmas amostras utilizadas no treinamento e validação das redes neurais foram utilizadas no treinamento e validação pelo classificador de distribuição gaussiana por máxima

verossimilhança (MAXVER). Esta etapa foi implementada no executável denominado “Funcpow.exe” desenvolvido por Vieira (2000). A opção pelo emprego deste executável se deve à possibilidade de utilização dos mesmos formatos de arquivos de treinamento e validação que foram usados para a classificação pelas redes neurais.

Os resultados obtidos pelos classificadores utilizados foram manipulados no software ERDAS Imagine 8.5 para produzir os mapas finais das classes de solos da bacia do rio São Domingos.

#### **2.4. Avaliação dos Resultados**

A avaliação dos resultados obtidos constou da determinação do nível de exatidão ou confiança da classificação (índice Kappa) e da exatidão global da classificação das redes neurais consideradas e do algoritmo MAXVER, através da análise da matriz de confusão (Congalton, 1991).

A matriz de confusão (tabela de contingência, tabela de avaliação ou matriz de erro), tem sido reconhecida como a mais importante técnica de estimativa da exatidão de produtos, principalmente de dados sensores remotos (Story & Congalton, 1986; Skidmore & Turner, 1989). A matriz de confusão compara o conjunto de dados de referência, que normalmente está representado nas colunas, com os dados classificados que estão representados ao longo das linhas. Os elementos da diagonal principal indicam o nível de concordância entre os dois conjuntos de dados.

A exatidão global ( $P_o$ ), definida como a estimativa da % de área mapeada que foi corretamente classificada quando comparada com os dados de referência ou verdade de campo, pode ser computada pela divisão da soma da diagonal principal (número de classificações corretas ou concordância real) pelo número total de amostras tomadas, segundo a equação 2:

$$P_o = \frac{\sum_{i=1}^m n_{ii}}{N} \quad (2)$$

onde  $N$  representa o número total de amostras contempladas pela matriz de confusão;  $n_{ii}$  representa os elementos da diagonal principal e  $m$  o número de classes presentes na matriz.

Como a exatidão global não indica a distribuição da exatidão entre as classes individuais, uma medida mais detalhada, também derivada da matriz de confusão, na forma de exatidões das categorias individuais, pode ser obtida pela divisão do número total de amostras classificadas corretamente naquela categoria pelo número total de amostras da mesma.

Congalton (1991) recomenda o coeficiente Kappa ( $Ka$ ) como uma medida adequada da exatidão de uma classificação temática porque esta leva em conta toda a matriz de confusão (incluindo erros de comissão e omissão) mais do que somente os elementos da diagonal como a exatidão global faz. O coeficiente Kappa é uma medida da concordância real (indicada pelos elementos da diagonal da matriz de confusão) menos a possibilidade de concordância (indicada pelo produto das linhas e colunas totais, que não incluem entradas não reconhecidas) (Rutchev & Vilcheck, 1994; Congalton & Green, 1999). Em outras palavras, esta é uma medida de como a classificação realizada concorda com os dados de referência (Congalton & Mead, 1983). O Coeficiente Kappa pode ser obtido segundo a equação 3:

$$Ka = \frac{n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}}{n^2 - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}} \quad (3)$$

onde  $Ka$  é uma estimativa do coeficiente Kappa;  $x_{ii}$  é o valor na linha  $i$  e coluna  $i$ ; linhas totais  $x_{i\oplus}$  é a soma de linhas  $i$  e colunas totais  $x_{\oplus i}$  é a soma das colunas  $i$  da matriz de confusão;  $n$  é o número total de amostras e  $c$  o número total de classes.

Landis & Koch (1977) e Monserud & Leemans (1992) sugerem que valores de Kappa de 0,75 ou maiores mostram um desempenho do classificador de muito bom a excelente, enquanto valores entre 0,4 e 0,75 representam desempenho moderado e valores menores que do que 0,4, uma baixa concordância (baixo desempenho). Entretanto, estas diretrizes são válidas para um conjunto de amostras grande, obtido aleatoriamente a partir de uma distribuição multinomial, ou uma amostragem aleatória

estratificada, segundo Congalton & Green (1999). O coeficiente Kappa condicional ( $Ka_i$ ) pode também ser facilmente computado para concordância de uma classe individual usando a equação 4 (Congalton & Green, 1999):

$$Ka_i = \frac{n x_{ii} - x_{i\oplus} x_{\oplus i}}{n x_{i\oplus} - x_{i\oplus} x_{\oplus i}} \quad (4)$$

onde  $Ka_i$  é a estimativa da máxima verossimilhança da concordância condicional para a classe  $i^{\text{th}}$  (classe individual) e as variáveis restantes tal como definido para a equação 2. Já a variância da amostra para a mesma classe  $i^{\text{th}}$ , segundo Congalton & Green (1999), é estimada pela equação 5:

$$Var_{ai} = \frac{n(x_{i\oplus} - x_{ii})}{[x_{i\oplus}(n - x_{\oplus i})]^3} [(x_{i\oplus} - x_{ii})(x_{i\oplus} x_{\oplus i} - nx_{ii}) + nx_{ii}(n - x_{i\oplus} - x_{\oplus i} + x_{ii})] \quad (5)$$

Intervalos de confiança ao redor do valor Kappa podem ser computados usando a variância da amostra ( $var$ ) e o fato de que a estatística de Kappa é assintoticamente normalmente distribuída. Congalton & Green (1999) sugeriram que este fato também fornece meios para testar a significância da estatística de Kappa para uma matriz de confusão individual a fim de determinar se o nível de concordância entre a classificação de dados de sensores remotos e os dados de referência é significativamente maior do que 0 (melhor do que uma classificação randômica). O teste estatístico para avaliar a significância de uma matriz de confusão individual é dado pela equação 6:

$$Z = \frac{K_a}{\sqrt{var(K_a)}} \quad (6)$$

$Z$  é padronizado e distribuído normalmente e  $var$  é variância do coeficiente de Kappa ( $K_a$ ), que pode ser computada usando o método *Delta* (Bishop et al., 1975; Kalkhan et al., 1997), conforme a equação 7. Se  $Z \geq Z_{\alpha/2}$  a classificação é significativamente melhor do que uma classificação aleatória, onde  $\alpha/2$  é o nível de confiança do teste  $Z$  e o número de graus de liberdade é assumido como sendo infinito.

$$Var(K_a) = \frac{1}{n} \frac{\theta_1(1 - \theta_1)}{(1 - \theta_2)^2} + \frac{2(1 - \theta_1)(2\theta_1\theta_2 - \theta_3)}{(1 - \theta_2)^3} + \frac{(1 - \theta_1)^2(\theta_4 - 4\theta_2^2)}{(1 - \theta_2)^4} \quad (7)$$

onde  $\theta_1 = \frac{1}{n} \sum_{i=1}^c x_{ii}$  (8);  $\theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_{i \oplus x \oplus i}$  (9);  $\theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_{ii}(x_{i \oplus} + x_{\oplus i})$  (10); e

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c x_{ij}(x_{j \oplus} + x_{\oplus j})^2 \quad (11).$$

Uma matriz de significância de Kappa entre as redes consideradas e o algoritmo MAXVER foi também gerada para verificar a existência de diferenças significativas ou não entre os resultados obtidos e para a escolha da melhor arquitetura de rede para a classificação final dos dados (Vieira, 2000).

Um teste estatístico para verificar a significância das diferenças entre dois ou mais classificadores (representado pelas suas respectivas matrizes de confusão) usando a análise do coeficiente de Kappa é proposta como uma abordagem alternativa para comparação de matrizes de confusão independentes. Assim, os resultados da análise de Kappa podem ser sumarizados na forma de uma matriz de significância, na qual os elementos da diagonal principal indicam se o resultado da respectiva classificação é estatisticamente diferente de uma classificação randômica. Na matriz de significância os valores de  $Z$  podem ser computados usando a equação 6 e a variância do coeficiente Kappa obtida usando-se a equação 7.

Por outro lado, os elementos fora da diagonal indicam, mais uma vez se  $Z \geq Z_{\alpha/2}$ , que dois classificadores independentes são significativamente diferentes. A fórmula usada para testar a significância entre dois coeficientes Kappa independentes é dada pela equação a seguir:

$$Z = \frac{|K_{a1} - K_{a2}|}{\sqrt{\text{var}(K_{a1}) + \text{var}(K_{a2})}} \quad (12),$$

onde  $K_{a1}$  e  $K_{a2}$  são os dois coeficientes Kappa que estão sendo comparados (Congalton & Mead, 1986).

O resultado final obtido com a abordagem por redes neurais e o algoritmo MAXVER foram comparados com o mapa de solos da bacia produzido com a metodologia convencional de levantamento de solos. Este mapa, na escala de 1:50.000, foi produzido por uma equipe de pesquisadores da Embrapa Solos para subsidiar os estudos relacionados com a recarga hídrica em áreas de relevo acidentado.



Complementando os testes de validação dos resultados obtidos, 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. A partir desta matriz, foi calculada a exatidão global (porcentagem de pixels classificados corretamente), o índice Kappa e a variância (Congalton, 1991). Finalmente, foi gerada uma matriz de significância de Kappa entre o mapa obtido pela abordagem por redes neurais, o mapa obtido com a utilização do algoritmo MAXVER 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


Inicialmente, foi avaliada a possibilidade de utilização de uma única rede neural para a predição das classes de solos da bacia do rio São Domingos. No entanto, devido ao número elevado de classes identificadas e à grande complexidade envolvida, o tempo gasto no processo de treinamento foi excessivamente longo e os resultados obtidos não foram satisfatórios. Deste modo, optou-se pelo desenvolvimento de duas redes neurais, uma para a Área 1 e outra para a Área 2. Como as relações dentro de cada unidade são mais similares, esperava-se que a estrutura da rede para cada uma delas fosse menos complexa do que a estrutura para toda a área, o que efetivamente ocorreu. Uma estrutura de rede mais simples reduz a complexidade, facilita o treinamento e melhora o poder de generalização da rede (Vieira, 2000; Zhu, 2000).

No primeiro estágio da avaliação foi realizada uma comparação entre os diferentes conjuntos de variáveis discriminantes testadas utilizando-se os mesmos conjuntos de amostras de treinamento e validação, modificando-se, apenas, o número de neurônios na camada de entrada, em ambas as redes neurais consideradas. Esta comparação constou da verificação do MSE (*mean square error*) e do desempenho do índice Kappa após 10.000 ciclos de aprendizado, e teve por objetivo selecionar o melhor conjunto de variáveis discriminantes para ser utilizada na classificação. Os resultados obtidos são apresentados conforme a seguir.

### 3.1. Área 1 (granulitos da Unidade São José de Ubá)

Os diferentes conjuntos de variáveis utilizadas para discriminar as classes de solos da Área 1 produziram resultados muito próximos para o MSE, a partir de 10 neurônios, como pode ser observado na Figura 2.





**FIGURA 3.** Resultados do índice Kappa das redes neurais para os conjuntos de variáveis discriminantes testados (AT - atributos do terreno; C - índice “clay minerals”; O - índice “iron oxide”; e N - índice NDVI).

Na Figura 3 observa-se que o índice Kappa variou bastante em função das variáveis discriminantes utilizadas e do número de neurônios na camada interna. Nesta avaliação, a combinação dos atributos do terreno com todos os três índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7 (conjunto 1) foi a que apresentou o melhor desempenho, com um valor para o índice Kappa de 0,908 para uma rede neural com 8 neurônios na camada interna. O melhor desempenho para o conjunto 2 (atributos do terreno + índice “clay minerals” + índice “iron oxide”) foi obtido com uma arquitetura de rede com 5 neurônios na camada interna (0,844), enquanto que para o conjunto 3 (atributos do terreno + índice “clay minerals” + índice NDVI) o melhor desempenho foi alcançado utilizando uma rede neural com 5 neurônios na camada interna (0,828).

Os conjuntos 4 (atributos do terreno + índice “iron oxide” + índice NDVI) e 6 (atributos do terreno + índice “iron oxide”) obtiveram um desempenho para o índice Kappa muito semelhante (0,861 e 0,862, respectivamente), para redes com 15 e 10 neurônios na camada interna, respectivamente. Já a combinação dos atributos do terreno com o índice “clay minerals” (conjunto 5) teve um desempenho para o índice Kappa de 0,836 para uma rede com 25 neurônios na camada interna. Finalmente, os conjuntos 7

(atributos do terreno + índice NDVI) e 8 (somente os atributos do terreno) obtiveram um desempenho para o índice Kappa de 0,825 e 0,843, respectivamente, para o mesmo número de neurônios na camada interna (5 neurônios).

De modo geral, as redes com mais de 10 neurônios na camada interna não produziram resultados significativamente melhores ou obtiveram, até mesmo, resultados inferiores aos obtidos pelas redes com menos de 10 neurônios (Figura 3). Uma matriz de significância foi utilizada para comparar o desempenho do índice Kappa dos diferentes conjuntos de variáveis discriminantes testados (Tabela 2).

**TABELA 2. Matriz de significância de Kappa para os conjuntos testados.**

Conjuntos	AT+C+ O+N (8) <sup>a</sup>	AT+C +O (5) <sup>a</sup>	AT+C +N (5) <sup>a</sup>	AT+O +N (15) <sup>a</sup>	AT+C (25) <sup>a</sup>	AT+O (10) <sup>a</sup>	AT+N (5) <sup>a</sup>	AT (5) <sup>a</sup>
<b>Exatidão global</b>	91,6	85,7	84,3	87,3	85,0	87,4	85,8	85,6
<b>Kappa</b>	0,908	0,844	0,828	0,861	0,836	0,862	0,825	0,843
<b>Variância<sup>b</sup></b>	0,051	0,081	0,087	0,073	0,084	0,073	0,089	0,081
<b>1 - AT+C+O+N</b>	127,15							
<b>2 - AT+C+O</b>	5,57*	93,78						
<b>3 - AT+C+N</b>	6,81*	1,23	88,77					
<b>4 - AT+O+N</b>	4,22*	1,37	2,61*	100,77				
<b>5 - AT+C</b>	6,20*	0,62	0,61	2,00*	91,22			
<b>6 - AT+O</b>	4,13*	1,45	2,69*	0,08	2,08*	100,89		
<b>7 - AT+N</b>	7,02*	1,46	0,23	2,83*	0,84	2,91*	87,45	
<b>8 - AT</b>	5,66*	0,08	1,16*	1,45	0,55	1,53	1,38	93,67

\* existe diferença significativa ao nível de 95%; <sup>a</sup> n°. de neurônios na camada interna; <sup>b</sup> valores multiplicados por 1000; AT - atributos do terreno; C - índice “clay minerals”; O - índice “iron oxide”; e N - índice NDVI.

O melhor desempenho do índice Kappa obtido pela combinação dos atributos do terreno com os índices derivados do sensor ETM<sup>+</sup> do LANDSAT 7 difere de todos os demais conjuntos. Dentre os índices utilizados, a maior contribuição para a discriminação dos solos da área estudada é dada pelo índice “iron oxide”, visto que a combinação deste com os atributos do terreno, isoladamente (conjunto 6) ou junto com outros índices (conjuntos 1 e 4) obteve os melhores resultados. Por outro lado, a adição do índice NDVI piorou a classificação dos dados, exceto quando associado com o índice “iron oxide” (conjuntos 1 e 4) (Tabela 2). O índice “clay minerals”, quando associado com os atributos do terreno, produziu resultados ligeiramente melhores do que o índice NDVI; no entanto, ambos interferiram negativamente na classificação, pois o resultado

obtido quando se utilizou apenas os atributos do terreno é superior a estes, embora estatisticamente todos sejam semelhantes (Tabela 2).

Segundo Foody & Arora (1997) e Dobos, et al. (2001), muitos estudos têm demonstrado que a separabilidade de classes e a exatidão de uma classificação aumentam com o aumento no número de variáveis discriminantes utilizadas, até um ponto onde a adição de dados de outras variáveis não tem efeito significativo ou resulta em um decréscimo na exatidão da classificação (fenômeno de Hughes). Além disso, de acordo com Kanellopoulos & Wilkinson (1997), o aumento da dimensionalidade dos dados eleva a complexidade da rede e alonga o tempo de treinamento, tornando-o mais difícil. O fenômeno de Hughes foi verificado para quase todos os conjuntos testados, exceto quando os três índices foram utilizados junto aos atributos do terreno.


Os índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7 foram utilizados como variáveis adicionais, com o objetivo de melhorar a discriminação das classes de solo na área estudada. Embora não apresentem uma relação direta com os fatores de formação do solo, a utilização destes índices juntamente com os atributos do terreno teve um efeito significativo sobre a exatidão da classificação (Tabela 2).

Na Figura 4 é possível fazer-se uma análise da contribuição dos diferentes índices (médias das amostras de treinamento re-escaloadas entre 0 e 1 para permitir a comparação) para a discriminação das classes de solo da Área 1.

Os índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7 apresentam uma distribuição diferenciada entre as classes de solo. Na Figura 4 observa-se que o índice NDVI mostra uma distribuição muito parecida com o índice “clay minerals”, o que pode ter causado uma redundância entre estas duas variáveis. Esta redundância pode ter contribuído para o desempenho inferior da classificação, quando se utilizou estes índices junto com os atributos do terreno (Tabela 2), embora, segundo Foody & Arora (1997), a rede neural tenha habilidade para estimar a importância das variáveis discriminantes na classificação e ignorar efetivamente as variáveis redundantes.

O índice NDVI, embora muito utilizado como variável auxiliar para predição de características ou classes de solo (McKenzie & Ryan, 1999; Dobos et al., 2000; Zhu, 2000; Zhu et al., 2001), quando associado com os atributos do terreno, produziu o menor desempenho da classificação entre os conjuntos testados. Este resultado está

relacionado com a baixa diferenciação deste índice entre as classes de solo como pode ser observado na Figura 4. Por sua vez, esta baixa diferenciação deve-se ao fato de que quase toda a vegetação original da área foi removida para dar lugar a pastagens, em sua grande maioria de capim colonião.



O índice “iron oxide” mostra uma tendência contrária ao índice “clay minerals” (Figura 4), apresentando uma diferenciação entre as classes G1, G2, G3 e G4 e as demais, mais nítida do que os outros dois índices, o que certamente contribuiu para melhorar o desempenho da classificação quando este índice foi utilizado, seja isoladamente ou em combinação com os outros.

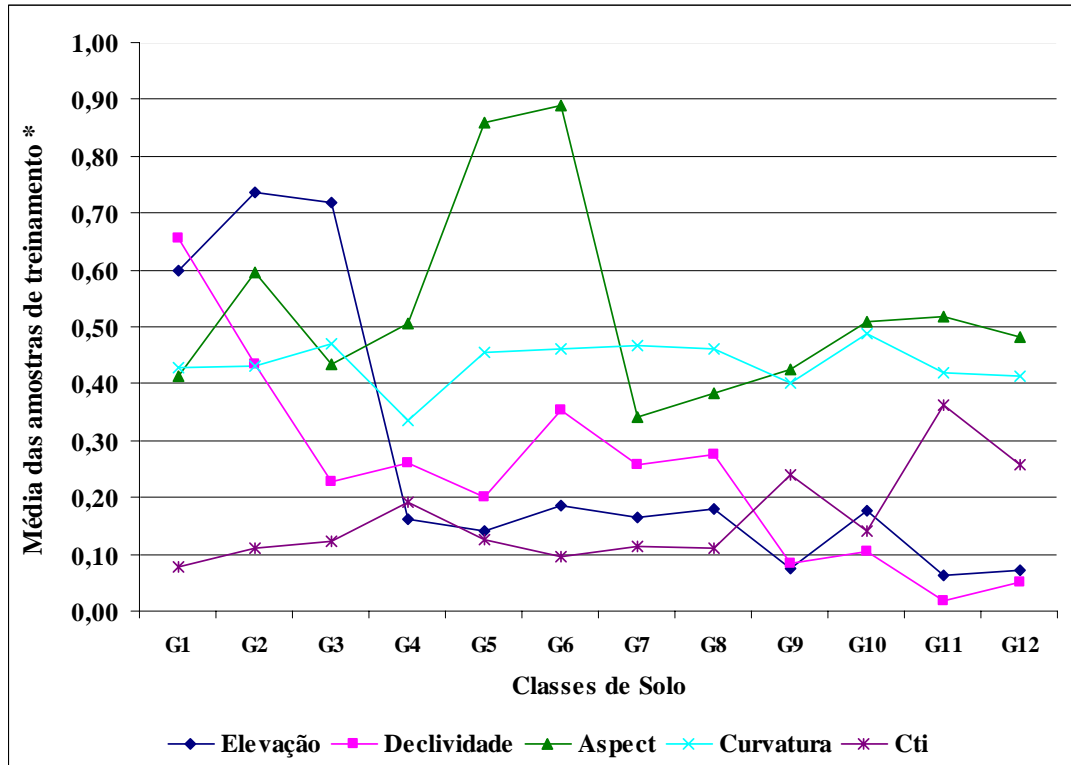
No Brasil, vários estudos já comprovaram a potencialidade da utilização de dados de sensores remotos orbitais como ferramenta auxiliar para o mapeamento de solos (Valério Filho et al., 1976; Ramos, 1983; Marchetti & Garcia, 1990; Pereira et al., 1991; Madeira Netto, 1993; Viegas, 1993; Soares, 1994; Silva, 1994; Sousa et al., 1997). Assim, os resultados obtidos no presente estudo demonstram que a utilização dos índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7, principalmente os índices “iron oxide” e “clay minerals”, contribuíram significativamente para a resolução do problema, confirmando, mais uma vez, a potencialidade desses dados para o mapeamento de solos.

Segundo Dobos et al. (2001), os dados de sensores remotos são grandemente influenciados pela variabilidade do terreno, porém, ainda não conseguem identificar com precisão toda a variabilidade do solo que ocorre na paisagem. Muitos estudos (Franklin, 1987; Lee et al., 1988; Frank, 1988; Leprieur et al., 1988) têm sugerido que os dados de sensores remotos devem ser complementados com informações do terreno para corrigir as distorções que surgem das variações topográficas da paisagem e para fornecer dados adicionais para modelagem solo-paisagem.

Neste sentido, a contribuição dos atributos do terreno para a discriminação das classes de solos da Área 1 pode ser verificada na Figura 5. De modo geral, as diferenças nos atributos do terreno entre as classes de solo (média das amostras de treinamento re-escaladas entre 0 e 1) são muito mais significativas do que as verificadas para os índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7, o que contribuiu com maior peso para a discriminação dos solos. Isto foi comprovado pelo valor do índice Kappa obtido quando se utilizou somente os atributos do terreno (Tabela 2).

A forte influência dos atributos do terreno sobre a variação espacial dos solos é um princípio bem conhecido (Park & Vlek, 2002), que foi confirmado neste estudo. No entanto, apesar da maior importância dos atributos do terreno, a utilização destes

separadamente apresentou um desempenho estatisticamente inferior ao obtido quando foram adicionados os três índices do sensor ETM<sup>+</sup> do LANDSAT 7, o que corrobora a importância destes índices na discriminação dos solos desta área.



**FIGURA 5. Distribuição dos atributos do terreno entre as classes de solo da Área 1. \* valores dos atributos re-escalados entre 0 e 1 para permitir a apresentação em conjunto.**

Estudos realizados por Dobos et al. (2000) e Dobos et al. (2001), utilizando atributos do terreno e dados do AVHRR para o mapeamento de solos, mostraram que os atributos do terreno sozinhos não foram suficientes para discriminar os solos das áreas por eles estudadas, enquanto a integração com os dados AVHRR elevou o desempenho da classificação. Por outro lado, Carvalho Junior (2005), utilizou somente atributos do terreno em uma abordagem por redes neurais artificiais para a classificação de paisagens de áreas montanhosas e obteve uma exatidão global de 70%.

Assim, em função do seu melhor desempenho o conjunto que contém os atributos do terreno e todos os índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7 (conjunto 1) foi escolhido para auxiliar na discriminação dos solos da Área 1. Após a definição do melhor conjunto de variáveis discriminantes, foi gerada uma matriz de significância de Kappa entre as redes consideradas, para verificar a



existência de diferenças significativas ou não entre os resultados obtidos e para a escolha da melhor arquitetura de rede para a classificação final dos dados (Tabela 3).

**TABELA 3. Matriz de significância de Kappa e respectivos índices para as diferentes arquiteturas de redes neurais testadas.**

<b>Redes</b>	<b>R3</b>	<b>R5</b>	<b>R6</b>	<b>R7</b>	<b>R8</b>	<b>R9</b>	<b>R10</b>	<b>R15</b>	<b>R20</b>	<b>R25</b>
<b>Exatidão global</b>	86,6	81,3	86,4	86,9	91,6	89,2	88,6	88,0	89,7	78,9
<b>Kappa</b>	0,85	0,80	0,85	0,86	0,91	0,88	0,88	0,87	0,88	0,77
<b>Variância<sup>a</sup></b>	0,077	0,100	0,078	0,075	0,051	0,063	0,067	0,070	0,061	0,110
<b>R3</b>	97,21									
<b>R5</b>	4,28*	79,60								
<b>R6</b>	0,08	4,20*	96,47							
<b>R7</b>	0,41	4,69*	0,49	99,07						
<b>R8</b>	4,86*	9,11*	4,93*	4,45*	127,15					
<b>R9</b>	2,45*	6,74*	2,53*	2,04*	2,44*	111,12				
<b>R10</b>	1,92	6,19*	1,99*	1,51	2,95*	0,53	107,02			
<b>R15</b>	1,32	5,60*	1,40	0,91	3,55*	1,13	0,60	103,87		
<b>R20</b>	2,30*	6,62*	2,38*	1,89	2,65*	0,18	0,35	0,96	112,67	
<b>R25</b>	6,07*	1,79	5,98*	6,47*	10,88*	8,52*	7,97*	7,38*	8,41*	73,42


\* existe diferença significativa ao nível de 95%; <sup>a</sup> valores multiplicados por 1000.

Segundo Foody & Arora (1997), a arquitetura de uma rede neural artificial pode ter uma influência significativa em sua habilidade para classificar dados de diferentes fontes. Nesta avaliação, os maiores valores de exatidão global e índice Kappa e, conseqüentemente, os menores de variância, foram obtidos com uma arquitetura de rede com apenas uma camada interna contendo 8 neurônios (Kappa de 0,908), seguida das redes com 9 e 20 neurônios na camada interna (Kappa de 0,882 e 0,880, respectivamente). O aumento da complexidade da rede com a adição de neurônios na camada interna não melhorou substancialmente a exatidão da classificação (Tabela 3). De acordo com Foody & Arora (1997), em geral, redes maiores e mais complexas são mais eficientes para caracterizar corretamente um conjunto de treinamento, porém podem ser menos eficientes do que redes mais simples para generalizar, fato que ocorreu nesta avaliação.

A Tabela 3 mostra que todos os valores da diagonal são maiores que 1,96, indicando que a classificação de todas as redes é significativamente melhor do que uma classificação randômica ou aleatória. Os melhores desempenhos foram obtidos com a utilização das redes com uma camada interna contendo 8 (127,15), 20 (112,67) e 9 (111,12) neurônios. No entanto, a rede com 8 neurônios na camada interna é

significativamente diferente de todas as demais redes, e deste modo, foi escolhida para a discriminação das classes de solos da Área 1.

Para definição do melhor conjunto de variáveis discriminantes para ser utilizado na classificação, utilizando o classificador de distribuição gaussiana por máxima verossimilhança (MAXVER) foi feita, do mesmo modo como realizado para o classificador por redes neurais, uma comparação entre os diferentes conjuntos de variáveis discriminantes, utilizando-se os mesmos conjuntos de amostras de treinamento e validação. Esta comparação foi baseada na verificação do desempenho do índice Kappa e os resultados obtidos são apresentados na Figura 6.



**FIGURA 6.** Resultados do índice Kappa para a classificação MAXVER dos conjuntos testados (AT - atributos do terreno; C - índice “clay”; O - índice “iron oxide”; e N - índice NDVI).

Nesta avaliação, o melhor desempenho também foi obtido com a utilização dos atributos do terreno e todos os índices do sensor ETM<sup>+</sup> do LANDSAT 7 como variáveis discriminantes, do mesmo modo que ocorreu para a classificação pelas redes neurais, produzindo uma exatidão global de 84,4%, índice Kappa de 0,830 e variância de 0,000086. Estes resultados não são estatisticamente diferentes apenas daqueles obtidos pelo conjunto de variáveis 6 (atributos do terreno + índice “iron oxide”), conforme

mostra a matriz de significância de Kappa entre as classificações MAXVER consideradas (Tabela 4).

A incorporação do índice NDVI piorou a classificação de quase todos os conjuntos, com exceção do conjunto 1 (Figura 6 e Tabela 4). Na classificação pelo algoritmo MAXVER, a maior contribuição para o desempenho da classificação foi dada pelo índice “iron oxide”, visto que a sua utilização no conjunto 6 produziu um desempenho estatisticamente semelhante ao obtido pelo conjunto 1 (Tabela 4).

Em função dos resultados obtidos, o conjunto de variáveis contendo os atributos do terreno e todos os índices derivados do sensor ETM<sup>+</sup> do LANDSAT 7, do mesmo modo como obtido para a classificação por redes neurais, foi selecionado para auxiliar na discriminação dos solos da Área 1 pelo classificador MAXVER.

**TABELA 4. Matriz de significância de Kappa para as classificações MAXVER consideradas.**

Conjuntos	AT+C+ O+N	AT+C +O	AT+C +N	AT+O +N	AT+C	AT+O	AT+N	AT
<b>Exatidão global</b>	84,4	81,7	78,3	79,4	81,1	82,7	77,4	80,4
<b>Kappa</b>	0,830	0,801	0,764	0,776	0,793	0,812	0,754	0,786
<b>Variância<sup>a</sup></b>	0,086	0,098	0,111	0,107	0,101	0,094	0,114	0,104
<b>1 - AT+C+O+N</b>	89,50							
<b>2 - AT+C+O</b>	2,14*	80,91						
<b>3 - AT+C+N</b>	4,70*	2,56*	72,52					
<b>4 - AT+O+N</b>	3,89*	1,75	0,81	75,02				
<b>5 - AT+C</b>	2,71*	0,57	1,99*	1,18	78,91			
<b>6 - AT+O</b>	1,34	0,79	3,35*	2,54*	1,36	83,75		
<b>7 - AT+N</b>	5,37*	3,23*	0,67	1,48	2,66*	4,02*	70,62	
<b>8 - AT</b>	3,19*	1,06	1,50	0,69	0,49	1,85	2,17*	77,07

\* existe diferença significativa ao nível de 95%; <sup>a</sup> valores multiplicados por 1000; AT - atributos do terreno; C - índice “clay minerals”; O - índice “iron oxide”; e N - índice NDVI.

Na etapa final da avaliação, foi realizada a comparação entre o desempenho da classificação pela abordagem por redes neurais e pelo algoritmo MAXVER. A análise da matriz de significância de Kappa (Tabela 5) indica haver diferença significativa entre estas classificações. Este resultado concorda com aqueles obtidos por outros autores, onde de modo geral, a abordagem por redes neurais tem apresentado um desempenho superior àquele obtido pelo algoritmo MAXVER, principalmente na classificação de dados de sensores remotos. Hepner et al. (1990) utilizando a abordagem por redes

neurais, obteve resultados qualitativamente superiores à classificação supervisionada convencional e experimentos realizados por Heermann & Khazenie (1992); Bischof et al. (1992) e Paola & Schowengerdt (1995) utilizando redes neurais, produziram exatidões mais elevadas do que a classificação pelo MAXVER. McBratney et al. (2000) utilizaram redes neurais artificiais para prever a distribuição de solos e concluíram que a abordagem por redes neurais foi superior a muitos outros métodos estatísticos lineares.

**TABELA 5. Matriz de significância de Kappa para os classificadores considerados.**

<b>Classificador</b>	<b>Rede neural</b>	<b>MAXVER</b>
<b>Exatidão global</b>	91,6	84,4
<b>Kappa</b>	0,908	0,830
<b>Variância</b>	0,000051	0,000086
<b>Rede neural</b>	127,145	
<b>MAXVER</b>	6,66*	89,50

\* existe diferença significativa ao nível de 95%.

Embora os classificadores tenham apresentado diferenças significativas, com ampla vantagem para o classificador por redes neurais (Kappa de 0,908), há que ressaltar que esta abordagem requer mais tempo e recursos computacionais para treinar as redes com as diferentes configurações de parâmetros testadas do que a abordagem clássica pelo algoritmo MAXVER. No entanto, para Yool (1998), as redes neurais levam vantagem sobre os métodos convencionais de classificação supervisionada, como o algoritmo MAXVER, porque estes se mostram inadequados e impraticáveis para o mapeamento de grandes áreas.

Segundo Kanellopoulos & Wilkinson (1997), um aspecto que tem sido negligenciado nas comparações entre classificadores estatísticos e redes neurais é a existência de diferenças significativas entre o desempenho destes classificadores quando se consideram as classes individualmente. Assim, para algumas classes a abordagem por redes neurais fornece uma exatidão maior, enquanto que para outras os métodos convencionais são superiores. Este efeito resulta dos modelos matemáticos muito distintos presentes nos diferentes classificadores e do modo pelo qual eles dividem o espaço. Nas Tabelas 6 e 7 são apresentadas as matrizes de confusão obtidas para as classificações realizadas.

O pior desempenho obtido pela classificação por redes neurais ocorreu para a classe G12 (Argissolo Amarelo Eutrófico típico ou câmbico), com uma exatidão de

62,0%, (Tabela 6). Do total dos pixels considerados como sendo da classe G12, 39 foram assinalados para a classe G9 (Argissolo Vermelho ou Vermelho-Amarelo Eutrófico típico relevo ondulado), 8 pixels à classe G10 (Latosolo Vermelho-Amarelo Distrófico típico) e 10 à classe G11 (Gleissolo Háptico Ta ou Tb Eutrófico solódico ou típico ou Cambissolo Háptico Tb Eutrófico gleico) (Tabela 6).

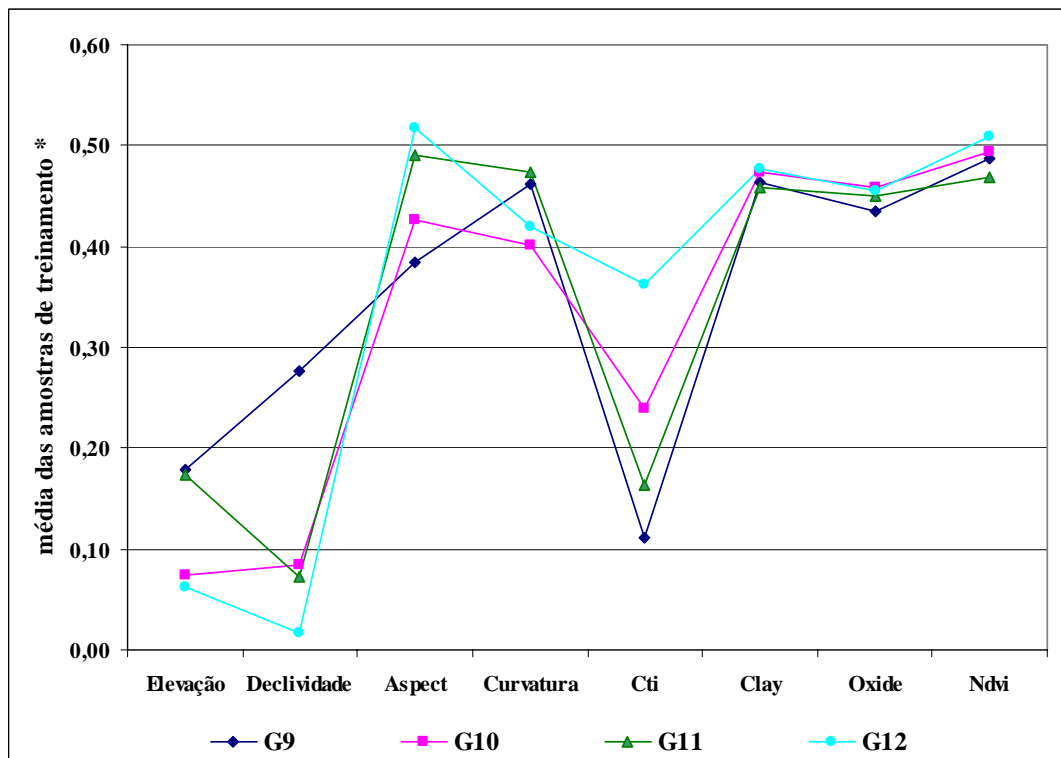
**TABELA 6. Matriz de confusão obtida na classificação por redes neurais.**

Classe	G1	G2	G3	G4	G5	G6	G7	G8	G9	G10	G11	G12	Total	Exatidão do Usuário	Z
<b>G1</b>	147	5	0	0	0	0	0	0	0	0	0	0	152	96,7	61,27
<b>G2</b>	0	142	14	1	0	0	0	0	0	0	0	0	157	90,4	35,31
<b>G3</b>	0	2	135	1	1	0	0	0	0	0	0	0	139	97,1	62,76
<b>G4</b>	0	1	0	145	1	1	0	0	0	2	0	0	150	96,7	60,44
<b>G5</b>	0	0	0	0	144	6	0	3	0	0	0	0	153	94,1	45,33
<b>G6</b>	0	0	0	2	0	140	3	0	1	0	0	0	146	95,9	53,48
<b>G7</b>	0	0	1	1	0	3	146	4	0	0	0	0	155	94,2	45,95
<b>G8</b>	0	0	0	0	0	0	1	139	2	0	0	0	142	97,9	74,34
<b>G9</b>	0	0	0	0	2	0	0	0	143	6	1	39	191	74,9	21,81
<b>G10</b>	0	0	0	0	2	0	0	4	3	131	0	8	148	88,5	30,94
<b>G11</b>	0	0	0	0	0	0	0	0	0	4	143	10	157	91,1	36,68
<b>G12</b>	3	0	0	0	0	0	0	0	1	5	6	93	108	86,1	23,58
Total	150	150	150	150	150	150	150	150	150	150	150	150	1800		
Exatidão do produtor	98,0	94,7	90,0	96,7	96,0	93,3	97,3	92,7	95,3	87,3	95,3	62,0			

Exatidão global = 91,6; Kappa = 0,908; Variância = 0,000051; Z calculado = 127,14; Z tabelado = 1,96.

Esta confusão pode ser explicada pelas características das variáveis discriminantes que são muito parecidas entre estas classes (Figura 7). É possível observar que a classe G12 difere da classe G9, basicamente, em relação à declividade que é ligeiramente mais elevada na classe G9 (média re-escalada entre 0 e 1 das amostras de treinamento), e ao aspecto que é ligeiramente maior, em termos de azimuth, na classe G12. Para as demais variáveis discriminantes utilizadas o comportamento é muito semelhante; principalmente, em relação aos índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7. Com relação à classe G10, nota-se que a diferenciação se dá, mais marcadamente, pela declividade (8 a 15% na G10 e 5 a 8% na G12), pelo aspecto e pelo índice CTI, visto que a classe G12 ocupa as áreas suavemente onduladas e a G10 o topo ondulado dos morros. Assim, a confusão com a classe G10 pode ser atribuída a um erro do classificador em discriminar corretamente os pixels. Por sua vez,

a classe G11 difere da G12 em relação à declividade, que é ligeiramente maior na classe G12, e ao índice Cti (Figura 7).



**FIGURA 7. Distribuição das variáveis discriminantes entre as classes G9, G10, G11 e G12.**  
 \* valores das variáveis discriminantes re-escalados entre 0 e 1 para permitir a apresentação em conjunto.

As demais classes de solos avaliadas pelo classificador por redes neurais obtiveram uma exatidão bastante satisfatória, com mais de 90% dos pixels sendo corretamente classificados, com exceção da classe G10 que obteve uma exatidão de 87,3% (Tabela 6).

Na Tabela 7 é apresentada a matriz de confusão obtida para a classificação pelo algoritmo da máxima verossimilhança. Nesta classificação, os piores desempenhos foram obtidos para as classes G8 e G12 com uma exatidão de 60 e 56%, respectivamente (Tabela 7), contra 92,7 e 62% obtido pelo classificador por redes neurais para as mesmas classes (Tabela 6).

**TABELA 7. Matriz de confusão obtida na classificação pelo algoritmo MAXVER.**

Classe	G1	G2	G3	G4	G5	G6	G7	G8	G9	G10	G11	G12	Total	Exatidão do Usuário	Z
<b>G1</b>	146	5	13	0	0	0	0	0	0	0	0	0	164	89,0	33,41
<b>G2</b>	4	124	0	0	0	0	0	0	0	0	0	0	128	96,9	57,71
<b>G3</b>	0	21	137	0	0	0	0	0	0	0	0	0	158	86,7	29,38
<b>G4</b>	0	0	0	141	3	21	1	33	8	4	0	0	211	66,8	18,81
<b>G5</b>	0	0	0	0	137	2	0	16	4	0	0	1	160	85,6	28,24
<b>G6</b>	0	0	0	0	0	123	2	0	1	0	0	0	126	97,6	65,85
<b>G7</b>	0	0	0	5	0	4	147	9	0	0	0	0	165	89,1	33,63
<b>G8</b>	0	0	0	4	1	0	0	90	0	1	0	0	96	93,8	34,70
<b>G9</b>	0	0	0	0	0	0	0	2	136	14	21	61	234	58,1	16,37
<b>G10</b>	0	0	0	0	9	0	0	0	0	131	0	3	143	91,6	36,17
<b>G11</b>	0	0	0	0	0	0	0	0	0	0	124	1	125	99,2	114,11
<b>G12</b>	0	0	0	0	0	0	0	0	1	0	5	84	90	93,3	32,44
Total	150	150	150	150	150	150	150	150	150	150	150	150	1800		
Exatidão do Produtor	97,3	82,7	91,3	94,0	91,3	82,0	98,0	60,0	90,7	87,3	82,7	56,0			

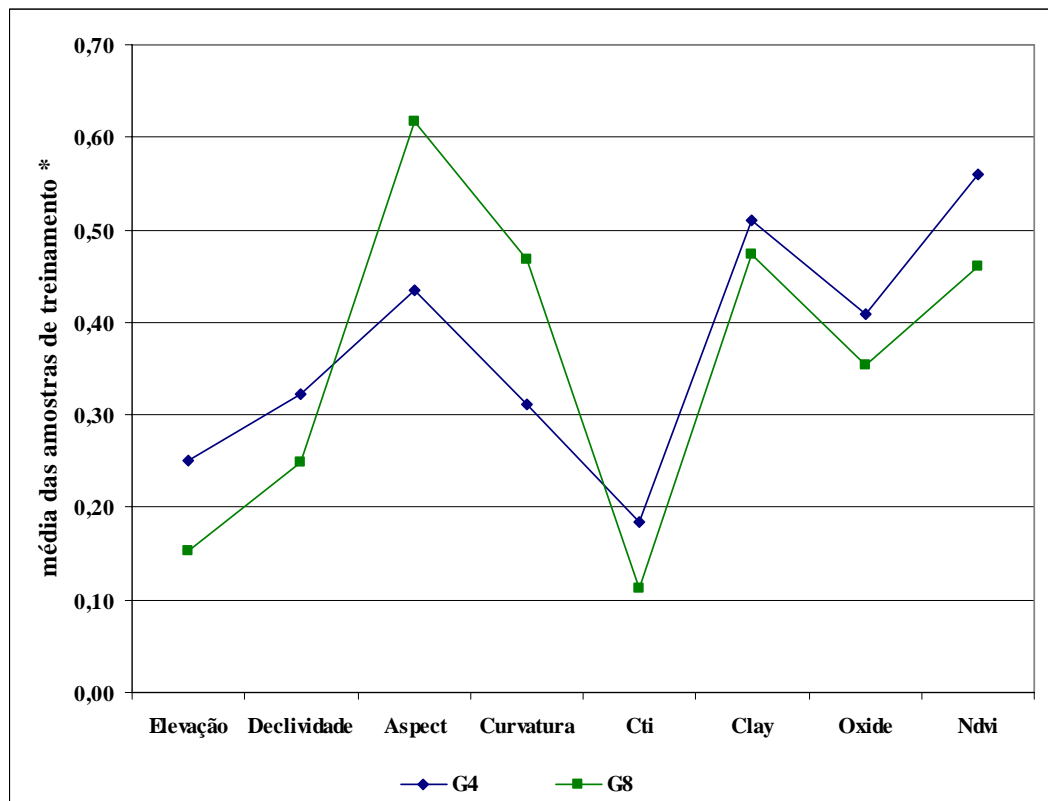
Exatidão global = 84,4; Kappa = 0,830; Variância = 0,000086; Z calculado = 89,35; Z tabelado = 1,96.

A classe G8 apresentou uma maior confusão com a classe G4, com 22% dos pixels que deveriam ser assinalados à classe G8 sendo assinalados erroneamente para a classe G4, resultado bastante inferior ao obtido pela classificação por redes neurais que obteve uma exatidão de 92,7%. Os valores médios das variáveis discriminantes destas classes são bem distintos (Figura 8) e sob estas condições o classificador MAXVER se mostrou menos hábil do que o classificador por redes neurais na discriminação destas classes.

40,67% dos pixels considerados como pertencentes à classe G12 foram assinalados à classe G9 (Tabela 7). A Figura 7 mostra que esta confusão está em parte relacionada com as características das variáveis discriminantes destas classes que são muito parecidas, conforme já mencionado quando da apresentação dos resultados para o classificador por redes neurais. Assim, os resultados obtidos pela classificação por redes neurais para a classe G12 (62%), sugerem uma menor eficiência do classificador MAXVER.

Do total de pixels da classe G11, 21 (14%) foram assinalados para classe G9 (Tabela 7). A Figura 7 mostra que estas classes são separadas, basicamente, pela declividade, que é maior na classe G9 (ondulado) e pelo aspecto (maior na classe G11), características que possibilitam uma boa separabilidade entre estas. Assim, os resultados

obtidos pela classificação por redes neurais para a classe G11 (95,3%), comprovam a menor eficiência do classificador MAXVER.



**FIGURA 8.** Distribuição das variáveis discriminantes entre as classes G4 e G8. \* valores das variáveis discriminantes re-escalados entre 0 e 1 para permitir a apresentação em conjunto.

Dentre as classes de solos avaliadas pelo classificador MAXVER, a maior exatidão foi obtida para as classes G7 (98%) e G1 com 97,3% dos pixels sendo corretamente classificados (Tabela 7).

Finalmente, uma comparação, entre a classificação pelas redes neurais e pelo algoritmo MAXVER, mostra que as diferentes classes de solo da Área 1 tiveram comportamento diferenciado entr



### 3.2. Área 2 (migmatitos das Unidades Vista Alegre, São João do Paraíso e Catalunha e milonito gnaissé da Unidade Santo Eduardo)

A escolha do melhor conjunto de variáveis discriminantes para a identificação das classes de solos da Área 2 foi realizada com base na avaliação do índice Kappa (Figura 9), já que, anteriormente, o MSE não se mostrou adequado para a escolha do melhor conjunto de variáveis para a Área 1.

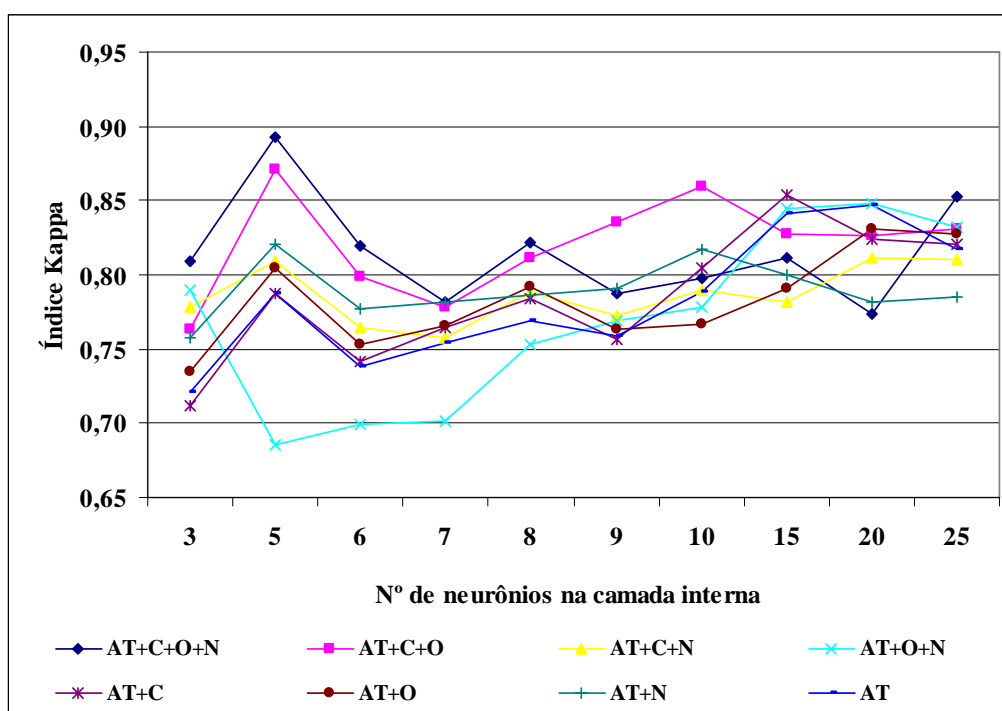


FIGURA 9. Resultados do índice Kappa das redes neurais para os conjuntos de variáveis discriminantes testados (AT - atributos do terreno; C - índice “clay minerals”; O - índice “iron oxide”; e N - índice NDVI).

Do mesmo modo como verificado para a Área 1, na Figura 9 também se observa que o índice Kappa variou bastante em função do conjunto de variáveis discriminantes utilizado e do número de neurônios na camada interna da rede neural. A combinação dos atributos do terreno com todos os índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7 foi a que apresentou o melhor desempenho para o índice Kappa (0,893) para uma rede neural com 5 neurônios na camada interna. O melhor desempenho para o conjunto 2 (atributos do terreno + índice “clay minerals” + índice “iron oxide”) foi obtido também com uma arquitetura de rede com 5 neurônios na camada interna (0,871). O melhor desempenho para os conjuntos 3 (atributos do terreno + índice “clay

minerals” + índice NDVI) e 4 (atributos do terreno + índice “iron oxide” + índice NDVI) foi alcançado utilizando uma rede neural com 20 neurônios na camada interna (0,811 e 0,848, respectivamente).

O conjunto 5 (atributos do terreno + índice “clay minerals”) obteve um desempenho para o índice Kappa de 0,854 para uma arquitetura de rede com 15 neurônios na camada interna. Os conjuntos 6 (atributos do terreno + índice “iron oxide”) e 8 (atributos do terreno) obtiveram o melhor desempenho com uma rede contendo 20 neurônios na camada interna (0,831 e 0,847, respectivamente). Finalmente, o conjunto 7 (atributos do terreno + índice NDVI) obteve um índice Kappa de 0,821 para uma arquitetura de rede composta por 5 neurônios na camada interna.

Uma matriz de significância foi utilizada para comparar o desempenho do índice Kappa dos diferentes conjuntos de variáveis discriminantes testados (Tabela 8).

**TABELA 8. Matriz de significância de Kappa e respectivos índices para os conjuntos de variáveis discriminantes testados.**

Conjunto	AT+C+ O+N (5) <sup>a</sup>	AT+C +O (5) <sup>a</sup>	AT+C +N (20) <sup>a</sup>	AT+O +N (20) <sup>a</sup>	AT+C (15) <sup>a</sup>	AT+O (20) <sup>a</sup>	AT+N (5) <sup>a</sup>	AT (20) <sup>a</sup>
<b>Exatidão global</b>	90,4	88,4	82,9	86,3	86,9	84,8	83,9	86,2
<b>Kappa</b>	0,893	0,871	0,811	0,848	0,854	0,831	0,821	0,847
<b>Variância<sup>b</sup></b>	0,071	0,084	0,115	0,096	0,093	0,105	0,0110	0,098
<b>1 - AT+C+O+N</b>	105,98							
<b>2 - AT+C+O</b>	1,77	95,03						
<b>3 - AT+C+N</b>	6,01*	4,25*	75,63					
<b>4 - AT+O+N</b>	3,48*	1,71	2,55*	86,55				
<b>5 - AT+C</b>	3,05*	1,28	2,98*	0,44	88,56			
<b>6 - AT+O</b>	4,67*	2,91*	1,35	1,20	1,64	81,10		
<b>7 - AT+N</b>	5,35*	3,59*	0,67	1,88	2,32*	0,68	78,28	
<b>8 - AT</b>	3,54*	1,78	2,47*	0,07	0,51	1,12	1,80	85,56

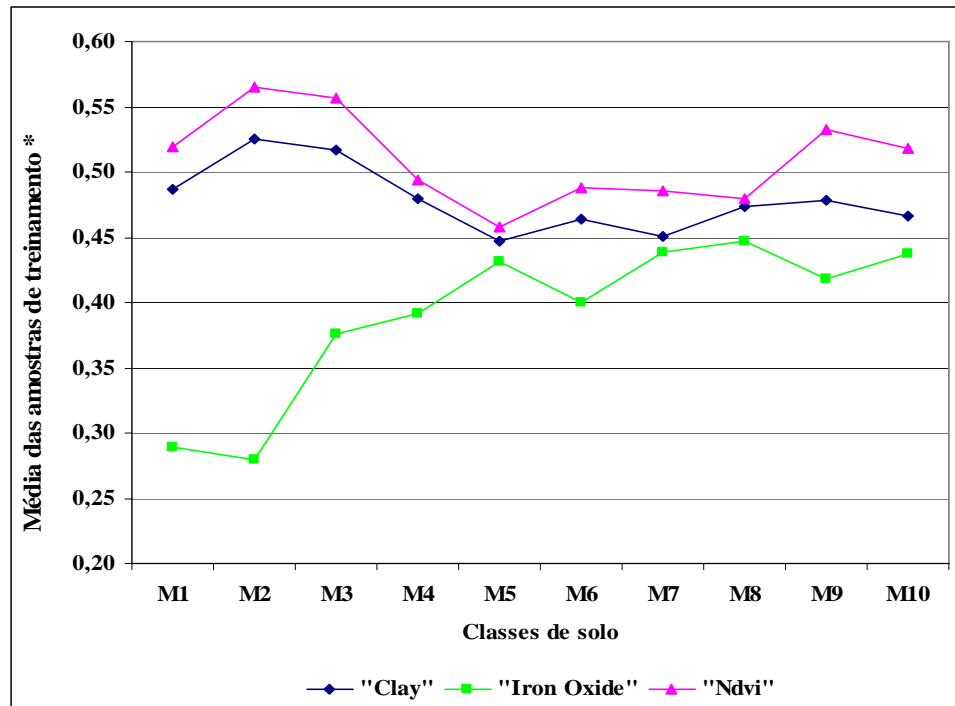
\* existe diferença significativa ao nível de 95%; <sup>a</sup> n°. de neurônios na camada interna; <sup>b</sup> valores multiplicados por 1000; AT - atributos do terreno; C - índice “clay minerals”; O - índice “iron oxide”; e N - índice NDVI.

O melhor desempenho do índice Kappa foi obtido pela combinação dos atributos do terreno com os índices derivados do sensor ETM<sup>+</sup> do LANDSAT 7. Este não difere apenas do conjunto de variáveis 2 (Tabela 8). Conforme verificado na avaliação das variáveis para discriminação dos solos da Área 1, a adição do índice NDVI aos atributos do terreno, isoladamente ou junto com o índice “clay minerals” piorou a classificação dos dados (conjuntos 3 e 7) (Tabela 8). Dentre os índices utilizados, a maior

contribuição para a discriminação dos solos da área estudada parece ser dada pelo índice “clay minerals”, visto que a combinação deste com os atributos do terreno, isoladamente (conjunto 5) ou junto com os outros índices (conjuntos 1 e 2) obteve os melhores resultados.

O índice “iron oxide”, quando associado com os atributos do terreno, produziu resultados ligeiramente melhores do que o índice NDVI. No entanto, ambos não contribuíram efetivamente para melhorar a classificação, já que o resultado obtido, quando foram utilizados apenas os atributos do terreno, é superior a estes, embora estatisticamente todos sejam semelhantes (Tabela 8). Do mesmo modo como observado para a Área 1, aqui também o fenômeno de Hughes foi verificado para quase todos os conjuntos de variáveis testados, exceto quando os três índices foram utilizados em combinação com os atributos do terreno.


A contribuição dos diferentes atributos do terreno e dos índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7, para a discriminação das classes de solo da Área 2 é mostrada nas Figuras 10 e 11 (médias das amostras de treinamento re-escaladas entre 0 e 1). Os índices NDVI e “clay5 minerals” mostram uma distribuição pouco diferenciada entre as classes de solo e muito parecida entre estes (Figura 10). Os valores do índice “clay minerals” para as classes M2 (Neossolo Litólico Eutrófico típico ou Neossolo Regolítico Eutrófico léptico) e M3 (Cambissolo Háplico Ta Eutrófico típico) são ligeiramente superiores às demais classes, o que pode contribuir para uma melhor discriminação destas classes em relação às outras.



**FIGURA 10.** Distribuição dos índices da imagem do sensor ETM<sup>+</sup> do LANDSAT 7 entre as classes de solo da Área 2. \* valores dos índices re-escalados entre 0 e 1 para permitir a apresentação em conjunto.

O índice “iron oxide” apresenta um comportamento semelhante ao verificado na Área 1, com as unidades M1 (Afloramentos de rocha), M2, M3 e M4 (Cambissolo Háplico Ta Eutrófico típico ou léptico ou lítico ou argissólico) apresentando valores distintos das demais unidades (Figura 10), o que propiciou uma melhora no desempenho do treinamento das redes quando se utilizou este índice como variável discriminante.

Semelhantemente ao observado na Área 1, a contribuição dos atributos do terreno para a discriminação das classes de solos da Área 2 é mais marcante do que a contribuição dos índices derivados da imagem do sensor ETM<sup>+</sup> do LANDSAT 7 (Figura 11). Dentre os atributos, apenas a curvatura mostra pouca diferenciação entre as classes. Entretanto, esta é muito importante na separação da classe M4 das demais, visto que o valor negativo para a curvatura (côncava) é o principal atributo diferenciador desta classe.



**FIGURA 11. Distribuição dos atributos do terreno entre as classes de solo da Área 2. \* valores dos atributos do terreno re-escalados entre 0 e 1 para permitir a apresentação em conjunto.**

O índice CTI tem um comportamento muito parecido entre as classes M1, M2, M3, M4, M5 (Argissolo Vermelho Eutrófico abrupto), M6 (Argissolo Vermelho Eutrófico abrupto latossólico ou Luvisolo Háptico Órtico típico ou léptico), M7 (Argissolo Vermelho ou Vermelho-Amarelo Eutrófico abrupto relevo ondulado) e M8 (Latosolo Vermelho Distrófico típico), já que estas ocupam posição de terço médio ou superior de encosta. Por sua vez, os valores verificados para estas classes são bem distintos dos valores observados para as classes M9 (Gleissolo Háptico Ta Eutrófico solódico ou típico ou Cambissolo Háptico Ta Eutrófico gleico ou Planossolo Háptico Eutrófico solódico) e M10 (Argissolo Amarelo Eutrófico abrupto ou abrupto câmbico), que ocupam as áreas suavemente onduladas. O índice Cti foi utilizado, principalmente, para auxiliar na separação das classes M9 e M10 da classe M8 que ocorre em áreas de topos de morros levemente onduladas.

Assim, em função do seu melhor desempenho, o conjunto 1 (atributos do terreno + índices do sensor ETM<sup>+</sup> do LANDSAT 7) foi selecionado para a discriminação dos solos da Área 2. Uma matriz de significância de Kappa foi gerada entre as diferentes

arquitecturas de redes consideradas para este conjunto de variáveis discriminantes com o fim de verificar a existência de diferenças significativas ou não entre os resultados obtidos e para a escolha da melhor arquitetura de rede para a classificação final dos dados (Tabela 9).


**TABELA 9. Matriz de significância de Kappa e respectivos índices para as diferentes arquitecturas de redes neurais testadas.**

<b>Redes</b>	<b>R3</b>	<b>R5</b>	<b>R6</b>	<b>R7</b>	<b>R8</b>	<b>R9</b>	<b>R10</b>	<b>R15</b>	<b>R20</b>	<b>R25</b>
<b>Exatidão global</b>	82,8	90,4	83,7	80,4	83,9	80,8	81,8	82,9	79,6	86,8
<b>Kappa</b>	0,809	0,893	0,819	0,782	0,822	0,787	0,798	0,811	0,774	0,853
<b>Variância<sup>a</sup></b>	0,117	0,071	0,112	0,128	0,11	0,126	0,121	0,116	0,132	0,094
<b>R3</b>	74,79									
<b>R5</b>	6,13*	105,98								
<b>R6</b>	0,66	5,47*	77,39							
<b>R7</b>	1,73	7,87*	2,39*	69,12						
<b>R8</b>	0,86	5,28*	0,20	2,59*	78,38					
<b>R9</b>	1,41	7,55*	2,07*	0,31	2,28*	70,11				
<b>R10</b>	0,71	6,86*	1,38	1,01	1,58	0,70	72,55			
<b>R15</b>	0,13	6,00*	0,53	1,86	0,73	1,54	0,84	75,30		
<b>R20</b>	2,22*	8,35*	2,88*	0,50	3,09*	0,81	1,51	2,35*	67,37	
<b>R25</b>	3,03*	3,11*	2,37*	4,77*	2,17*	4,45*	3,75*	2,90*	5,26*	87,98

\* existe diferença significativa ao nível de 95%. <sup>a</sup> valores multiplicados por 1000.

Nesta avaliação, os maiores valores de exatidão global e índice Kappa e, conseqüentemente, os menores de variância, foram obtidos com uma arquitetura de rede com apenas uma camada interna contendo 5 neurônios (Kappa de 0,893), seguida da rede com 25 neurônios na camada interna (Kappa de 0,853). O aumento da complexidade da rede, com a adição de neurônios na camada interna, não melhorou substancialmente a exatidão da classificação (Tabela 9). No entanto, a rede com 5 neurônios na camada interna é significativamente diferente de todas as demais redes e por isso foi selecionada para auxiliar na predição das classes de solos da Área 2.

Continuando o processo de avaliação, foi realizada a comparação entre os diferentes conjuntos de variáveis utilizando o classificador de distribuição gaussiana por máxima verossimilhança (MAXVER). Esta comparação constou da verificação do desempenho do índice Kappa e utilizou os mesmos conjuntos de amostras de treinamento e validação utilizados na abordagem por redes neurais. Os resultados obtidos são apresentados na Figura 12.



**FIGURA 12.** Resultados do índice Kappa para a classificação MAXVER dos conjuntos de variáveis discriminantes testados (AT - atributos do terreno; C - índice “clay minerals”; O - índice “iron oxide”; e N - índice NDVI).

Nesta avaliação, o melhor desempenho foi obtido com a utilização do conjunto de variáveis 8 (atributos do terreno) que produziu uma exatidão global de 77,5%, índice Kappa de 0,750 e variância de 0,000142, diferentemente do que ocorreu para a classificação por redes neurais onde o melhor desempenho foi obtido pelo conjunto 1 (atributos do terreno + índices do sensor ETM<sup>+</sup> do LANDSAT 7). Estes resultados não são estatisticamente diferentes daqueles obtidos para os conjuntos 5 e 6, conforme mostra a matriz de significância de Kappa entre as classificações MAXVER consideradas (Tabela 10).

**TABELA 10. Matriz de significância de Kappa para as classificações MAXVER consideradas.**

Conjuntos	AT+C+ O+N	AT+C +O	AT+C +N	AT+O +N	AT+C	AT+O	AT+N	AT
<b>Exatidão global</b>	72,3	73,8	74,4	72,6	75,5	75,3	73,6	77,5
<b>Kappa</b>	0,693	0,709	0,716	0,696	0,727	0,726	0,707	0,75
<b>Variância<sup>a</sup></b>	0,162	0,156	0,154	0,161	0,150	0,151	0,157	0,142
<b>1 - AT+C+O+N</b>	54,45							
<b>2 - AT+C+O</b>	0,90	56,77						
<b>3 - AT+C+N</b>	1,29	0,40	57,70					
<b>4 - AT+O+N</b>	0,17	0,73	1,13	54,85				
<b>5 - AT+C</b>	1,93	1,03	0,63	1,76	59,36			
<b>6 - AT+O</b>	1,87	0,97	0,57	1,70	0,06	59,08		
<b>7 - AT+N</b>	0,78	0,11	0,51	0,62	1,14	1,08	56,43	
<b>8 - AT</b>	3,27*	2,38*	1,98*	3,10*	1,35	1,40	2,49*	62,94

\* existe diferença significativa ao nível de 95%; <sup>a</sup> valores multiplicados por 1000; AT - atributos do terreno; C - índice “clay minerals”; O - índice “iron oxide”; e N - índice NDVI.

Finalmente, foi realizada a comparação entre o desempenho da classificação pela abordagem por redes neurais e pelo algoritmo MAXVER. A análise da matriz de significância de Kappa (Tabela 11) indica haver diferença significativa entre estas classificações.

**TABELA 11. Matriz de significância de Kappa para os classificadores considerados.**

Classificador	MAXVER	Rede neural
<b>Exatidão global</b>	77,5	90,4
<b>Kappa</b>	0,750	0,893
<b>Variância</b>	0,000142	0,000071
<b>MAXVER</b>	62,94	-
<b>Rede neural</b>	9,80*	105,98

\* existe diferença significativa ao nível de 95%.

A comparação entre a exatidão obtida pelos classificadores para cada classe de solo da Área 2 é apresentada a seguir. Nas Tabelas 12 e 13 são apresentadas as matrizes de confusão obtidas para as classificações realizadas. O pior desempenho obtido pela classificação por redes neurais ocorreu para a classe M5 (Argissolo Vermelho Eutrófico abruptico) com uma exatidão de 70,7%. Esta classe teve uma maior confusão com a classe M6 (Argissolo Vermelho Eutrófico abruptico latossólico ou Luvisolo Háptico Órtico típico ou léptico), com 24 pixels (16,0%) sendo erroneamente classificados. As classes M5 e M6 apresentam características ambientais muito semelhantes, sendo diferenciadas apenas com relação ao aspecto (Figura 13), com a classe M5 apresentando

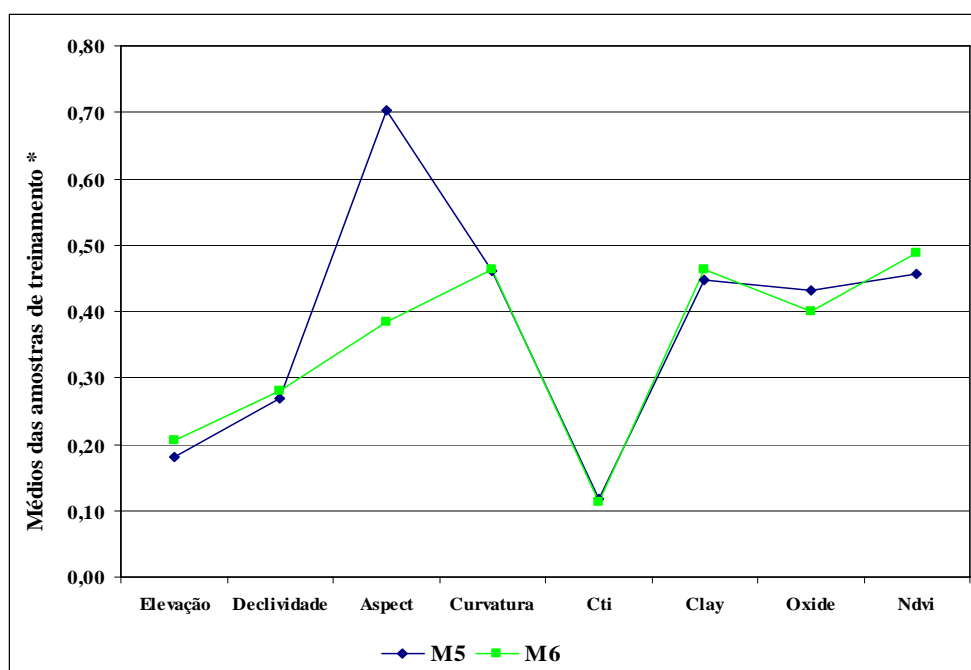


valores mais elevados (média normalizada entre 0 e 1 das amostras de treinamento). A classe M5 ocupa as encostas voltadas para noroeste, nordeste ou sudoeste e a classe M6 as encostas orientadas para sudeste. As demais variáveis apresentam valores muito semelhantes e contribuem pouco para a separação destas classes.

**TABELA 12. Matriz de confusão obtida na classificação por redes neurais.**

Classe	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	Total	Exatidão do Usuário	Z
M1	150	2	1	0	0	1	0	0	0	0	154	97,4	68,38
M2	0	145	2	3	0	3	0	0	0	0	153	94,8	47,37
M3	0	2	143	1	0	7	3	0	0	0	156	91,7	37,25
M4	0	1	0	139	7	1	0	0	0	0	148	93,9	42,99
M5	0	0	3	1	106	3	0	7	0	0	120	88,3	26,99
M6	0	0	1	6	24	125	0	9	0	0	165	75,8	20,30
M7	0	0	0	0	3	0	128	2	0	1	134	95,5	48,07
M8	0	0	0	0	10	9	17	130	4	2	172	75,6	20,63
M9	0	0	0	0	0	0	0	0	146	3	149	98,0	76,63
M10	0	0	0	0	0	0	2	2	0	144	148	97,3	65,68
Total	150	150	150	150	150	150	150	150	150	150	1500		
Exatidão do Produtor	100	96,7	95,3	92,7	70,7	83,3	85,3	86,7	97,3	96,0			


Exatidão global = 90,4; Kappa = 0,893; Variância = 0,000071; Z calculado = 105,79; Z tabelado = 1,96.



**FIGURA 13. Distribuição das variáveis discriminantes entre as classes M5 e M6. \* valores das variáveis discriminantes re-escalados entre 0 e 1 para permitir a apresentação em conjunto.**

Do total dos pixels considerados como pertencentes à classe M7 (Argissolo Vermelho ou Vermelho-Amarelo Eutrófico abrupto relevo ondulado), 17 (11,24%) foram assinalados para a classe M8 (Latosolo Vermelho Distrófico típico - topo de morro) (Tabela 12). Na Figura 14 observa-se que estas classes se diferenciam, basicamente, pela elevação que é ligeiramente maior na classe M8 (média normalizada entre 0 e 1 das amostras de treinamento), e em menor proporção, pelo aspecto e pelo índice CTI.

As demais classes apresentaram uma exatidão superior a 85% e as confusões que ocorrem são pouco significativas. Dentre as classes de solos avaliadas pelo classificador por redes neurais, as maiores exatidões foram obtidas para as classes M1, M9, M2 e M10, com exatidão superior a 95% (Tabela 12).



**FIGURA 14.** Distribuição das variáveis discriminantes entre as classes M7 e M8. \* valores das variáveis discriminantes re-escalados entre 0 e 1 para permitir a apresentação em conjunto.

A matriz de confusão obtida para a classificação pelo algoritmo da máxima verossimilhança é apresentada na Tabela 13.

**TABELA 13. Matriz de confusão obtida na classificação pelo algoritmo MAXVER.**


Classe	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	Total	Exatidão do Usuário	Z
<b>M1</b>	149	11	0	0	0	0	0	0	0	0	160	93,1	41,879
<b>M2</b>	1	118	0	5	0	4	0	0	0	0	128	92,2	34,893
<b>M3</b>	0	21	120	0	0	2	0	0	0	0	143	83,9	24,455
<b>M4</b>	0	0	0	100	0	3	0	0	0	0	103	97,1	52,671
<b>M5</b>	0	0	30	25	140	64	1	18	0	0	278	50,4	14,901
<b>M6</b>	0	0	0	20	0	71	1	0	0	0	92	77,2	15,580
<b>M7</b>	0	0	0	0	2	2	123	14	4	6	151	81,5	23,046
<b>M8</b>	0	0	0	0	8	4	20	118	7	0	157	75,2	19,426
<b>M9</b>	0	0	0	0	0	0	0	0	79	0	79	100,0	0,000
<b>M10</b>	0	0	0	0	0	0	5	0	60	144	209	68,9	19,276
Total	150	150	150	150	150	150	150	150	150	150	1500		
Exatidão do Produtor	99,3	78,7	80,0	66,7	93,3	47,3	82,0	78,7	52,7	96,0			
Exatidão global = 77,5; Kappa = 0,750; Variância = 0,000142; Z calculado = 62,97; Z tabelado = 1,96.													

Na classificação pelo algoritmo MAXVER, os piores desempenhos foram obtidos para as classes M6, M9 e M4 com uma exatidão de 47,3, 52,7 e 66,7%, respectivamente (Tabela 13), contra 83,3, 97,3 e 92,7% obtido pelo classificador por redes neurais para as mesmas classes (Tabela 12).

A classe M6 apresentou uma maior confusão com a classe M5, com 42,7% dos pixels que deveriam ser assinalados à classe M6 sendo assinalados erroneamente para a classe M5. Com isso, a exatidão obtida é bastante inferior à obtida pela classificação por redes neurais que teve uma exatidão de 83,3%. Esta confusão também ocorreu na classificação pela rede neural, porém em menor proporção (Tabela 12), o que demonstra que, sob estas condições, o classificador MAXVER é menos eficiente do que o classificador por redes neurais na discriminação destas classes.

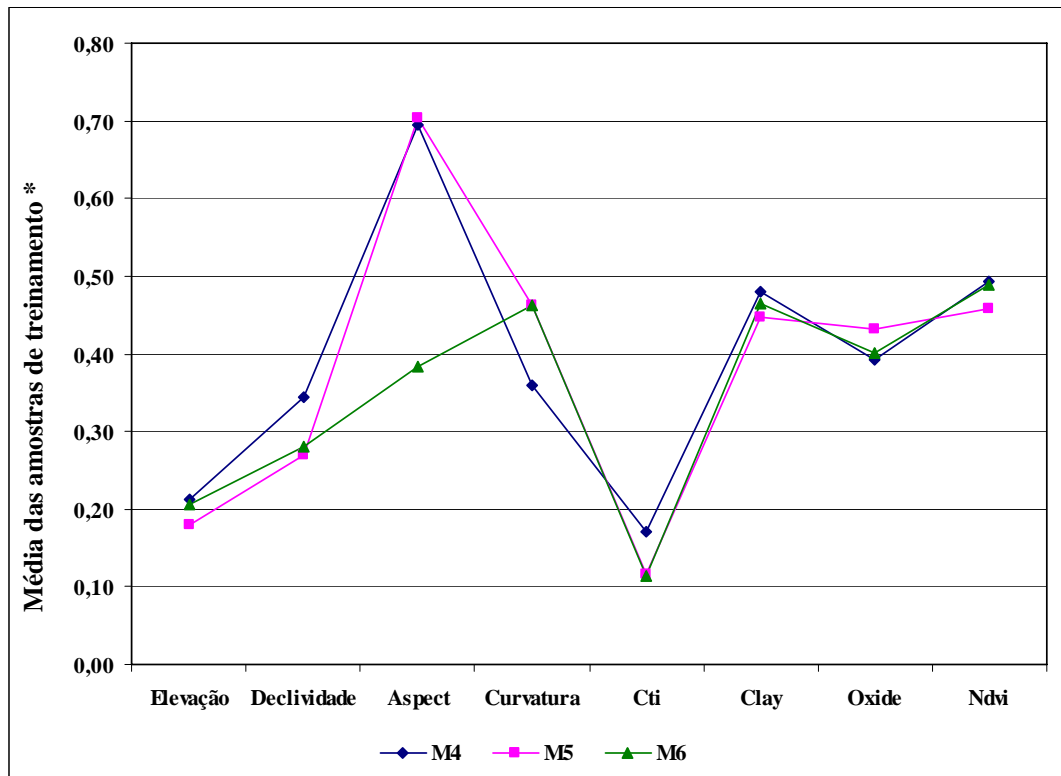
40% dos pixels considerados como pertencentes à classe M9 foram erroneamente assinalados à classe M10 (Argissolo Amarelo Eutrófico abruptico ou abruptico câmbico) (Tabela 13). A Figura 15 mostra que as características ambientais destas classes são muito parecidas, o que contribui para que haja uma confusão entre elas. O atributo que mais contribui para separação destas classes é o índice Cti que é

ligeiramente mais elevado na classe M9, que ocupa uma posição mais baixa na paisagem. Por outro lado, o resultado obtido pela rede neural para a classe M9 (97,3%), evidencia a menor eficiência do classificador MAXVER.



**FIGURA 15. Distribuição das variáveis discriminantes entre as classes M9 e M10. \* valores das variáveis discriminantes re-escalados entre 0 e 1 para permitir a apresentação em conjunto.**

Do total de pixels pertencentes à classe M4, 25 pixels (16,7%) foram assinalados para classe M5 e 20 (13,3%) à classe M6 (Tabela 13). As classes M4 e M5 são diferenciadas, principalmente, pela elevação, declividade e curvatura (Figura 16), características que, embora pouco pronunciadas, possibilitam uma boa separabilidade entre estas, como mostra o resultado obtido pela classificação por redes neurais para a classe M4 (92,7%). Por sua vez, a confusão com a classe M6 parece estar mais relacionado com uma deficiência do classificador visto que a diferença no aspecto é marcante entre as classes M4 e M6, como mostra a Figura 16.



**FIGURA 16. Distribuição das variáveis discriminantes entre as classes M4, M5 e M6. \* valores das variáveis discriminantes re-escalados entre 0 e 1 para permitir a apresentação em conjunto.**

As demais classes, embora tenham apresentado alguma confusão, tiveram um bom desempenho na classificação pelo algoritmo MAXVER, com valores de exatidão superiores a 78,7%. Dentre estas classes a maior exatidão foi obtida para a classe M1 (99,3%), seguida pelas classes M10 e M5, com 96,0 e 93,3%, respectivamente, dos pixels sendo corretamente classificados (Tabela 13). Por último, a comparação entre a classificação pelas redes neurais e pelo algoritmo MAXVER para a Área 2 mostrou que a rede neural foi superior na classificação de quase todas as classes, com exceção da M5 onde a classificação MAXVER foi superior (Tabelas 12 e 13).

### 3.3. Análise da Concordância entre as Classificações

As redes neurais, depois de treinadas e validadas, juntamente com o algoritmo MAXVER, foram utilizadas para predição das classes de solo da bacia do rio São Domingos. Para tanto, as informações sobre as condições ambientais (variáveis discriminantes) 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) para uma representação booleana. A conversão foi feita adicionando a cada pixel o valor correspondente à classe que apresentou a maior porcentagem 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 (redes neurais e MAXVER).

Embora, os resultados obtidos para o índice Kappa, quando se utilizou os conjuntos de amostras de validação, tenham sido bastante satisfatórios para ambos os classificadores ( $>0,75$ ), sugerindo um desempenho do classificador de muito bom a excelente (Landis & Koch, 1977; Monserud & Leemans, 1992), os mapas de solos da bacia do rio São Domingos produzidos por estes classificadores mostram-se distintos. A análise da concordância entre as classificações para as classes de solo consideradas (Figura 17) mostra que a concordância entre o mapa produzido pela abordagem por redes neurais e pelo algoritmo MAXVER foi de apenas 49,68%. Esta baixa concordância evidencia a natureza distinta dos modelos matemáticos presentes nestes classificadores e o modo como eles dividem o espaço (Kanellopoulos & Wilkinson, 1997).



**FIGURA 17. Comparação entre os mapas temáticos produzidos pelos classificadores.**



**FIGURA 18. Mapa produzido pelas redes neurais.**



**FIGURA 19. Mapa produzido pelo MAXVER.**

**FIGURA 20. Mapa convencional.**

**TABELA 14. Legenda utilizada nos mapas de solos da bacia do rio São Domingos para ambos os classificadores.**

---

1	- AFLORAMENTOS DE ROCHA relevo escarpado ou NEOSSOLO LITÓLICO Eutrófico típico relevo montanhoso
2	- CAMBISSOLO HÁPLICO Tb Eutrófico típico ou léptico relevo forte ondulado substrato granulitos
3	- ARGISSOLO VERMELHO Eutrófico câmbico ou ARGISSOLO VERMELHO-AMARELO Eutrófico câmbico relevo forte ondulado e montanhoso
4	- ARGISSOLO VERMELHO Eutrófico típico ou NITOSSOLO VERMELHO Eutrófico típico relevo forte ondulado e montanhoso
5	- ARGISSOLO VERMELHO-AMARELO Eutrófico típico ou ARGISSOLO VERMELHO-AMARELO Distrófico latossólico relevo forte ondulado e montanhoso
6	- ARGISSOLO VERMELHO Eutrófico típico ou câmbico ou ARGISSOLO VERMELHO-AMARELO Eutrófico típico ou câmbico relevo ondulado
7	- LATOSSOLO VERMELHO-AMARELO Distrófico típico relevo suave ondulado (topo de morro)
8	- GLEISSOLO HÁPLICO Ta ou Tb Eutrófico solódico ou típico ou CAMBISSOLO HÁPLICO Ta ou Tb Eutrófico gleico relevo plano
9	- ARGISSOLO AMARELO Eutrófico típico ou câmbico relevo suave ondulado
10	- CAMBISSOLO HÁPLICO Ta ou Tb Eutrófico típico ou léptico relevo forte ondulado substrato migmatitos ou milonitos
11	- ARGISSOLO VERMELHO Eutrófico abrúptico relevo forte ondulado e montanhoso
12	- ARGISSOLO VERMELHO Eutrófico abrúptico latossólico ou ARGISSOLO VERMELHO-AMARELO Distrófico abrúptico latossólico relevo forte ondulado e montanhoso
13	- ARGISSOLO VERMELHO Eutrófico abrúptico ou abrúptico câmbico ou ARGISSOLO VERMELHO-AMARELO Eutrófico abrúptico ou abrúptico câmbico relevo ondulado
14	- LATOSSOLO VERMELHO Distrófico típico relevo suave ondulado (topo de morro)
15	- LUVISSOLO HIPOCRÔMICO Órtico típico relevo forte ondulado e montanhoso
16	- ARGISSOLO AMARELO Eutrófico abrúptico ou abrúptico câmbico relevo suave ondulado
17	- ARGISSOLO VERMELHO Eutrófico abrúptico câmbico relevo forte ondulado e montanhoso

---

Nos mapas inferidos a ocorrência de mais de uma classe de solo em um determinado pixel se deve exclusivamente a dificuldade de estabelecimento de relações solo-paisagem mais precisas, impostas: 1) pelo tamanho do pixel utilizado pelas variáveis ambientais discriminantes; 2) pela grande heterogeneidade geológica da área, como a ocorrência de Argissolos Vermelhos Abrúpticos latossólicos e Luvisolos Hipocrômicos, na Unidade Vista Alegre, em encostas forte onduladas e montanhosas voltadas para sudeste; 3) pela falta de informação sobre a profundidade de ocorrência do contato lítico, como a ocorrência de Argissolos Vermelhos e Vermelho-Amarelos típicos ou câmbicos, na Unidade São José de Ubá e Argissolos Vermelhos e Vermelho-Amarelos abrúpticos ou abrúpticos câmbicos, nas Unidades Vista Alegre, São João do Paraíso, Catalunha e Santo Eduardo, todos ocorrendo em áreas de relevo ondulado; 4) pelas características do Sistema Brasileiro de Classificação de Solos (Embrapa, 1999),

como a ocorrência de Argissolos Vermelhos e Nitossolos Vermelhos em encostas forte onduladas e montanhosas voltadas para o norte; e 5) pela presença de forte dependência espacial das propriedades dos solos, como no caso da ocorrência de Argissolos Vermelho-Amarelos Eutróficos ou Distróficos em encostas forte onduladas e montanhosas voltadas para sul, de argila de atividade alta ou baixa em Gleissolos e Cambissolos da Unidade Vista Alegre, de caráter solódico ou não solódico em Gleissolos. Segundo McKenzie & Ryan (1999), a presença de dependência espacial sugere que alguma forma de krigagem seja usada para fazer a predição espacial e contornar este problema, o que, no entanto, está além dos objetivos deste trabalho.

Assim, as diferenças observadas entre os mapas de solos produzidos pelos classificadores utilizados e o mapa de solos convencional se deve, em grande parte, a limitação de escala do mapa convencional (reconhecimento de média intensidade), conforme observado por Zhu et al. (2001).

A natureza mais generalizada do mapa convencional dificultou a análise da concordância com os mapas inferidos. Para contornar este problema e evidenciar o maior detalhamento destes últimos foram determinadas, para cada unidade de mapeamento do mapa de solos convencional, as classes de solos identificadas nos mapas inferidos. Os resultados da Tabela 15 mostram que foram identificadas nestes mapas mais classes de solos do que no mapa de solos convencional em todas as unidades de mapeamento, evidenciando, assim, o maior detalhamento espacial dos primeiros. Estes resultados evidenciam também a dificuldade e a inexatidão da delimitação manual dos limites das unidades de mapeamento nas fotografias aéreas convencionais, conforme também observado por Zhu et al. (2001).

Neste sentido, vários especialistas têm expressado sua preocupação com relação à confiabilidade da informação fornecida pelos mapas de solos (Webster & Beckett, 1968; Burrough et al., 1971; Marsman & De Gruijter, 1984). Marsman & De Gruijter, (1986) relataram purezas médias variando de 64 a 70% para mapas de solos na escala de 1:50.000, com valores extremos entre 34 e 100%. Estudos realizados por Nordt et al., (1991) e Young et al. (1997) mostraram que a pureza estatística das unidades de mapeamento é menor do que 50%. Wilding et al. (1965) avaliaram a pureza de algumas unidades de mapeamento nos Estados Unidos e encontraram valores distintos para os

diferentes níveis de classificação, conforme a seguir: grande grupo, 96%; subgrupo, 85%; série, 42%; e tipo, apenas 39%.

**TABELA 15. Resultados obtidos para a comparação entre os mapas de solos inferidos e o mapa de solos convencional.**

Unidades	Mapa convencional		Mapas inferidos		
	Classes	% <sup>a</sup>	Classes <sup>b</sup>	Redes neurais (%)	MAXVER (%)
<b>AR1</b>	Afloramentos de rocha	50	<b>AR + RLe típico</b>	<b>43,4</b>	<b>45,7</b>
	CXd Tb típico	30	<b>CXe Tb típico (granulitos)</b>	<b>10,3</b>	<b>8,9</b>
	RLe típico	20	PVAe típico ou PVAd latossólico	8,8	4,6
			CXe Ta ou Tb típico (migmatitos)	7,6	24,5
		PVe abruptico	19,1	5,2	
<b>AR2</b>	Afloramentos de rocha	40	<b>AR + RLe típico</b>	<b>31,8</b>	<b>16,2</b>
	Cxe Tb típico	40	<b>Cxe Tb típico (granulitos)</b>	<b>33,0</b>	0,0
	RLe típico	20	PVe ou PVAe câmbico	<b>9,2</b>	28,7
			PVAe típico ou PVAd latossólico	<b>10,6</b>	33,2
		<b>CXe Ta ou Tb típico (migmatitos)</b>	<b>1,3</b>	<b>5,4</b>	
<b>CXve1</b>	Cxe Ta típico	60	PVe ou PVAe câmbico	0,9	5,3
	PAe abruptico câmbico	20	PVe ou NVe típico	20,6	2,9
	GXe Ta típico	20	PVAe típico ou PVAd latossólico	7,0	4,0
		PVe ou PVAe típico (ondulado)	15,5	69,8	
		<b>GXe Ta ou Tb ou CXe Ta ou Tb gleico</b>	<b>47,0</b>	16,3	
		PAe típico	9,0	0,0	
<b>CXve2</b>	CXe Ta gleico	70	<b>GXe Ta ou Tb ou CXe Ta ou Tb gleico</b>	<b>46,7</b>	<b>18,4</b>
	GXe Ta típico	30	PAe típico ou câmbico	0,0	37,0
			CXe Ta ou Tb típico (migmatitos)	9,6	2,4
			PVe abruptico	16,9	11,9
			PVe ou PVAe abruptico (ondulado)	9,2	27,4
			PAe abruptico ou abruptico câmbico	13,6	0,0
<b>CXve3</b>	CXe Ta gleico	70	PVe ou PVAe típico (ondulado)	13,2	27,3
	GXe Ta solódico	30	<b>GXe Ta ou Tb ou CXe Ta ou Tb gleico</b>	<b>33,0</b>	<b>12,4</b>
			PVe abruptico	17,5	6,0
			PVe ou PVAe abruptico (ondulado)	12,3	26,0
		PAe abruptico ou abruptico câmbico	4,9	15,8	

<sup>a</sup> % de ocorrência na associação. <sup>b</sup> partes em negrito correspondem às classes identificadas nos mapas inferidos que são iguais ou semelhantes às classes identificadas no mapa convencional.

TABELA 15. Continuação.

Unidades	Mapa convencional		Mapas inferidos		
	Classes	% <sup>a</sup>	Classes <sup>b</sup>	Redes neurais (%)	MAXVER (%)
<b>CXve3</b>	CXe Ta gleico	70	PVe ou PV Ae típico (ondulado)	13,2	27,3
	GXe Ta solódico	30	<b>GXe Ta ou Tb ou CXe Ta ou Tb gleico</b>	<b>33,0</b>	<b>12,4</b>
			CXe Ta ou Tb típico (migmatitos)	6,3	3,3
			PVe abruptico	17,5	6,0
			PVe ou PV Ae abruptico (ondulado)	12,3	26,0
			TP Órtico típico	4,7	2,9
			PAe abruptico ou abruptico câmbico	4,9	15,8
<b>GXve1</b>	GXe Ta solódico e vértico	100	PVe ou PV Ae câmbico	16,2	6,5
			PAe típico ou câmbico	7,5	0,1
			PVe ou PV Ae típico (ondulado)	16,3	72,3
			<b>GXe Ta ou Tb ou CXe Ta ou Tb gleico</b>	<b>46,6</b>	<b>5,8</b>
<b>GXve2</b>	GXe Ta solódico PAe abruptico câmbico	70 30	PVe ou PV Ae câmbico	1,1	5,1
			PVe ou NVe típico	5,8	0,7
			PVe ou PV Ae típico (ondulado)	25,0	77,7
			<b>GXe Ta ou Tb ou CXe Ta ou Tb gleico</b>	<b>52,0</b>	<b>11,9</b>
			PAe típico ou câmbico	8,5	0,7
<b>GXve3</b>	GXe Ta solódico CXe Tb gleico	80 20	PVe ou NVe típico	7,8	3,8
			PVe ou PV Ae típico (ondulado)	20,7	45,4
			<b>GXe Ta ou Tb ou CXe Ta ou Tb gleico</b>	<b>39,4</b>	<b>11,7</b>
			PVe abruptico	9,6	6,8
			PVe ou PV Ae abruptico (ondulado)	6,6	13,2
			PAe abruptico ou abruptico câmbico	4,5	11,5
<b>GXve4</b>	GXe Ta solódico e vértico SXe solódico	80 20	PVe ou NVe típico	12,2	7,1
			PVe ou PV Ae típico (ondulado)	32,1	84,4
			<b>GXe Ta ou Tb ou CXe Ta ou Tb gleico</b>	<b>46,0</b>	<b>2,7</b>
			PAe típico ou câmbico	6,4	0,4
<b>PVAd1</b>	PVAd típico PAd abruptico  PV Ae típico	40 40 20	<b>PVe ou PV Ae típico (ondulado)</b>	<b>21,3</b>	<b>83,1</b>
			GXe Ta ou Tb ou CXe Ta ou Tb gleico	34,8	0,0
			PAe típico ou câmbico	25,5	0,0
			PVe abruptico	11,3	16,2
<b>PVAd2</b>	PVAd latossólico PAd latossólico PV Ae típico	40 30 30	PVe ou PV Ae câmbico	5,9	11,5
			PVe ou NVe típico	11,4	8,8
			<b>PV Ae típico ou PVAd latossólico</b>	<b>30,1</b>	<b>26,6</b>
			PVe ou PV Ae típico (ondulado)	7,3	11,8
			CXe Ta ou Tb típico (migmatitos)	4,6	5,2
			PVe abruptico	14,3	18,3
			PVe abruptico latossólico	13,0	10,1

<sup>a</sup> % de ocorrência na associação. <sup>b</sup> partes em negrito correspondem às classes identificadas nos mapas inferidos que são iguais ou semelhantes às classes identificadas no mapa convencional.



TABELA 15. Continuação.

Unidades	Mapa convencional		Mapas inferidos		
	Classes	% a	Classes	Redes neurais (%)	MAXVER (%)
<b>PVAe7</b>	PVAe abruptico	40	GXe Ta ou Tb ou CXe Ta ou Tb gleico	8,4	0,4
	PAe cambico	40	<b>CXe Ta ou Tb típico (migmatitos)</b>	<b>0,9</b>	<b>6,7</b>
	CXe Ta típico	20	PVe abruptico	30,9	32,6
			<b>PVe ou PVAe abruptico (ondulado)</b>	<b>38,7</b>	<b>42,1</b>
			LVe típico	8,7	9,3
PAe abruptico ou abruptico cambico		9,0	5,8		
<b>PVAe8</b>	PVAe cambico	40	<b>PVe ou PVAe cambico</b>	<b>29,4</b>	<b>7,1</b>
	PAe cambico	30	PVe ou NVe típico	2,9	14,3
	CXe Tb típico	30	PVe ou PVAe típico (ondulado)	63,2	77,1
<b>PVAe9</b>	PVAe abruptico e cambico	80	PVe ou PVAe cambico	1,7	6,9
	PVe abruptico	20	PVe ou NVe típico	12,4	8,2
			PVAe típico ou PVAd latossólico	14,9	15,1
			PVe ou PVAe típico (ondulado)	32,9	50,8
			GXe Ta ou Tb ou CXe Ta ou Tb gleico	17,7	2,4
<b>PVAe10</b>	PVAe abruptico e cambico	70	PVAe típico ou PVAd latossólico	31,4	15,7
	PVe abruptico	30	PVe ou PVAe típico (ondulado)	31,4	75,4
			GXe Ta ou Tb ou CXe Ta ou Tb gleico	25,4	6,4
			PAe típico ou cambico	8,2	0,0
<b>PVAe11</b>	PVAe típico	70	PVe ou PVAe cambico	17,6	30,9
	PVe típico	30	<b>PVe ou Nve típico</b>	<b>50,1</b>	<b>35,4</b>
			<b>PVAe típico ou PVAd latossólico</b>	<b>21,3</b>	<b>22,1</b>
			PVe abruptico	9,3	9,0
<b>PVAe12</b>	PVAe abruptico e cambico	50	PVe ou PVAe cambico	3,4	7,7
	PVe abruptico	30	PVe ou NVe típico	13,9	10,6
			PVAe típico ou PVAd latossólico	21,3	19,4
	Cxe Ta típico	20	PVe ou PVAe típico (ondulado)	10,9	15,8
		<b>PVe abruptico</b>	<b>30,0</b>	<b>27,1</b>	
<b>PVAe13</b>	PVAe típico	40	PVe ou PVAe cambico	6,4	12,5
	PVAd latossólico	30	<b>PVe ou Nve típico</b>	<b>26,7</b>	<b>18,5</b>
	PVe típico	30	<b>PVAe típico ou PVAd latossólico</b>	<b>28,8</b>	<b>28,7</b>
			<b>PVe ou PVAe típico (ondulado)</b>	<b>9,9</b>	<b>15,2</b>
PVe abruptico		13,3	13,0		
<b>PVAe14</b>	PVAe abruptico e cambico	80	PVe ou Nve típico	12,1	4,3
	Cxe Tb gleico	20	PVe ou PVAe típico (ondulado)	23,1	39,9
			<b>GXe Ta ou Tb ou CXe Ta ou Tb gleico</b>	<b>31,7</b>	<b>12,2</b>
			PVe abruptico	7,8	10,6
			PVe ou PVAe abruptico (ondulado)	11,2	13,3
PAe abruptico ou abruptico cambico		8,2	9,9		

<sup>a</sup> % de ocorrência na associação. <sup>b</sup> partes em negrito correspondem às classes identificadas nos mapas inferidos que são iguais ou semelhantes às classes identificadas no mapa convencional.



TABELA 15. Continuação.

Unidades	Mapa convencional		Mapas inferidos		
	Classes	% a	Classes	Redes neurais (%)	MAXVER (%)
<b>PVe1</b>	PVe típico e abrupto	70	<b>PVe ou PV Ae típico (ondulado)</b>	<b>7,9</b>	<b>6,7</b>
	PV Ae típico	30	GXe Ta ou Tb ou CXe Ta ou Tb gleico	9,6	0,0
			<b>PVe abrupto</b>	<b>16,9</b>	<b>10,5</b>
			PVe abrupto latossólico	11,1	24,9
			<b>PVe ou PV Ae abrupto (ondulado)</b>	<b>38,3</b>	<b>44,1</b>
		LVe típico	10,3	11,7	
<b>PVe2</b>	PVe típico e abrupto	70	PVe ou PV Ae câmbico	6,3	12,1
	PV Ae típico	30	<b>PVe ou NVe típico</b>	<b>21,2</b>	<b>16,0</b>
			<b>PV Ae típico ou PV Ad latossólico</b>	<b>34,8</b>	<b>32,3</b>
			<b>PVe ou PV Ae típico (ondulado)</b>	<b>10,1</b>	<b>14,2</b>
		<b>PVe abrupto</b>	<b>13,9</b>	<b>14,5</b>	
<b>PVe3</b>	PVe típico e abrupto	70	PVe ou PV Ae câmbico	2,7	7,2
	PV Ae típico	30	<b>PVe ou NVe típico</b>	<b>25,2</b>	<b>21,6</b>
			<b>PV Ae típico ou PV Ad latossólico</b>	<b>67,8</b>	<b>68,5</b>
<b>PVe4</b>	PVe abrupto	70	PVe ou PV Ae câmbico	3,4	7,6
	PV Ae câmbico	30	PVe ou NVe típico	13,5	10,3
			PV Ae típico ou PV Ad latossólico	21,6	20,1
			PVe ou PV Ae típico (ondulado)	11,6	13,2
		<b>PVe abrupto</b>	<b>27,9</b>	<b>27,5</b>	
<b>PVe5</b>	PVe típico e abrupto	70	PVe ou PV Ae câmbico	6,7	11,9
	PV Ae abrupto	30	<b>PVe ou NVe típico</b>	<b>16,9</b>	<b>11,6</b>
	câmbico		PV Ae típico ou PV Ad latossólico	31,5	29,7
			PVe ou PV Ae típico (ondulado)	8,9	12,2
		<b>PVe abrupto</b>	<b>20,4</b>	<b>21,0</b>	
<b>PVe6</b>	PVe abrupto	60	CXe Tb típico (granulitos)	7,6	2,5
	PV Ae típico	40	PVe ou PV Ae câmbico	20,9	40,8
			PVe ou NVe típico	16,0	11,4
			<b>PV Ae típico ou PV Ad latossólico</b>	<b>31,1</b>	<b>19,4</b>
			CXe Ta ou Tb típico (migmatitos)	4,6	7,9
		<b>PVe abrupto</b>	<b>7,5</b>	<b>5,1</b>	
<b>PVe7</b>	PVe abrupto	40	<b>PVe ou PV Ae câmbico</b>	<b>7,0</b>	<b>16,1</b>
	PV Ae câmbico	40	PVe ou NVe típico	16,2	7,1
	CXe Ta saprolítico	20	PV Ae típico ou PV Ad latossólico	31,2	32,9
			<b>CXe Ta ou Tb típico (migmatitos)</b>	<b>8,4</b>	<b>10,1</b>
			<b>PVe abrupto</b>	<b>18,6</b>	<b>20,1</b>
		PVe abrupto latossólico	10,6	6,0	
<b>PVe8</b>	PVe abrupto	40	<b>CXe Ta ou Tb típico (migmatitos)</b>	<b>20,0</b>	<b>45,9</b>
	PV Ae câmbico	40	<b>PVe abrupto</b>	<b>58,5</b>	<b>36,7</b>
	CXe Ta típico	20	PVe abrupto latossólico	9,8	6,8

<sup>a</sup> % de ocorrência na associação. <sup>b</sup> partes em negrito correspondem às classes identificadas nos mapas inferidos que são iguais ou semelhantes às classes identificadas no mapa convencional.

TABELA 15. Continuação.

Unidades	Mapa convencional		Mapas inferidos		
	Classes	% a	Classes	Redes neurais (%)	MAXVER (%)
<b>PVe9</b>	PVe abruptico	50	<b>PVe ou PVAe câmbico</b>	<b>5,1</b>	<b>8,1</b>
	PVAe câmbico	30	PVe ou NVe típico	12,5	7,5
	TC Órtico típico	20	PVAe típico ou PVAd latossólico	10,1	11,2
			CXe Ta ou Tb típico (migmatitos)	7,1	10,6
			<b>PVe abruptico</b>	<b>47,3</b>	<b>46,4</b>
<b>PVe10</b>	PVe abruptico	50	PVe ou NVe típico	15,3	3,7
	PVAe típico	30	AR + RLe típico	68,8	9,7
	Afloramentos de rocha	20	CXe Ta ou Tb típico (migmatitos)	0,5	36,9
			<b>PVe abruptico</b>	<b>10,7</b>	<b>16,1</b>
			PVe abruptico latossólico	4,7	18,9
<b>RYbe</b>	RUE Tb gleico solódico	60	PVe ou NVe típico	50,0	33,3
	GXe Ta solódico	40	PVe ou PVAe típico (ondulado)	50,0	58,3
<b>SXe</b>	SXe solódico e típico	80	<b>GXe Ta ou Tb ou CXe Ta ou Tb gleico</b>	<b>26,8</b>	<b>0,0</b>
			PVe ou PVAe abruptico (ondulado)	14,6	46,5
	GXe Ta solódico	20	PAe abruptico ou abruptico câmbico	58,6	51,5

<sup>a</sup> % de ocorrência na associação. <sup>b</sup> partes em negrito correspondem às classes identificadas nos mapas inferidos que são iguais ou semelhantes às classes identificadas no mapa convencional. AR – Afloramentos de rocha; RL – Neossolo Litólico; CX – Cambissolo Háplico; GX – Gleissolo Háplico; PA – Argissolo Amarelo; PVA – Argissolo Vermelho-Amarelo; PV – Argissolo Vermelho; NV – Nitossolo Vermelho; TC – Luvisso Crômico; TP – Luvisso Hipocrômico; LVA – Latossolo Vermelho-Amarelo; LV – Latossolo Vermelho; RY – Neossolo Flúvico; SX – Planossolo Háplico; d – distrófico; e – eutrófico.

Tomando como exemplo a unidade de mapeamento GXve1 (Gleissolo Háplico Ta Eutrófico solódico e vértico – 100%), com área aproximada de 2568 ha, característica de áreas planas, verifica-se que o limite traçado no mapa convencional engloba também áreas de relevo suave ondulado (17,69%), ondulado (30,14%), forte ondulado (14,58%) e, até mesmo, montanhoso (0,36%), o que evidencia a dificuldade

esta razão, foram identificados apenas 5,76% da unidade como pertencentes a esta classe, o que pode ser interpretado como uma baixa eficiência deste classificador.

Outra unidade de mapeamento que merece destaque é a CXve1 com apenas 61,98 ha, composta por Cambissolo Háptico Ta Eutrófico típico (60%), Argissolo Amarelo Eutrófico abrupto câmbico (20%) e Gleissolo Háptico Ta Eutrófico típico. De acordo com o mapa de declividade da bacia do rio São Domingos esta unidade apresenta as seguintes classes de relevo: plano (36,12%), suave ondulado (14,54%), ondulado (36,56%) e forte ondulado (12,78%). Levando-se em consideração que os solos desta associação ocorrem em relevo plano e suave ondulado, 49,34% da unidade compõem ambientes com características distintas das evidenciadas pelo mapa de solos convencional. Por outro lado, a classificação pela rede neural identificou 47% desta unidade como pertencentes à classe dos Gleissolos Hápticos Eutróficos, 44% à classe dos Argissolos Vermelhos ou Vermelho-Amarelos e 9% à classe Argissolo Amarelo.

A unidade PVe2 do mapa convencional é formada por Argissolo Vermelho Eutrófico típico e abrupto (70%) e Argissolo Vermelho-Amarelo Eutrófico típico (30%). Ambos ocorrem em áreas convexas, sendo que o 1º componente ocupa as encostas voltadas para norte e o 2º as encostas voltadas para sul, conforme evidenciado no capítulo 3. No mapeamento convencional é difícil separar estes componentes por causa da escala de trabalho, assim foram mapeados como uma associação. Por outro lado, nas abordagens utilizadas (redes neurais e MAXVER) estas classes foram mapeadas individualmente, devido à facilidade de derivação da orientação da encosta pelo SIG.

Uma análise das características ambientais na unidade PVe2 mostra que 56,69% da área unidade apresenta uma combinação de relevo forte ondulado e montanhoso, curvatura convexa e orientação norte, características da ocorrência de Argissolo Vermelho Eutrófico típico ou abrupto, enquanto 29,50% apresentam condições que favorecem à ocorrência de Argissolo Vermelho-Amarelo Eutrófico típico (relevo forte ondulado e montanhoso, curvatura convexa e orientação sul). O restante da área apresenta relevo ondulado (7,04%), plano (1,65%) e uma combinação de relevo forte ondulado e curvatura côncava.


Situações semelhantes às evidenciadas nestes exemplos são verificadas em outras unidades de mapeamento (Tabela 15). Estudo realizado por Young et al. (1997) para estimar a composição taxonômica de uma unidade de mapeamento mostrou uma elevada variabilidade, com 28 classes, ao nível de família, sendo identificadas nesta unidade.

Embora, os resultados alcançados não sejam suficientes para definir qual das abordagens é superior, as características ambientais evidenciadas nos exemplos sugerem que a abordagem pelas redes neurais apresenta uma melhor exatidão do que a abordagem convencional.


Os resultados obtidos para as comparações entre os mapas inferidos e o mapa convencional são apresentados nas Figuras 21 e 22. A comparação foi realizada considerando-se separadamente cada componente da associação do mapa de solos convencional (1º, 2º e 3º componentes). Posteriormente, os resultados destas comparações foram somados para produzir a concordância geral entre os mapas. Além destas, foram realizadas também comparações por nível categórico do Sistema Brasileiro de Classificação de Solos (Embrapa, 1999).

Os resultados das classificações pelas redes neurais e pelo MAXVER, embora tenham obtido uma elevada exatidão quando se utilizou as amostras de validação, não produziram uma boa concordância com o mapa de solos convencional (Figuras 21a e 22a). 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.

Thomas et al. (1999) obtiveram uma concordância de 55% entre um mapa de solos produzido a partir da utilização de parâmetros derivados de um MDE e geologia e um mapa convencional, na escala de 1:100.000. Brown et al. (1998), por sua vez, empregando as mesmas abordagens utilizadas no presente estudo (redes neurais e MAXVER), para o mapeamento de paisagens glaciadas, obtiveram concordâncias com o mapa original entre 51 e 61% para quatro classificações testadas.



**FIGURA 21.** Comparação entre o mapa de solos produzido pelo classificador por redes neurais e o mapa de solos convencional.



**FIGURA 22.** Comparação entre o mapa de solos produzido pelo classificador MAXVER e o mapa de solos convencional.

O padrão espacial das classes resultantes das classificações pela rede neural e pelo MAXVER é bastante complexo e distinto, contendo poucas áreas que reúnem muitos pixels, ao contrário do mapa de solos convencional que apresenta grandes e extensos polígonos representando as classes de solos. Assim, 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 entre as comparações é a natureza geológica bastante complexa da área, que em algumas partes da bacia do rio São Domingos dificultou o correto estabelecimento das relações solo-paisagem, fundamentais para o perfeito desempenho das abordagens testadas. Além desta complexidade, em algumas partes da bacia, relacionadas, principalmente com áreas do Domínio de colinas dissecadas (Dantas, 2000) a profundidade de exposição das rochas (contato lítico) tem uma importância grande na distribuição dos solos, superando muitas vezes a influência da morfometria da superfície. McKenzie & Austin (1993) encontraram que a presença de camada de impedimento a pouca profundidade é um forte preditor de propriedades do solo e a presença de estruturas geológicas como diques podem controlar o padrão de distribuição dos solos. Diques de material básico são comuns na área da bacia do rio São Domingos, porém estes não são mostrados no mapa geológico (DRM, 1980).

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. Por outro lado, estes aspectos foram incorporados ao modelo mental utilizado pelos pedólogos que realizaram o levantamento pela abordagem convencional.

Com relação aos modelos quantitativos utilizados na correlação ambiental, como o empregado neste estudo, McKenzie & Ryan (1999) destacam que, embora estes modelos possam ser utilizados para predição espacial de classes de solos, formando uma base mais científica para o levantamento de solos, eles podem não utilizar toda a capacidade preditiva dos modelos mentais intuitivos usados no levantamento convencional. McKenzie et al. (2000) notaram que um pedólogo experiente usualmente utiliza relações entre solos e variáveis ambientais obtidas em outras paisagens quando mapeiam uma nova área. Entretanto, este tipo de informação é difícil de ser incorporada

em um modelo explícito como o apresentado neste estudo. Uma outra faceta da abordagem convencional destacada por McKenzie & Ryan (1999) e muito difícil de ser incorporada em um sistema mais quantitativo é a grande quantidade de observações de campo, nas quais muitas impressões das relações entre solos e variáveis ambientais mais facilmente observáveis são obtidas à medida que a área vai sendo mapeada.

Por último, outro fator que não pode ser descartado é o fato dos mapas terem sido realizados por diferentes equipes de pedólogos, o que conforme destacado por Bie & Beckett (1973), pode alterar o resultado do mapeamento. Finalmente, existem circunstâncias onde a variação dos solos ocorre sem relação com variáveis ambientais facilmente observáveis (falta de um preditor confiável). Nestes casos, a amostragem detalhada é inevitável e alguma forma de interpolação é necessária para gerar a predição espacial (McKenzie & Ryan, 1999).

As comparações entre os mapas inferidos e o mapa de solos convencional, considerando-se o 1º componente da associação de solos para cada nível categórico do Sistema Brasileiro de Classificação de Solos, obtiveram resultados satisfatórios apenas para o 1º nível categórico, tanto para a classificação pelas redes neurais quanto pelo MAXVER, (75,22 e 74,64%, respectivamente redes neurais e MAXVER) (Figura 21b e 22b). Nos demais níveis a concordância foi inferior a 50%, para ambos os classificadores (Figuras 21c, d, e e 22c, d, e), evidenciando, ainda mais, as discrepâncias entre as abordagens utilizadas, principalmente no 4º nível categórico, onde a concordância foi de apenas 23,27 e 12,92% (redes neurais e MAXVER, respectivamente).

### **3.5. Análise da Concordância entre Pontos de Controle Coletados no Campo, os Mapas Inferidos e o Mapa de Solos Convencional**

288 pontos georreferenciados, entre perfis de solo, amostras extras e pontos de observação coletados durante os trabalhos de campo foram utilizados para verificar qual a concordância dos mapas inferidos e do mapa convencional com estes pontos de referência. Os resultados obtidos para estas comparações são mostrados nas Tabelas 16 e 17. Do total de pontos avaliados a classificação pelas redes neurais inferiu as classes de solo corretamente em 204 locais (70,83%), o MAXVER em 146 (50,69%) e o mapa convencional em 152 (52,77%).



**TABELA 16. Comparação entre os pontos de observação coletados no campo, os mapas inferidos e o mapa convencional.**

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

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.

Os resultados alcançados são semelhantes àqueles obtidos em outros estudos. Zhu (1997) utilizando uma abordagem baseada em conhecimento (*knowledge-based - KB*) inferiu corretamente 81,3% dos locais visitados. Com a utilização de uma abordagem por redes neurais, tal como a utilizada neste estudo, Zhu (2000) inferiu corretamente as classes de solos avaliadas em 77% dos locais, enquanto o método convencional obteve 60,9% de classes corretamente inferidas. Em outro estudo (*Soil-land inference model - SoLIM*), Zhu et al. (2001) obtiveram 83,8% de pixels classificados corretamente e o método convencional 66,7%.

**TABELA 17. Matriz de significância de Kappa para as classificações consideradas.**

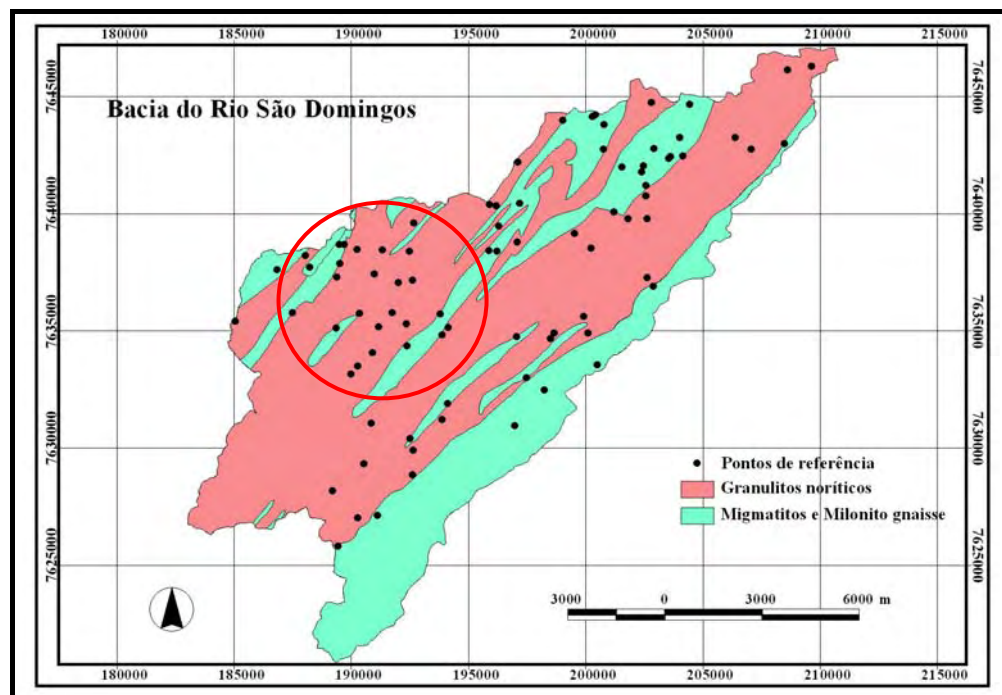
Classificação	Rede neural	MAXVER	Mapa convencional
Exatidão global	70,83	50,69	52,77
Kappa	0,678	0,460	0,469
Variância	0,000837	0,000991	0,00099
<b>Rede neural</b>	23,44		
<b>MAXVER</b>	5,10 *	14,61	
<b>Mapa convencional</b>	4,89 *	0,20	14,91

\* existe diferença significativa ao nível de 95%.

A matriz de significância de Kappa apresentada na Tabela 17 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. De acordo com Landis & Koch (1977) e Monserud & Leemans (1992), o valor de Kappa obtido pela abordagem por redes neurais indica um desempenho moderado do classificador. Por sua vez, a classificação pelo MAXVER e o mapa de solos convencional não apresentaram diferenças significativas.

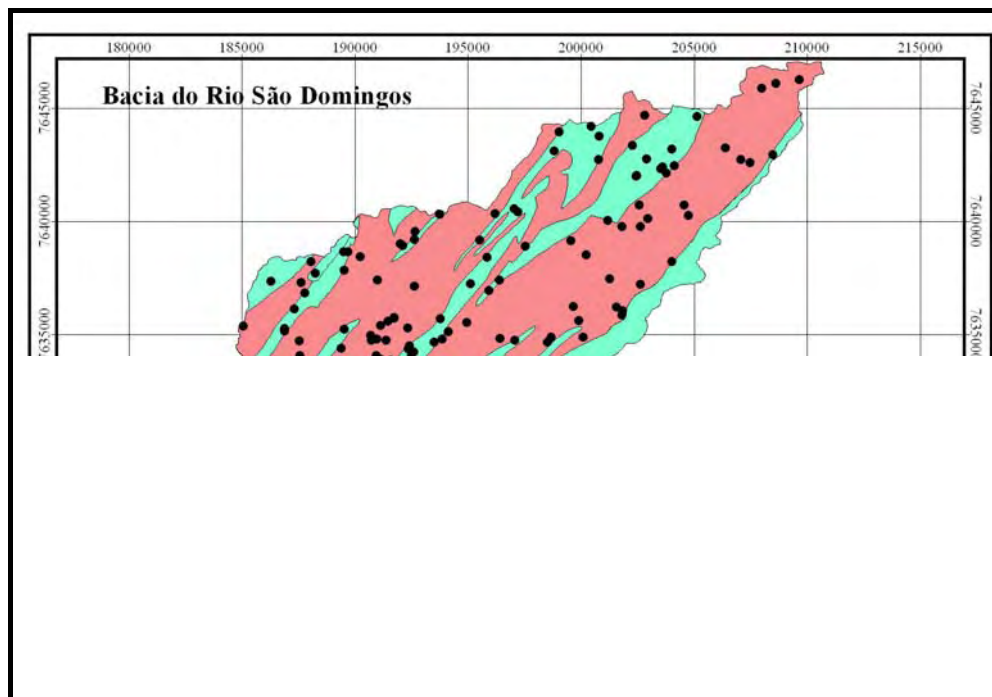
Na classificação pelas redes neurais uma importante causa de discordância com os pontos de referência está relacionada com os limites das unidades do mapa geológico (DRM, 1980). A maioria das observações erroneamente classificadas ocorre nos limites entre estas unidades, como mostra a Figura 23. Para 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 Thomas et al. (1999) e McKenzie & Ryan (1999).



**FIGURA 23.** Localização dos pontos de referência erroneamente classificados pelas redes neurais.

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 (Figura 24). 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.



**FIGURA 24. Localização dos pontos de referência erroneamente classificados pelo mapa de solos convencional.**

Finalizando, os resultados obtidos neste estudo evidenciam claramente a maior eficiência da abordagem por redes neurais sobre o método convencional de levantamento de solos, conforme relatado por Zhu (2000).

#### **4. CONCLUSÕES**

O classificador baseado nas redes neurais testado neste estudo produziu uma maior exatidão na classificação geral, com resultados significativamente melhores e comprovados através dos testes estatísticos utilizados, quando comparado ao classificador clássico da máxima verossimilhança, sugerindo, neste caso, que a abordagem por redes neurais foi mais eficiente na discriminação dos solos da bacia do

rio São Domingos. A exatidão geral da classificação para ambos os classificadores mostrou-se bastante influenciada pelo número de variáveis discriminantes utilizadas.

A análise entre o mapa produzido pelo classificador por redes neurais e pelo MAXVER mostrou uma baixa concordância, o que evidencia a natureza distinta dos modelos matemáticos presentes nestes classificadores.

Os mapas produzidos pelos classificadores 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 software de SIG, que tem a capacidade de manipular muitas variáveis simultaneamente. Neste sentido, a disponibilidade de dados mais detalhados sobre as variáveis ambientais tornou possível reduzir significativamente as associações de solos e permitiu identificar pequenos componentes na paisagem que são difíceis de serem identificados pelo mapeamento convencional. A presença de mais de uma classe de solo associada a um determinado pixel somente ocorreu devido à dificuldade ou impossibilidade de estabelecimento de relações solo-paisagem mais precisas.

Os mapas inferidos tiveram uma baixa concordância com o mapa de solos convencional. As principais causas das discordâncias 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/ou exposição da rocha; e problemas relacionados com o modelo de correlação ambiental utilizado.

A comparação com pontos de observação coletados no campo 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.

Por fim, este estudo mostra que a utilização de atributos do terreno e dados de sensores remotos em uma abordagem por redes neurais pode contribuir grandemente para tornar o mapeamento de solos no Brasil mais quantitativo e confiável. A disponibilidade de dados de sensores remotos (LANDSAT, ASTER, SRTM, CBERS, entre outros) a custos mais baixos e a facilidade de obtenção dos atributos do terreno em um SIG comercial tornam a abordagem utilizada ainda mais atraente. Além disso, os

cientistas de solo podem se dedicar mais a tarefa de entendimento das relações solo-paisagem, dando mais atenção ao que eles mais sabem fazer, conforme destacado por Zhu et al. (2001).

## 5. LITERATURA CITADA

ATKINSON, P. M. & TATNALL, A. R. L. Neural networks in remote sensing. **International Journal of Remote Sensing**, v.18, p.699-709, 1997.

BENEDIKTSSON, J. A. & SVEINSSON, J. R. Feature extraction for multisource data classification with artificial neural networks. **International Journal of Remote Sensing**, v.18, p.727-740, 1997.

BENEDIKTSSON, J. A.; SWAIN, P. H. & ERSOY, O. K. Conjugate-gradient neural networks in classification of multisource and very-high-dimensional remote sensing data. **International Journal of Remote Sensing**, v.14, p.2883-2903, 1993.

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**, v.28, p.540-552, 1990.

BIE, S. W. & BECKETT, P. H. T. Comparison of 4 independent soil surveys by air-photo interpretation, Paphos area (Cyprus). **Photogrammetria**, v.29, p.189-202, 1973.

BISCHOF, H.; SCHNEIDER, W. & PINZ, A. J. Multispectral classification of Landsat-images using neural networks. **IEEE Transactions on Geoscience and Remote Sensing**, v.30, p.482-490, 1992.

BISHOP, Y.; FIENBERG, Y. S. & HOLLAND, P. **Discrete multivariate analysis: theory and practice**. Cambridge, MA: MIT Press, 1975. 557p.

BROWN, D. G.; LUSCH, D. P. & DUDA, K. A. Supervised classification of types of glaciated landscapes using digital elevation data. **Geomorphology**, v.21, p.233-250, 1998.

BURROUGH, P. A.; BECKETT, P. H. T. & JARVIS, M. G. The relation between cost and utility in soil survey (I-III). **Soil Science**, v.22, p.359-394, 1971.

CAMPBELL, J. B. **Introduction to remote sensing**. New York: The Guilford Press, 1987. 551p.

CARVALHO JUNIOR, W. **Classificação supervisionada de pedopaisagens do Domínio dos mares de morros utilizando redes neurais artificiais**. 2005. 143f. Tese (Doutorado em Solos e Nutrição de Plantas) - Universidade Federal de Viçosa, Viçosa, MG, 2005.

CAUDILL, M. Neural network: training tips and techniques. **AI Experts**, v.6, p.56-61, 1991.

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.

CHEN, K. S. et al. Land-cover classification of SPOT image using a dynamic learning neural network. **Photogrammetric Engineering and Remote Sensing**, v.61, p.403-408, 1995.

CONGALTON, R. G. & GREEN, K. **Assessing the accuracy of remotely sensed data: principles and practices**. New York: Lewis Publishers, 1999. 137p.

CONGALTON, R. G. & MEAD, R. A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering and Remote Sensing**, v.49, p.69-79, 1983.

CONGALTON, R. G. & MEAD, R. A. A review of discrete multivariate analysis techniques used in assessing the accuracy of remotely sensed data from error matrices. **IEEE Transactions on Geoscience and Remote Sensing**, v.24, p.169-174, 1986.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing Environment**, v.37, p.35- 46, 1991.

CÔTE, S. & TATNALL, A. R. L. A neural network-based method for tracking features from satellite sensor images. **International Journal of Remote Sensing**, v.16, p.3695-3701, 1995.

DANIEL, K. W.; TRIPATHI, N. K. & HONDA, K. Artificial neural network analysis of laboratory and in situ spectra for the estimation of macronutrients in soils of Lop Buri (Thailand). **Australian Journal of Soil Research**, v.41, p.47-59, 2003.

DANTAS, M. E. **Geomorfologia do Estado do Rio de Janeiro**. Brasília: CPRM, 2000. 1CD-ROM.

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.

DI, L.; RUNDQUIST, D. C. & HAN, I. Modeling relationships between NDVI and precipitation during vegetative growth cycles. **International Journal of Remote Sensing**, v.15, p.2121-2136, 1994.

DOBOS, E. et al. 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.

DOBOS, E. et al. Use of combined digital elevation model and satellite data for regional soil mapping. **Geoderma**, v.97, p.367-391, 2000.

EMBRAPA. Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação de Solos**. Brasília: Embrapa Produção de Informação; Rio de Janeiro: Embrapa Solos, 1999. 412 p.

FIDÊNCIO, P. H.; RUISANCHES, I. & POPPI, R. J. Application of artificial neural networks to the classification of soils from São Paulo state using near-infrared spectroscopy. **Analyst**, v.126, p.2194-2200, 2001.

FOODY, G. M. & ARORA, M. K. An evaluation of some factors affecting the accuracy of classification by an artificial neural network. **International Journal of Remote Sensing**, v.18, p.799-810, 1997.

FRANK, T. D. Mapping dominant vegetation communities in the Colorado Rocky Mountain Front Range with Landsat Thematic Mapper and digital terrain data. **Photogrammetric Engineering and Remote Sensing**, v.54, p.1727-1734, 1988.

FRANKLIN, S. E. Terrain analysis for digital patterns in geomorphometry and Landsat MSS spectral response. **Photogrammetric Engineering and Remote Sensing**, v.53, p.59-65, 1987.

HEBB, D. O. **The Organization of Behavior**. New York: John Wiley & Sons, 1949. 245p.

HEERMANN, P. D. & KHAZENIE, N. Classification of multispectral remote sensing data using a back-propagation neural network. **IEEE Transactions on Geoscience and Remote Sensing**, v.30, p.81-88, 1992.

HEPNER, G. F. et al. Artificial neural network classification using a minimal training set: comparison to conventional supervised classification. **Photogrammetric Engineering and Remote Sensing**, v.56, p.469-473, 1990.

HIROSE, Y.; YAMASHITA, K. & HIJIYA, S. Back-propagation algorithm which varies the number of hidden units. **Neural Networks**, v.4, p.61-66, 1991.

JENNY, H. **Factors of soil formation; a system of quantitative pedology**. New York: McGraw-Hill, 1941. 281p.

KALKHAN, M. A.; REICH, R. M. & CZAPLEWSKI, R. L. Variance estimates and confidence interval for Kappa measure of classification accuracy. **Canadian Journal of Remote sensing**, v.23, p.210-216, 1997.

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 arctic data with neural networks. **Photogrammetric Engineering and Remote Sensing**, v.55, p.1331-1338, 1989.

LANDIS, J. R. & KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v.33, p.159-174, 1977.

LEE, K.; LEE, G. B. & TYLER, E. J. Thematic Mapper and digital elevation modelling of soil characteristics in hilly terrain. **Soil Science Society of America Journal**, v.52, p.1104-1107, 1988.

LEE, S.; RYU, J. H.; WON, J. S. & PARK, H. J. Determination and application of the weights for landslide susceptibility mapping using an artificial neural network. **Engineering Geology**, v.71, p.289-302, 2004.

LEPRIEUR, C. E.; DURAND, J. M. & PEYRON, J. L. Influence of topography on forest reflectance using Landsat Thematic Mapper and digital terrain data. **Photogrammetric Engineering and Remote Sensing**, v.54, p.491-496, 1988.

LICZNAR, P. & NEARING, M. A. Artificial neural networks of soil erosion and runoff prediction at the plot scale. **Catena**, v.51, p.89-114, 2003.

LIU, Z. K. & XIAO, J. Y. Classification of remotely-sensed image data using artificial neural networks. **International Journal of Remote Sensing**, v.12, p.2433-2447, 1991.

LOZANO-GARCIA, D. F.; FERNANDEZ, R. N. & JOHANNSEN, C. J. Assessment of regional biomass-soil relationships using vegetation indexes. **IEEE Transactions on Geoscience and Remote Sensing**, v.29, n.331-338, 1991.

LUMBRERAS, J. F. et al. **Mapa de reconhecimento de média intensidade de solos da bacia hidrográfica do rio São Domingos, municípios de São José de Ubá e Itaperuna, Estado do Rio de Janeiro**. Rio de Janeiro: Embrapa Solos, 2006.

MADEIRA NETTO, J. S. Estimativas de teores de hematita em latossolos com imagens TM. Simpósio Brasileiro de Sensoriamento Remoto, 7., 1993, Curitiba. **Anais...**, São José dos Campos: INPE/SLPER/SBC, 1993. v.3, p.249-255.



MARCHETTI, D. A. & GARCIA, G. J. Mapeamento de solos através do caráter espectral, da rede de drenagem e da vegetação. **Anais da Escola Superior de Agricultura Luiz de Queiroz**, 1990, Piracicaba. **Anais...** Piracicaba: ESALQ, 1990. v.47, p.193-220.

MARSMAN, B. A. & DE GRUIJTER, J. J. Dutch soil survey goes into quality control. In: BURROUGH, P. A. & BIE, S. W. (Eds.). **Soil Information Systems Technology**, Pudoc, Wageningen. p. 127-134. 1984.

MARSMAN, B. A. & DE GRUIJTER, J. J. Quality of soil maps: a comparison of soil survey methods in a sandy area. **Soil Survey Papers**, v.15. Wageningen, The Netherlands, 1986. 102p.

MAS, J. F. et al. Modeling deforestation using GIS and artificial neural networks. **Environmental Modeling & Software**, v.19, p.461-471, 2004.

MASTER, T. **Practical neural network recipes in C++**. San Diego, California: Academic, 1993. 493p.

MATHER, P. M. **Computer Processing of Remotely-Sensed Images: An Introduction**. 2nd ed. Chichester: John Wiley & Sons, 1999. 306p.

McBRATNEY, A. B. et al. 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.

McKENZIE, N. J.; GESSLER, P. E.; RYAN, P. J & O'CONNELL, D. A. The role of terrain analysis in soil mapping. In: WILSON, J. P. & GALLANT, J. C. (Eds.). **Terrain analysis: principles and applications**. New York: John Wiley & Sons, 2000. p. 245-265.

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.

MONSERUD, R. A. & LEEMANS, R. Comparing global vegetation maps with the Kappa statistic. **Ecological Modelling**, v.62, p.275-293, 1992.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 2.ed. Viçosa : UFV, 2003. 307p. : il.

NARASIMHA, R. P. V. et al. Relation between root zone soil moisture and Normalized Difference Vegetation Index of vegetated fields. **International Journal of Remote Sensing**, v.14, p.441-449, 1993.

NORDT, L. C.; JACOB J. S. & WILDING, L. P. Quantifying map unit composition for quality control in soil survey. In: MAUSBACH, M. J. & WILDING, L. P. (Eds.). **Spatial variabilities of soils and landforms**. Madison, Wisconsin: Soil Science Society of America, 1991. p.183-198. (SSSA Special Publication; nº 28).

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.

PARK, S. J. & VLEK, P. L. G. Environmental correlation of three-dimensional soil spatial variability: a comparison of three adaptive techniques. **Geoderma**, v.109, p.117-140, 2002.

PEDDLE, D. R. et al. Multisource image classification II: an empirical comparison of evidential reasoning, linear discriminant analysis, and maximum likelihood algorithms for alpine land cover classification. **Canadian Journal of Remote Sensing**, v.20, p.397-408, 1994.

PEREIRA, L. C. et al. Sensoriamento remoto no estudo de correlação vegetação x solos da floresta estadual do Antimari - Acre. Congresso Brasileiro de Ciência do Solo, 23., 1991, Porto Alegre. **Anais...** Porto Alegre: SBCS, 1991. p.271.

RAMOS, C. R. L. **Classificação dos solos no semi-árido Paraibano através de imagem MSS-LANDSAT**. 1983. 163f. Dissertação (Mestrado em Solos) - Universidade Federal da Paraíba, Areia, PB, 1983.

RUTCHEY, K. & VILCHECK, L. Development of an everglades vegetation map using a SPOT image and the Global Positioning System. **Photogrammetric Engineering and Remote Sensing**, v.60, p.767-775, 1994.

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

SCHAAP, M. G. & LEIJ, F. J. Using neural networks to predict soil water retention and soil hydraulic conductivity. **Soil and Tillage Research**, v.47, p.37-42, 1998.

SCHALKOFF, R. J. **Pattern Recognition: Statistical, Structural and Neural Approaches**. New York: John Wiley & Sons, 1992. 384p.

SILVA, F. H. B. B. **Caracterização dos padrões de drenagem a partir de técnicas de sensoriamento remoto para uso em levantamento de reconhecimento (Alta Intensidade) de solos.** 1994. 149f. Dissertação (Mestrado em Solos) - Universidade Federal da Paraíba, Campina Grande, PB, 1994.

SKIDMORE, A. & TURNER, B. Assessing the accuracy of resource inventory maps. In: Proceedings for Global Natural Resource Monitoring and Assessments: Preparing for the 21<sup>th</sup> Century, 1989, Venice, Italy. **Proceedings...** Bethesda, MD: American Society for Photogrammetry and remote Sensing, 1989. v.2, p.524-535.

SOARES, A. F. **Sensoriamento remoto e geoprocessamento aplicados na caracterização dos solos e da cobertura vegetal na bacia hidrográfica do Rio Candiru-Acú (PA).** 1994. 139f. Dissertação (Mestrado em Solos e Nutrição de Plantas) - Escola Superior de Agricultura Luiz de Queiroz - ESALQ, Piracicaba, SP, 1994.

SOUSA, E. B.; VALÉRIO FILHO, M. & VERTAMATTI, E. Técnicas de processamento digital de imagens TM/Landsat como suporte à identificação de unidades de mapeamento de solos. In: Congresso Brasileiro de Ciência do Solo, 26., 1997, Rio de Janeiro. **Anais...** Rio de Janeiro: SBCS, 1997. 1 CD-ROM.

STORY, M. & CONGALTON, R. G. Accuracy assessment: A user's perspective. **Photogrammetric Engineering and Remote Sensing**, v.61, p.391-401, 1986.

SU, H.; RANSOM, M. D. & KANEMASU, E. T. Detecting soil information on a native prairie using Landsat TM and SPOT satellite data. **Soil Science Society of American Journal**. v.53, p.1479-1483, 1989.

SWAIN, P. H. Fundamentals of pattern recognition. In: SWAIN, P. H. & DAVIS, S. M. (Eds.). **Remote Sensing: the Quantitative Approach**, p.136-187. New York: McGraw-Hill. 1978.

THOMAS, A. L.; KING, D.; DAMBRINE, E. & COUTURIER, A. Predicting soil classes with parameters derived from relief and geologic materials in a sandstone region of the Vosges mountains (Northeastern France). **Geoderma**, v.90, p.291-305, 1999.

VALÉRIO FILHO, M.; HIGA, N. T. & CARVALHO, V. C. **Avaliação das imagens orbitais (LANDSAT-1) como base para levantamento de solos.** São José dos Campos: INPE, 1976. 276p.

VIEGAS, P.L. da C. **Mapeamento dos solos basálticos da região da campanha - RS por meio de classificação digital de dados LANDSAT-TM.** 1993. 167f. Dissertação (Mestrado em Solos) - Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 1993.

VIEIRA, C. A. O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study.** 2000. 327f. (PhD Thesis) - University of Nottingham, Nottingham, UK, 2000.

WASSERMAN, P. D. **Neural computing: theory and practice**. New York: Van Nostrand Reinhold, 1989. 230p.

WEBSTER, R. & BECKETT, P. H. T. Quality and usefulness of soil maps. **Nature**, v.219, p.680-682, 1968.

WILDING, L. P.; JONES, R. B. & SHAFER, G. M. Variation of soil morphological properties within Miami, Celina and Crosby mapping units in West-Central Ohio. **Soil Science Society of American Proceedings**, v.29, p.711-717, 1965.

YANG, G.; COLLINS, M. J. & GONG, P. Multisource data selection for lithologic classification with artificial neural networks. **International Journal of Remote Sensing**, v.19, p.3675-3680, 1998.

YANG, W.; YANG, L. & MERCHANT, J. W. An assessment of AVHRR/NDVI-ecoclimatological relations in Nebraska, USA. **International Journal of Remote Sensing**, v.18, p.2161-2180, 1997.

YOOL, S. R. Land cover classification in rugged areas using simulated moderate-resolution remote sensor data and an artificial neural network. **International Journal of Remote Sensing**, v.19, p.85-96, 1998.

YOUNG, F. J.; HAMMER, R. D. & WILLIAMS, F. Estimation of map unit composition from transect data. **Soil Science Society of American Journal**, v.61, p.854-861, 1997.

ZELL, A. Et al. **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. et al. Soil mapping using GIS, expert knowledge, and fuzzy logic. **Soil Science Society of American Journal**, v.65, p.1463-1472, 2001.

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



geomorfopedológicas que ocorrem na área estudada. Inicialmente, a utilização de técnicas de geoprocessamento e análise digital do terreno auxiliaram na identificação das interações que ocorrem entre os diferentes fatores de formação dos solos na bacia estudada, levando à formação de combinações que permitiram o delineamento de segmentos da paisagem, que por sua vez, foram utilizados como base para a definição de um padrão de amostragem, fundamental para explicar as relações existentes entre os solos, as diferentes litologias e os atributos do terreno utilizados.

A forte influência do material de origem e dos atributos do terreno foi confirmada neste estudo. Os atributos do terreno que afetam mais significativamente a distribuição dos solos na paisagem são: elevação, declividade, aspecto, curvatura e posição na encosta. O tipo de material de origem do solo, além de influenciar características importantes como textura, saturação por bases, CTC, entre outras, teve influência marcante na ausência ou presença de mudança textural abrupta nos solos da BHSD, sendo esta a principal diferença entre os Argissolos derivados de granulitos (sem mudança textural abrupta) dos Argissolos derivados dos migmatitos e dos milonitos gnaisses (com mudança textural abrupta). Por sua vez, a curvatura do terreno, que controla o fluxo superficial de água no solo, é o principal fator que determina diferenças no grau de evolução dos solos da BHSD. Variações microclimáticas importantes condicionadas pela orientação das encostas foram determinantes na diferenciação dos solos nas encostas convexas, tanto nos solos derivados de granulitos quanto naqueles derivados dos migmatitos e milonitos gnaisses.

Finalmente, os atributos do terreno derivados do MDE e os resultados do estudo das relações geomorfopedológicas foram utilizados em uma abordagem por redes neurais para a predição das classes de solo da BHSD e, comparado com o classificador MAXVER e com o mapa de solos convencional. O classificador baseado nas redes neurais produziu uma maior exatidão na classificação geral, com resultados significativamente melhores e comprovados nos testes estatísticos utilizados, do que o classificador MAXVER, e a exatidão geral da classificação para ambos mostrou-se bastante influenciada pelo número de variáveis ambientais discriminantes utilizadas.

A análise entre o mapa produzido pelo classificador por redes neurais e pelo MAXVER mostrou uma baixa concordância. Por sua vez, estes mapas 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. Além disso, a disponibilidade de dados mais detalhados sobre as variáveis ambientais tornou possível reduzir significativamente 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 e as principais causas foram: limitação de escala do mapa convencional e maior detalhamento espacial dos mapas inferidos; dificuldade de delimitação e inexatidão dos limites das unidades de mapeamento do mapa convencional; heterogeneidade geológica da área; profundidade do contato lítico e/ou exposição da rocha; e problemas relacionados com o próprio modelo de correlação ambiental utilizado. A comparação com pontos de observação coletados no campo 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.

Os resultados alcançados mostram que a utilização de atributos do terreno e dados de sensores remotos orbitais em uma abordagem por redes neurais pode contribuir grandemente para melhoria da qualidade dos levantamentos de solos no Brasil. A disponibilidade de dados de sensores remotos orbitais a custos mais baixos e a facilidade de obtenção dos atributos do terreno em um SIG comercial tornam a abordagem utilizada ainda mais atraente.

Os resultados promissores obtidos apontam para a necessidade de avançar nas pesquisas através da avaliação de outras técnicas de correlação ambiental, bem como técnicas geoestatísticas, para solução de problemas como aqueles que não puderam ser solucionados neste estudo, por exemplo, a separação dos Gleissolos solódicos dos não solódicos. Além disso, estas técnicas precisam ser avaliadas em condições ambientais distintas das encontradas na área estudada, principalmente em áreas de relevo suavizado, onde a contribuição dos atributos do terreno é limitada e, a utilização dos dados de sensores remotos orbitais pode ser uma alternativa viável.

# Livros Grátis

( <http://www.livrosgratis.com.br> )

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)



[Baixar livros de Literatura](#)  
[Baixar livros de Literatura de Cordel](#)  
[Baixar livros de Literatura Infantil](#)  
[Baixar livros de Matemática](#)  
[Baixar livros de Medicina](#)  
[Baixar livros de Medicina Veterinária](#)  
[Baixar livros de Meio Ambiente](#)  
[Baixar livros de Meteorologia](#)  
[Baixar Monografias e TCC](#)  
[Baixar livros Multidisciplinar](#)  
[Baixar livros de Música](#)  
[Baixar livros de Psicologia](#)  
[Baixar livros de Química](#)  
[Baixar livros de Saúde Coletiva](#)  
[Baixar livros de Serviço Social](#)  
[Baixar livros de Sociologia](#)  
[Baixar livros de Teologia](#)  
[Baixar livros de Trabalho](#)  
[Baixar livros de Turismo](#)