

**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Estratégias de mapeamento digital de solos por redes neurais
artificiais baseadas na relação solo-paisagem**

Gustavo Pais de Arruda

Dissertação apresentada para obtenção do título de
Mestre em Ciências. Área de concentração: Solos e
Nutrição de Plantas

**Piracicaba
2012**

Gustavo Pais de Arruda
Engenheiro Agrônomo

**Estratégias de mapeamento digital de solos por redes neurais
artificiais baseadas na relação solo-paisagem**

Orientador:
Prof. Dr. **JOSÉ ALEXANDRE MELO DEMATTÊ**

Dissertação apresentada para obtenção do título de
Mestre em Ciências. Área de concentração: Solos e
Nutrição de Plantas

**Piracicaba
2012**

**Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA - ESALQ/USP**

Arruda, Gustavo Pais de
Estratégias de mapeamento digital de solos por redes neurais artificiais baseadas
na relação solo-paisagem / Gustavo Pais de Arruda. - - Piracicaba, 2012.
103 p. : il.

Dissertação (Mestrado) - - Escola Superior de Agricultura "Luiz de Queiroz", 2012.

1. Atributos geomorfométricos 2. Inteligência artificial 3. Mapeamento
digital de solos 4. Redes neurais 5. Relação solo-paisagem I. Título

CDD 631.47
A779e

"Permitida a cópia total ou parcial deste documento, desde que citada a fonte – O autor"

*Aos meus pais, Aderson Pais de Arruda e Josefina Bevenuto de Arruda
pelo apoio, dedicação, amor e educação durante toda a minha vida.
Sou eternamente grato por tudo o que me fizeram...*

*Aos meus irmãos Aderson Pais de Arruda Júnior e Marcio Pais de Arruda
pelo companheirismo e amizade.
Que a distância momentânea tenha um fim breve,
para bons momentos juntos novamente...*

*Á minha querida Juliana Infante, que com muito amor e carinho
sempre esteve ao meu lado.*

DEDICO

AGRADECIMENTOS

À Deus e Jesus Cristo pela oportunidade dada para a minha evolução.

Ao meu orientador José Alexandre M. Demattê pela participação no desenvolvimento desse trabalho e pelos conhecimentos passados desde o período de graduação.

Ao pesquisador da Embrapa Solos César da Silva Chagas pela colaboração no uso das Redes Neurais, sem a qual seria impraticável a aplicação da técnica.

Aos amigos da República Mansão dos Cupins: Retirante, Corajoso, Dú, Pé-di-mesa, João, Pedro, Andréia, Álvaro, Panceta, Tomás, Pururuca, Mazzarop e Iza. Aos amigos que sempre estarão comigo: Galinhã-azú, Dativa, Kapaxão e todos os amigos da Casa do Estudante Universitário.

Aos amigos de longa data, que sempre estão comigo nos bons momentos da vida: Xuxa, Frederico, Shin, Brunão e Braojo,

À Feodor Nenov e toda a equipe da AirBrasil Balonismo, por todos esses anos de muita aventura e diversão nos finais de semana. Muita da felicidade desses dois anos foi proporcionada pela companhia de todos vocês. Obrigado!!!

Aos amigos e colegas do Departamento de Ciência do Solo: Osmar, Suzana, Fabrício, Simone, Marston, Akênia, Rodnei, Júlio, Marco, Evandro, Mathilde, Eloana, Lucas, Anderson, Neilo, Yes, Alexandre, Negão, Zé Ricardo, Gabriel, Ingrid, Josiane, Marina, dentre tantos outros amigos que estiveram comigo nessa fase da minha vida. Os bons momentos ficarão bem guardados. E aos funcionários José Roberto, Marta, Célia, Cláudia (em nome de todas as garotas da limpeza), Marcos, Luís Silva, Rossi, Leandro, Moisés, e Jair.

Às todos os meus familiares e amigos da família. Espero que sempre continuemos unidos e fortes. À Ana Maria de Jesus, Thaís Zimbres e à todos meus primos que tanto amo.

À Fundação de Amparo e Pesquisa do Estado de São Paulo - FAPESP, pelo auxílio através da concessão da bolsa.

EPÍGRAFE

Nós viemos pra esse mundo para sermos felizes
e se isso não acontecer, algo está fora da realidade...
então mude suas atitudes, mude seu mundo, e comece mudando
a você mesmo!!!
sempre para um bem maior
sempre lembrando que Deus te ama muito e torce por você.

SUMÁRIO

RESUMO.....	11
ABSTRACT	13
1 INTRODUÇÃO	15
2 REVISÃO BIBLIOGRÁFICA	17
2.1 Mapeamento digital de solos.....	17
2.2 Modelo digital de elevação e atributos do terreno	18
2.3 Relação solo-paisagem.....	21
2.4 Redes Neurais Artificiais (RNA)	24
3 MATERIAL E MÉTODOS.....	29
3.1 Caracterização da área de estudo	29
3.2 Obtenção das variáveis ambientais para uso nas estratégias digitais	30
3.2.1 Geração do modelo digital de elevação e atributos do terreno	30
3.2.2 Geologia.....	30
3.2.3 Superfícies geomórficas.....	31
3.3 Estratégia de mapeamento digital de solos 1.....	32
3.3.1 Organização dos dados.....	32
3.3.2 Classificação não-supervisionada (Fuzzy k-médias).....	33
3.3.3 Mapeamento de solos pelo método convencional.....	34
3.3.4 Aplicação da técnica de RNA.....	35
3.3.5 Comparação e validação do mapa digital de solos	37
3.4 Estratégia de mapeamento digital de solos 2.....	38
3.4.1 Obtenção das unidades de mapeamento.....	38
3.4.2 Aplicação da técnica de RNA.....	39
3.4.3 Comparação e validação do mapa digital de solos	40
4 RESULTADOS E DISCUSSÃO.....	41
4.1 Caracterização das variáveis ambientais utilizadas nas estratégias digitais.....	41
4.2 Estratégia de mapeamento digital de solos 1.....	43
4.2.1 Classificação não supervisionada (Fuzzy k-médias).....	43
4.2.2 Mapa de solos convencional e caracterização das unidades de mapeamento.....	46
4.2.3 Avaliação das redes neurais artificiais	50
4.2.4 Geração e caracterização do mapa digital de solos.....	56
4.2.5 Comparação e validação do mapa digital de solos	58
4.3 Estratégia de mapeamento digital de solos 2.....	62
4.3.1 Mapa de solos convencional e caracterização das unidades de mapeamento.....	62

4.3.2 Avaliação das redes neurais artificiais	67
4.3.3 Geração e caracterização do mapa digital de solos	72
4.3.4 Comparação e validação do mapa digital de solos.....	73
5 CONCLUSÕES.....	79
REFERÊNCIAS	81
ANEXOS.....	89

RESUMO

Estratégias de mapeamento digital de solos por redes neurais artificiais baseadas na relação solo-paisagem

A escassez de informações do solo que permitam o seu uso adequado, seja para fins agrícola, ambiental ou de projeto urbanos, pode ser minimizada com soluções provenientes do desenvolvimento de novas tecnologias. Nesse sentido, o presente estudo teve como objetivo aplicar duas estratégias digitais para obtenção de mapas de solos preliminares em áreas onde não foram realizados levantamentos pedológicos convencionais. As estratégias foram executadas com base em variáveis ambientais que estabelecem relações entre ocorrência de solos e suas posições na paisagem. A área de estudo compreendeu o município de Barra Bonita-SP, totalizando 11.072 ha. Para uso na predição dos solos pela técnica de Redes Neurais Artificiais (RNA) foram utilizadas as variáveis: declividade, elevação, perfil de curvatura, plano de curvatura e índice de convergência derivados de um Modelo Digital de Elevação (MDE), além das informações de geologia e das superfícies geomórficas identificadas na região. Na primeira estratégia, por meio de uma análise de agrupamento (Fuzzy k-médias) das variáveis, foram escolhidas cinco áreas-chaves distribuídas na área de estudo, nas quais foi realizado levantamento de solos de nível semidetalhado para reconhecimento das unidades de mapeamento. Na estratégia 2, elaborou-se um mapa de solos de nível detalhado a partir de dados pré-existentes de apenas uma área-chave, localizada no centro da região. Com a identificação das unidades de mapeamento foram gerados arquivos de treinamento e testes das redes neurais. Utilizou-se o simulador JavaNNS e o algoritmo de aprendizado "backpropagation". Conjuntos de variáveis ambientais foram testados, avaliando a importância de cada variável na discriminação dos solos. A rede que exibiu melhor desempenho do índice Kappa foi utilizada para generalização de suas informações, obtendo os mapas digitais de solos. Pela aplicação de tabulação cruzada foram analisadas as correspondências espaciais entre os mapas digitais e um mapa convencional nível semidetalhado da região. Foram coletados pontos de referência para validar o desempenho dos mapas digitais. De acordo com a posição na paisagem e material de origem subjacente, notou-se tendência na ocorrência das classes de solos nas áreas-chaves mapeadas. A mesma disposição dos solos foi observada nas classificações digitais. Os atributos do terreno elevação e declividade exibiram maior influência na distinção entre os solos pelas redes neurais em ambas as estratégias. A comparação com pontos de referência mostrou que o mapa digital produzido com base em unidades de mapeamento provenientes de abordagem convencional detalhada teve um desempenho superior (81,8% de concordância) ao mapa baseado em levantamento pedológico de nível semidetalhado (72,7%). Este estudo mostrou que a obtenção de mapas digitais de solos, com uso de variáveis ambientais que expressem a relação solo-paisagem, pode contribuir para a geração de informações preliminares do solo em locais não mapeados, a partir de unidades de mapeamento obtidas em áreas adjacentes.

Palavras-chave: Mapa digital de solos; Inteligência artificial; Atributos geomorfométricos

ABSTRACT

Strategies for digital soil mapping by artificial neural networks based on soil-landscape

The scarcity of land information to enable its proper use, whether for agricultural, environmental and urban design, can be minimized by solutions from the development of new technologies. Accordingly, this study aimed to apply two strategies to obtain digital maps of soil in areas where no preliminary surveys were carried out conventional pedological. The strategies were implemented based on environmental variables that establish relations between the occurrence of soils and their positions in the landscape. The study area comprised the municipality of Barra Bonita, SP, totaling 11,072 ha. For use in the prediction of soil by the technique of Artificial Neural Networks (ANN) were used variables: slope, elevation, profile curvature, plan curvature and convergence index derived from a Digital Elevation Model (DEM), in addition to information geology and geomorphic surfaces identified in the region. In the first strategy, through a cluster analysis (Fuzzy k-means) of variables, we selected five key areas distributed in the study area, soil survey being conducted semi-detailed level at these sites for recognition of the map units. In strategy 2, a map was drawn up detailed level of soil from pre-existing data of only one key area, located in the center of the region. Identifying the map units were generated files for training and testing of neural networks. Was used the simulator JavaNNS and learning algorithm "backpropagation". Sets environmental variables were tested by assessing the importance of each variable to predict soil. The network showed better performance for the Kappa index was used to generalize their information, obtaining the digital soil maps. By applying cross tabulation analyzed the spatial correspondence between the digital maps and a conventional map of the region. Reference points were collected to validate the performance of digital maps. According to the position in the landscape and the underlying source material, was noticed a tendency of occurrence of soil classes in key areas mapped. The same arrangement was observed in the soil classifications digital. The attributes of the terrain elevation and slope exhibited a greater influence on the distinction between the soil by the neural networks in both strategies. The comparison with reference points showed that the digital map produced based on mapping units from the conventional approach detailed outperformed (81.8% agreement) to the map based on pedological survey of semi-detailed level (72.7 %). This study showed that to obtain digital maps of soils, use of environmental variables that express the soil-landscape relationship, may contribute to the generation of information preelminares soil in areas not mapped from map units obtained from adjacent areas.

Keywords: Digital soils map; Artificial intelligence; Attributes geomorphometric

1 INTRODUÇÃO

O conhecimento sobre as propriedades e atributos dos solos assume extrema importância na adoção de práticas adequadas de manejo, visando sustentabilidade do meio ambiente e maior eficiência na produção de alimentos. Problemas como erosão, contaminação do lençol freático, baixas produtividades em locais de alto potencial produtivo, entre outros fatores de caráter ambiental ou de produção, podem ser reduzidos ou até mesmo evitados com o uso de informações do solo. Neste sentido, destacam-se os levantamentos pedológicos como importante ferramenta por permitir a avaliação das limitações e do potencial de cada solo, prevenindo risco diante de um mau uso do mesmo, assim como permitindo a viabilização de projetos, planejamento de práticas agrícolas e conservação ambiental.

Pode-se dizer que o Brasil é um país totalmente carente de mapas de solos com nível de detalhe adequado a estudos em escala municipal (OLIVEIRA, 1999). Fatores como o declínio no número de pedólogos, o alto custo e o tempo demorado na realização dos levantamentos pedológicos tem contribuído para escassez dessas informações no contexto das ciências naturais (DEBELLA-GILO; ETZELMÜLLER, 2009).

Com o avanço tecnológico algumas alternativas vem sendo aplicadas para a geração de informações que minimizem problemas de incompatibilidade entre informação do solo e o manejo adotado. Tais alternativas são baseadas no uso de Sistema de Informação Geográfica (SIG) e técnicas de sensoriamento remoto, aliadas ao uso de algoritmos matemáticos que estabelecem relações entre os fatores e processos de formação dos solos e suas ocorrências na paisagem. Isto resulta no que pode ser denominado de Mapeamento Digital de Solos (MDS).

Uma importante técnica empregada na obtenção de mapas digitais constitui das Redes Neurais Artificiais (RNA). Estas realizam processamento de dados de maneira semelhante aos neurônios do cérebro humano (ZHU, 2000), permitindo o estabelecimento de relações matemáticas entre variáveis ambientais e classes de solos (COELHO, 2010). Dentre as inúmeras variáveis que vem sendo aplicadas no MDS, destacam-se os atributos derivados dos Modelos Digitais de Elevação (MDE) e as informações geológicas. Dessa forma, a predição de solos tem se baseado na relação solo-paisagem. Segundo Hudson (1992) a modelagem solo-

paisagem apresenta-se como um paradigma para o levantamento de solos e para o entendimento de seus padrões naturais, sendo tais modelos combinados com banco de dados e SIGs na tentativa de se prever a distribuição espacial e variação das propriedades dos solos.

No mapeamento de solos convencional o pedólogo coleta evidências das variáveis ambientais relacionadas aos processos e fatores de formação dos solos e gera uma hipótese a respeito da ocorrência destes. Tal processo varia de acordo com o modelo mental da relação solo-paisagem que cada pedólogo dispõe e das variáveis em que ele acredita manter maior relação com a ocorrência de solos. De maneira semelhante, a inserção de dados quantitativos que expressem os fatores de formação, em sistemas de inteligência artificial, prediz a partir de um processo de aprendizagem a ocorrência dos solos (ZHU, 2000; CHAGAS; CARVALHO JÚNIOR; BHERING, 2011; CHAGAS et al., 2010). Dessa forma, o trabalho tem por objetivo obter mapas digitais de solos com uso de RNA em função de variáveis que exprimam a relação solo-paisagem, com o intuito de reduzir a escassez de informações dos solos em áreas não mapeadas. Os objetivos específicos são: avaliar os desempenhos das variáveis aplicadas e dos níveis de detalhamento de mapas convencionais utilizados na predição das unidades mapeadas digitalmente.

Como hipótese, espera-se que: (a) a relação entre variáveis ambientais e ocorrência de solos na paisagem, estabelecida pelas redes neurais a partir de áreas menores, possa ser generalizada para áreas maiores e adjacentes, obtendo a classificação das unidades de mapeamento com qualidade. Assim, os mapas digitais de solos apresentarão coerência com a realidade de campo, devido serem gerados a partir de informações obtidas em levantamentos pedológicos convencionais; (b) as variáveis exibam comportamento distinto entre as unidades de mapeamento, contribuindo na separação das classes pela RNA; (c) o subsídio de informações provenientes de mapas de solos mais detalhados melhorem os resultados obtidos.

2 REVISÃO BIBLIOGRÁFICA

2.1 Mapeamento digital de solos

O mapeamento digital de solos tem surgido como uma área na que o mapeamento de solos é otimizado através da aplicação de metodologias pedométricas as quais possuem uma forte base matemática e estatística, com a aplicação do conhecimento em pedologia. Estas metodologias incorporam informações do ambiente as quais podem influir em determinadas condições do solo, podendo ser relacionadas às funções de predição de solos.

O primeiro modelo preditivo descrito foi o fatorial postulado por Jenny (1941). Nesta função clássica em pedologia, os fatores que determinam a formação do solo (S) são: clima (cl), organismos (o), relevo (r), material parental (p) e tempo (t), $S = f(\text{cl}, \text{o}, \text{r}, \text{p}, \text{t})$ ou *sclorpt*. Desde a aparição deste modelo, estudos tem sido desenvolvidos com o objetivo de estabelecer de forma quantitativa as relações entre estes fatores e o solo. Com o desenvolvimento dos sistemas de informação geográfica (SIG), as relações espaciais destes fatores começaram a ser mais exploradas. Desta forma, o componente espacial teve um grande impacto na compreensão dos fatores de formação, sobretudo quando relacionado ao relevo. A inserção de modelos digitais de elevação em SIG potencializou as pesquisas das relações entre o solo e parâmetros do terreno, e a compreensão das relações espaciais entre atributos pertencentes aos fatores de formação foi favorecida pela incorporação de metodologias geoestatísticas.

Em relação à predição espacial do solo McBratney; Mendonça e Minasny (2003) indicam que: (1) de forma geral, têm sido facilmente encontradas relações quantitativas entre o solo e a topografia, não obstante existe evidência de relações quantitativas com os outros quatro fatores de formação do solo; (2) em geral, as relações entre os fatores de formação e o solo não podem ser assumidas como lineares; (3) poucos trabalhos têm sido desenvolvidos em relação à interação entre fatores; (4) os solos podem ser preditos espacialmente a partir da sua posição geográfica usando uma variedade de técnicas; (5) os solos podem ser preditos a partir de outros atributos em um mesmo ponto geográfico; (6) o solo pode ser predito a partir dele mesmo, outros atributos do solo e atributos ambientais de localidades vizinhas.

Diante de tal fato, estes autores propuseram uma modificação ao modelo clorpt de Jenny. Esta modificação inclui dois fatores dos quais o solo pode ser inferido, sendo eles: espacial, devido a que o solo pode ser predito a partir de informações vizinhas; solo, devido a que o solo pode ser predito a partir de seus próprios atributos, ou os atributos podem ser preditos a partir das classes ou outras propriedades (MCBRATNEY; MENDONÇA; MINASNYA, 2003). Desta forma o solo (S) é uma função do solo (s), clima (c), organismos (o), relevo (r), material parental, idade ou tempo (a) e da sua posição no espaço (n). Este novo enfoque do modelo diretamente derivado do clorpt de Jenny recebe o nome de modelo *scorpan*, o qual pode ser escrito como:

$$Sc = f(s, c, o, r, p, a, n) \text{ ou } Sa = f(s, c, o, r, p, a, n)$$

Em que:

Sc são as classes de solos;

Sa são os atributos do solo.

Os mapas digitais de solos não são produtos estáticos, podendo ser modificados de forma contínua na medida em que novas informações (referentes às áreas de mapeamento) vão sendo disponibilizadas e incorporadas nas bases de dados. Assim, a acurácia destes mapas pode ser melhorada com menor custo e de forma rápida (SCHMIDT; BEHRENS; SCHOLTEN, 2008; HANSEN et al., 2009). A significativa diminuição de custos do mapeamento digital em relação ao convencional faz com que áreas de maior tamanho possam ser mapeadas com o mesmo investimento usado em áreas menores e que o monitoramento do solo possa ser mais frequente.

2.2 Modelo digital de elevação e atributos do terreno

A identificação de formas de terreno é tradicionalmente realizada por julgamentos em termos qualitativos, baseando-se nas descrições obtidas na fase de interpretação da paisagem. Métodos paramétricos são também possíveis e de grande interesse, pois fornecem uma base mais objetiva e uniforme para a identificação de sistemas terrestres. Doyle (1978) definiu os modelos que representam graficamente o relevo da superfície terrestre como um arranjo ordenado

de números, que reproduzem a distribuição espacial das características do terreno. Quando a característica do terreno é o relevo estimado pela sua cota ou altitude, tais modelos são denominados de Modelo Digital de Elevação (MDE). Este pode ser considerado como uma representação quantitativa digital da variação contínua do relevo sobre o espaço (GALLANT; WILSON, 2000).

Algumas das vantagens da utilização da análise digital do terreno sobre o método tradicional de análise estereoscópica de fotografias aéreas consistem na: rapidez e economia para quantificação e classificação de dados do relevo, com definição automática ou semi-automática das unidades morfológicas da paisagem (MCBRATNEY; MENDONÇA-SANTOS; MINASNYA, 2003) capacidade de explicar as relações existentes entre as propriedades dos solos e as formas da paisagem; rapidez e facilidade para correções em mapas de solos; facilidade de interpretação das mudanças graduais e contínuas das propriedades dos solos; disponibilidade de produtos de informações digitais (ZHU et al., 2001).

As características do relevo podem ser divididas em atributos primários e secundários, sendo que no primeiro caso são diretamente calculados a partir de um MDE, enquanto no outro a obtenção é feita pela combinação entre alguns atributos primários. A declividade, plano e perfil de curvatura, orientação da vertente e área específica de contribuição são alguns exemplos de atributos primários. Para os secundários tem-se o índice de umidade, índice de transporte de sedimentos, entre outros (MOORE et al., 1993).

Vários são os trabalhos que relacionam o comportamento dessas variáveis morfométricas com um determinado padrão de ocorrência de atributos dos solos ou de classes de solos na paisagem (ZHU, 2000; CHAGAS, CARVALHO JÚNIOR; BHERING, 2011; THOMAS et al., 1999; SOUZA JÚNIOR; DEMATTÊ, 2008; DEBELLA-GILO; ETZELMÜLLER, 2009). Isto devido estas variáveis serem consideradas como um importante atributo controlador dos processos pedogenéticos por influírem no comportamento da água no solo. A declividade, afeta diretamente a velocidade do fluxo superficial e sub superficial da água, mantendo estreita relação com o teor de água no solo e potencial de erosão e deposição, além de outros processos (GALLANT; WILSON, 2000). O perfil de curvatura tem como característica descrever a forma da vertente no sentido descendente, podendo ser côncavo, convexo ou retilíneo; indica a proporção de mudança de potencial, sendo importante para o escoamento da água e velocidade de processos de transporte de

sedimentos. Por sua vez, o plano de curvatura, que pode ser classificado como convergente, divergente ou planar, está relacionado com a concentração e dispersão de água na paisagem. Ou seja, a curvatura se relaciona com os diferentes regimes de umidade, característica fundamental para uma avaliação mais precisa da distribuição dos solos na paisagem (HALL, 1983). Os índices de convergência topográfica indicam o acúmulo relativo da umidade na paisagem, expressando uma medida da tendência da água de superfície acumular-se ou não em diferentes locais (WOLOCK, 1993). Sua utilidade consiste em apresentar graficamente a estrutura morfológica de uma área, definindo locais de ocorrência de cordilheiras e vales (KISS, 2004).

O mapeamento do solo realizado de forma automatizada, resultando no que é denominado de Mapeamento Digital de Solos, faz uso de variáveis ambientais derivadas de um MDE para a predição espacial de classes de solos (SANCHEZ et al., 2009). Chagas et al. (2010) utilizaram os atributos topográficos elevação, declividade, aspecto, plano de curvatura e índice topográfico, junto à índices derivados de uma imagem Landsat 7, no mapeamento digital de solos com uso de redes neurais. Os autores observaram que o grupo de variáveis discriminantes contendo apenas os atributos do terreno apresentou melhores resultados na discriminação dos solos em relação ao grupo com apenas os índices derivados da imagem. Nesse trabalho, a declividade e a elevação foram os que mais contribuíram para melhorar o desempenho na classificação de solos.

Sirtoliet al. (2008) avaliaram as relações ocorrentes entre alguns atributos do terreno e os solos mapeados na região da Bacia Sedimentar de Curitiba, como auxílio na compreensão da distribuição dos solos na paisagem com distintas características. A declividade foi o atributo que melhor se correlacionou com as unidades de solos. Os perfis e planos de curvatura apresentaram particularidades para as classes dos Latossolos, Cambissolos e associação entre Gleissolos e Organossolos. No padrão estabelecido para a ocorrência de solos nas encostas da região estudada, os Latossolos se situaram nas posições mais elevadas, solos de caráter hidromórfico nas posições baixas e os Cambissolos nas posições intermediárias.

Rizzo (2011) obteve resultado classificado como muito bom, de acordo com o índice Kappa, na comparação entre um mapa de solos obtido por metodologia convencional e o mapa digital de solos gerado por atributos do terreno. Os atributos

utilizados foram: declividade, poder de fluxo d'água, curvatura, fator LS e índice de saturação topográfico. A estratégia de mapeamento aplicada pelo autor representou de maneira coerente a variabilidade espacial dos solos.

Ten Caten et al. (2009) utilizaram regressões logísticas múltiplas na espacialização de classes de solos em função de nove atributos do terreno derivados de um MDE. Concluíram que a modelagem linear generalizada possui potencial para gerar mapas de solos com padrão similar ao existente no mapa utilizado para treinar os modelos. Figueredo et al. (2008), aplicando a mesma técnica, fizeram uso dos atributos elevação, declividade, curvatura, distância dos rios, índice de umidade topográfica, comprimento de fluxo de escoamento e índice de poder de escoamento na predição de ocorrência e distribuição de classes de solos. A comparação entre o mapa digital e o mapa convencional apresentou elevada correspondência, reforçando a ideia de que o modelo gerado adequou-se na tentativa de aproximar as pedoformas estimadas às pedoformas originais.

Acurácia de 61% entre mapa digital e convencional foi obtido por Crivelenti (2009) empregando um modelo de predição de unidades de mapeamento de solos baseado na análise hierárquica do tipo árvores de decisão. As variáveis ambientais aplicadas na estratégia digital constituíram de parâmetros geomorfométricos derivados de um Modelo Digital de Elevação, mapa geológico e dados oriundos de levantamento de solos pré-existente. A influência das variáveis na predição das unidades de mapeamento decresceu na seguinte sequência: formação geológica, distância diagonal de drenagem, declividade, perfil de curvatura, plano de curvatura e área de contribuição da bacia.

De acordo com o exposto, fica evidente o emprego de atributos do terreno, derivados de um MDE, como variáveis ambientais em estratégias de mapeamento digital de solos. O uso dessas informações do terreno pode ser acompanhado de outras variáveis que expressem alguma relação com os fatores de formação dos solos.

2.3 Relação solo-paisagem

O mapeamento de solos há muito tempo tem se fundamentado nas relações existentes entre a ocorrência de solos e a paisagem (IPPOLIT et al., 2005), o que evidencia a importância do estudo do comportamento entre si dos aspectos

pedológicos, geológicos e geomorfológicos sobre a compreensão da distribuição das unidades de mapeamento de solos na paisagem (TERAMOTO; LEPSCH; VIDAL-TORRADO, 2001).

Informações de parâmetros geomorfológicos em levantamentos pedológicos e em estudos de variabilidade espacial dos solos são capazes de melhorar os resultados obtidos, tanto pela identificação das superfícies geomórficas, que exprime a idade relativa dos solos, quanto pelo reconhecimento da coluna litoestratigráfica e do material de origem (DANIELS; GAMBLE; CADY, 1971; GERRARD, 1993). No modelo de paisagem proposto por Ruhe (1969) e Daniels; Gamble e Cady (1971) superfície geomórfica é definida como sendo uma porção de terra que é definida no espaço e no tempo.

Além disso, o entendimento das relações entre solo e superfície geomórfica pode subsidiar levantamentos de solo por possibilitar a predição da feição pedológica de áreas ainda não investigadas, na tentativa de identificar a topossequência típica e o padrão de distribuição espacial dos solos e seus atributos em uma região (MOTTA et al., 2002).

Nesse contexto, a compartimentação da paisagem tem sido considerada importante ferramenta à identificação e mapeamento de áreas com solos homogêneos (CAMPOS et al., 2007). Diversos autores tem se dedicado ao estudo da compreensão da dinâmica e distribuição dos solos na paisagem (RODRIGUES; KLANT, 1978; LEPSCH; BUOL; DANIELS, 1977; VIDAL-TORRADO, 1994; COELHO; LEPSCH; MENK, 1994; MARQUES JÚNIOR; LEPSCH, 2000).

Teramoto; Lepsch e Vidal-Torrado (2001) estabeleceram relações entre superfícies geomórficas, unidades de mapeamento de solos e litologia em uma microbacia na região de Piracicaba, SP. Após identificação de dez unidades de mapeamento e cinco superfícies geomórficas, verificaram que quanto mais velha e estável a superfície menor era a variação de alguns atributos do solo, e que a evolução pedogenética foi maior com o aumento da idade da superfície. Constataram também que a variabilidade dos atributos químicos e físicos dos solos na camada de 60-80 cm mostrou-se litodependente. Por sua vez, os atributos morfológicos foram determinados principalmente pelo relevo.

Lepsch; Buol e Daniels (1977) observaram relação entre a ocorrência de unidades de mapeamento e das superfícies geomórficas identificadas numa região do Planalto Ocidental Paulista. Em um pequeno platô de relevo muito suave e

de provável origem deposicional foram mapeados os Oxisols, também ocorrentes em uma superfície a sudoeste desse local com colinas suaves onduladas. Na borda do platô, com declividades entre 2 a 8% e de origem erosional identificaram um complexo de Alfisols e Ultisols. Nas encostas que cortam abaixo dessa última superfície e em relevo mais acidentado, foram mapeados Alfisols e Ultisols abruptos e, na última superfície localizada mais ao pé da encosta e adjacente ao canal de drenagem ocorreram os Mollisols e um complexo de Ultisols. Verificaram, portanto, que cada superfície geomórfica exibiu comportamento distinto quanto à ocorrência de unidades mapeadas, possibilitando a determinação de um padrão de distribuição de solos na região.

No que diz respeito aos atributos pedológicos, a topografia do terreno configura-se no indicador mais importante sobre as propriedades do solo (MULLA; MCBRATNEY, 1999). Por interferir na drenagem, nos movimentos verticais e horizontais da água e, conseqüentemente, nos processos pedogenéticos, as formas do relevo promovem variações nos atributos químicos, físicos, biológicos e mineralógicos do solo, os quais estão condicionados à dinâmica da água em superfícies e subsuperfícies (BLASZCZYNSKI, 1997; BUI, 2004). Salienta-se, desta forma, a utilidade do aspecto topográfico da área para melhor compreensão das características distintas dos solos.

Cunha et al. (2005) relacionaram três superfícies geomórficas, identificadas em uma vertente de sequência litoestratigráfica arenito-basáltica, com os atributos físicos, químicos e mineralógicos de Latossolos. As variações dos solos na transeção estudada foram influenciadas pela idade das superfícies, inclinação do terreno e litologia. As diferentes taxas de Fe_d/Fe_s obtidas nos solos mapeados comprovaram que superfícies mais velhas exibem solos mais intemperizados.

Sanchez et al. (2009) caracterizou a variabilidade espacial de atributos do solo em diferentes pedoformas na região de Catanduva, SP. Nas pedoformas côncavas foi encontrada maior variabilidade espacial e maiores valores médios para atributos químicos e espessura do horizonte A+E. Por outro lado, menores teores de argila ocorreram nesses locais, demonstrando que a forma do relevo condicionou padrões diferenciados na variabilidade dos atributos estudados. De acordo com os autores, o relevo condicionou o fluxo de água e de solutos do solo, apresentando maior convergência nas formas côncavas, que por sua vez afetou a variabilidade espacial dos atributos do solo.

Campos; Marques Júnior e Pereira (2010) estudaram as influências das superfícies geomórficas na distribuição espacial dos atributos dos solos na região de Pereira Barreto, SP. Os resultados obtidos pelos autores mostraram que os atributos areia fina e areia grossa apresentaram distribuição espacial coincidente com as superfícies geomórficas estudadas, assim como os teores de argila e silte. O mesmo foi constatado para os atributos químicos: soma de bases (SB), pH, saturação de bases (V%), capacidade de troca catiônica (CTC) e o teor de matéria orgânica, nas profundidades de 0-25 cm e 80-100 cm, aumentando gradualmente da superfície mais antiga para a mais jovem. Os autores concluíram que a complexidade e variabilidade dos solos são inversamente proporcionais à idade da superfície.

2.4 Redes Neurais Artificiais (RNA)

No campo de pesquisa denominado de Inteligência Artificial, as Redes Neurais Artificiais (RNA) é uma técnica de programação fundamentada em um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento por meio da experiência (NUNES, 2003). Nesses organismos, cada neurônio é uma estrutura simples que permite três funções básicas: entrada, processamento e saída de sinais, realizadas nos dendritos, núcleo e axônio, respectivamente. Os dendritos são conexões que enviam sinais de entrada para os neurônios e o núcleo é o processador dessas informações. Caso o valor resultante da soma dos sinais esteja acima de certo limiar, o neurônio é excitado e tende a propagar o estímulo recebido. Os axônios são os canais de saída e estão ligados aos dendritos de outros neurônios através de sinapses.

Semelhante ao cérebro humano, a técnica de RNA adquire conhecimento por meio de um processo de aprendizado de sua rede formada por elementos de processamento (neurônios). Este conhecimento, relacionado às intensidades das conexões entre os neurônios, é denominado de pesos sinápticos (HAYKIN, 1994). As funções, o comportamento e a forma de um neurônio biológico são simuladas na estrutura lógico-matemática de um neurônio artificial. Assim, os dados de entrada correspondem aos dendritos, cujas ligações com o núcleo são realizadas através de elementos chamados pesos. Os estímulos que são captados pela camada de entrada são processados por uma função soma, sendo que o limiar

de disparo do neurônio biológico corresponde à função de ativação (SOUZA, 2006). Um esquema de um neurônio artificial pode ser verificado na Figura 1.

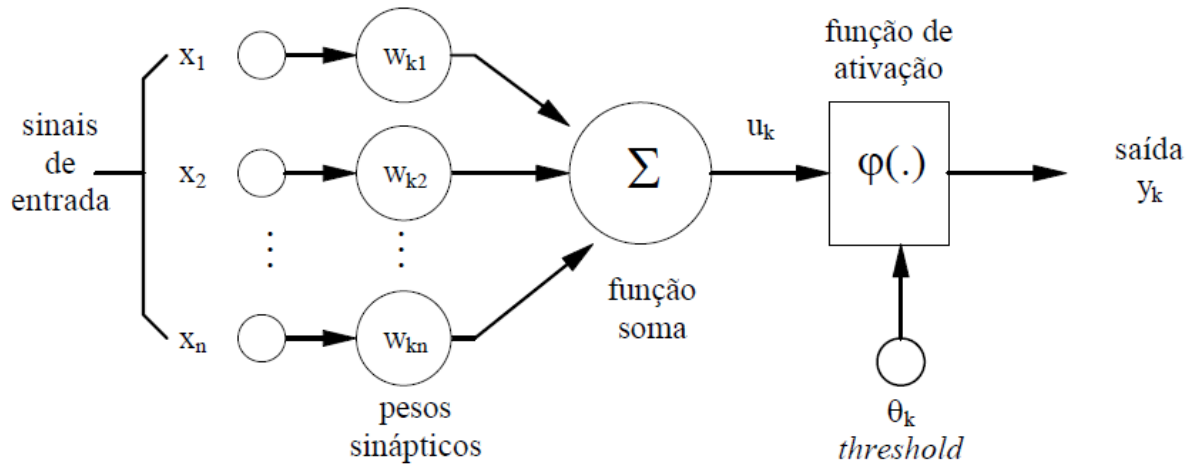


Figura 1 - Modelo de um neurônio (HAYKIN, 1994)

Os sinais de entrada equivalem às variáveis utilizadas para a resolução de um problema. Para exemplificar, dentro do contexto do mapeamento digital de solos, esses sinais correspondem às variáveis ambientais declividade, elevação, geologia, entre outras informações que se relacionam com algum fator de formação dos solos. As sinapses são caracterizadas por um peso (w) que representa sua intensidade. O peso w_{kn} tem como função multiplicar o sinal x_n na entrada da sinapse n conectada a um neurônio k . O peso w_{kn} é positivo se a sinapse associada é excitatória e negativo se a sinapse associada é inibitória. A função soma adiciona as entradas ponderadas pelos seus pesos respectivos, o que pode ser verificado na Equação 1:

$$u_k = \sum_{i=1}^n w_{ij} x_j \quad (1)$$

O limiar (threshold), θ_k , tem papel determinante na saída do neurônio, sendo que, se o valor de u_k for menor que este limiar, a saída do neurônio será inibida. Do contrário, o neurônio ficará ativo. A função de ativação tem como objetivo limitar a amplitude da saída de um neurônio, normalizando a entrada em um

intervalo fechado, normalmente entre $[0,1]$ ou $[-1,1]$. A saída do neurônio (y_k) pode ser representada pela Equação 2:

$$y_k = \varphi(u_k - \theta_k) \quad (2)$$

Em que:

φ é a função de ativação.

De maneira resumida, as operações que ocorrem em um neurônio da rede constam da apresentação de sinais à entrada, onde cada sinal é multiplicado por um peso indicando sua influência na saída da respectiva unidade; uma soma ponderada dos sinais é calculada, produzindo um nível de atividade, sendo que, se este nível exceder um limite (threshold) é produzida uma saída pela unidade.

De acordo com Brown et al., (2000) as propriedades que fazem das RNA adequadas ao reconhecimento de padrões e à classificação de dados espaciais são: facilidade para análises de grandes conjuntos de dados; habilidade em extrair padrões ocultos em conjuntos de dados que poderiam ser imperceptíveis aos humanos e às técnicas estatísticas tradicionais; possibilidade de trabalhar com dados ruidosos, limitados, interdependentes ou não-lineares. Destaca-se também sua capacidade em generalizar informações, ou seja, apresentar bons resultados para padrões não utilizados durante a fase de treinamento da rede (VIEIRA, 2000). No contexto da aplicação de RNA na classificação de dados de sensoriamento remoto, Atkinson e Tatnall (1997) enfatizaram como principais vantagens a independência do tipo de distribuição, diferindo da abordagem estatística paramétrica tradicional (distribuição normal), e a habilidade na manipulação de dados adquiridos em diferentes níveis de precisão.

Para a solução de um problema de aprendizado aplicando-se RNA, faz-se uso de um conjunto de regras bem definidas, denominado de algoritmo de aprendizado (BRAGA; CARVALHO; LUDERMIR, 1998). Haykin (1999) define aprendizagem como um processo pelo qual os parâmetros livres de uma rede neural são adaptados por meio de estímulos do ambiente em que a rede está inserida. O que difere substancialmente os vários tipos de algoritmos existentes para uso em modelos de redes neurais é a forma com que os pesos são atualizados.

Um algoritmo muito utilizado tem sido o *backpropagation*, também chamado de Regra Delta Generalizada, que realiza o aprendizado por correção do

erro. Este se baseia na retropropagação dos erros para que sejam efetuados os ajustes dos pesos. Ou seja, com a apresentação de um padrão à rede pela primeira vez, esta produz uma saída aleatória, sendo que a diferença entre a saída e o desejado constitui o erro (RAIA JR., 2000).

À organização dos elementos constituintes da rede dá-se o nome de topologia ou arquitetura da RNA. Dentre as redes mais utilizadas pode ser citada a Perceptron Multicamadas, constituída de: uma primeira camada de entrada com função de armazenar e apresentar os dados de entrada (conjunto de variáveis) na rede; camada intermediária ou oculta, onde os processamentos ocorrem, através de conexões que ponderam as entradas por meio dos pesos; e camada de saída, que recebe os valores já processados (SIRTOLI, 2008). A Figura 2 exibe um esquema de uma RNA do tipo Perceptron Multicamadas, exemplificando uma rede para o mapeamento digital de solos, contendo: cinco neurônios na camada de entrada (representando as variáveis ambientais), cinco na oculta ou interna, e três na camada de saída (representando as unidades de mapeamento).




Figura 2 - Esquema de uma RNA com três camadas

As etapas para aplicação das RNA são divididas em três momentos, denominados de treinamento, teste e generalização. Inicialmente, a rede aprende a resolver um conjunto de padrões de saída relacionados aos padrões de entrada. Nessa etapa são treinadas várias redes. Alguns dos fatores que caracteriza a diferença de uma rede para outra são: número de neurônios na camada de entrada (variáveis utilizadas) e na camada oculta; número de camada oculta; algoritmo de aprendizagem; ciclos de aprendizagem; entre outros. Num segundo momento, são

realizados testes estatísticos onde as saídas obtidas de novos padrões de entrada são comparadas às saídas desejadas, na pretensão de se validar cada rede treinada na primeira etapa. Por fim, a rede escolhida de acordo com a fase anterior é utilizada na resolução do problema, generalizando o conhecimento obtido. O treinamento é a única fase em que ocorre aprendizado, o qual se repete até a obtenção de resultados satisfatórios, ou seja, até que o especialista aceite os valores de erros gerados (MASTER, 1993).

No que diz respeito à utilização da técnica de redes neurais para o mapeamento digital de solos, trabalhos como os de Chagas; Carvalho Júnior e Bhering (2011), Chagas et al. (2010), Sirtoli (2008), Carvalho Júnior (2005) e Zhu (2000) comprovaram o bom desempenho das RNA na predição de classes de solos. Nesses trabalhos foram utilizados como variáveis ambientais dados como: atributos do terreno derivados de um Modelo Digital de Elevação, informações da geologia e índices obtidos de sensores acoplados em satélites.

3 MATERIAL E MÉTODOS

3.1 Caracterização da área de estudo

O trabalho foi desenvolvido em uma região pertencente ao município de Barra Bonita, Estado de São Paulo, em uma área de 11.072 ha, entre as coordenadas UTM (Universal Transversa de Mercator) de 750.539,3 e 764.418,8 mE e 7.524.287,8 e 7.514.029,1 mN (fuso 22, *Datum* SAD 69) (Figura 3). O clima da região, baseada na classificação de Köppen, é do tipo Cwa, subtropical de altitude com inverno seco, com temperatura média máxima de 30,0°C no mês mais quente e média mínima de 12,2°C no mês mais frio. A pluviosidade média anual é de 1.471 mm. A geologia é representada pela Formação Itaqueri composta predominantemente de arenitos de cimento argiloso e a Formação Serra Geral do Grupo São Bento, de basaltos, havendo dessecamento da cobertura arenítica do Itaqueri pela drenagem (IPT, 1981). A vegetação original de floresta latifoliada tropical semidecídua encontra-se substituída pela cultura da cana-de-açúcar.




Figura 3 - Localização da área de estudo

3.2 Obtenção das variáveis ambientais para uso nas estratégias digitais

3.2.1 Geração do modelo digital de elevação e atributos do terreno

Um Modelo Digital de Elevação (MDE) foi gerado, permitindo que fossem derivados atributos do terreno para uso como variável ambiental nas estratégias de mapeamento digital. Para tanto, as informações de referência para a obtenção desse modelo foram extraídas de quatro cartas topográficas com escala 1:10.000 (Instituto Geográfico e Cartográfico do Estado de São Paulo), referentes às Folhas Usina Lambari (SF-22-Z-B-II-4-SE-B), Campo Salles (SF-22-Z-B-II-4-SE-D), Mineiros do Tietê I (SF-22-Z-B-III-3-SO-A) e Mineiros do Tietê II (SF-22-Z-B-III-3-SO-C). Estas foram escaneadas, inseridas em um banco de dados e georreferenciadas, sendo realizadas as digitalizações dos respectivos pontos cotados, curvas de nível com equidistância vertical de 5m e hidrografia.

Nessa etapa, fez-se uso do SIG (Sistema de Informação Geográfica) ArcMap 9.3 (ESRI, 2006) com aplicação da função TOPO to RASTER, que é um método de interpolação especificamente desenhado para a criação de um MDE hidrológicamente consistente, baseado no programa ANUDEM desenvolvido por Hutchinson (1993). Esta função 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, 2006). Aplicou-se o procedimento FILL (ArcGis) para a correção de depressões espúrias.

Após a geração do modelo, foram derivados quatro atributos do terreno, sendo eles: declividade, perfil de curvatura, plano de curvatura (MOORE et al., 1991) e índice de convergência (KISS, 2004). A elevação foi obtida diretamente do MDE. Os atributos foram gerados com resolução espacial de 20 metros. Esse valor foi considerado adequado com a escala de trabalho utilizada e não resultou em demasiado tempo para processamento dos dados.

3.2.2 Geologia

Informações referentes à geologia da área foram obtidas por meio da digitalização de um mapa geológico com escala 1:500.000 (IPT, 1981) (Anexo A). Após georreferenciamento e vetorização do mapa, foi gerado um arquivo *raster*, com

resolução espacial de 20 metros, para posterior extração das informações de cada pixel e utilização como variável ambiental nas estratégias de mapeamento aplicadas.

No arquivo *raster*, os pixels localizados nas áreas correspondentes ao arenito Itaqueri foram classificados com o valor numérico “1”, e os situados nas áreas de basalto da Formação Serra Geral receberam o valor “0”. Essa conversão deve-se à necessidade de inserção de dados quantitativos na camada de entrada das redes neurais.

3.2.3 Superfícies geomórficas

A identificação das superfícies geomórficas foi realizada com o objetivo de se aplicar às RNA mais uma variável que expressasse relação com a ocorrência de solos na paisagem. Nessa informação está intrínseca a idade relativa dos solos (DANIELS; GAMBLE; CADY, 1971; TERAMOTO; LEPSCH; VIDAL-TORRADO, 2001; CUNHA et al., 2005; MARQUES JÚNIOR; LEPSCH, 2000). Assim, foi adicionado indiretamente o fator de formação dos solos “tempo” como variável nas estratégias digitais aplicadas.

Com base nas variações do relevo, identificando discontinuidades ou mudanças de gradientes nas inclinações das encostas, foram classificadas e delimitadas em um mapa as diferentes superfícies geomórficas ocorrentes na área de estudo. Isto se fez possível a partir de análise estereoscópica feita com fotografias aéreas na escala de 1:30.000. Como informação complementar analisou-se o comportamento dos atributos do terreno derivados do MDE, as curvas-de-nível obtidas das digitalizações das cartas planialtimétricas e o conhecimento da estratigrafia local. Foram seguidos os critérios e conceitos estabelecidos por Ruhe (1969) e Daniels; Gamble e Cady (1971).

O mapa com as superfícies foi digitalizado, georreferenciado e vetorizado, criando-se um arquivo *raster* com resolução espacial de 20 metros. Da mesma forma que os dados de geologia, os pixels com as informações das superfícies geomórficas foram classificados com valores numéricos para uso nas redes neurais.

3.3 Estratégia de mapeamento digital de solos 1

A Figura 4 apresenta um fluxograma com as atividades desenvolvidas na estratégia 1 para a obtenção do Mapa Digital de Solos 1 (MDS1).

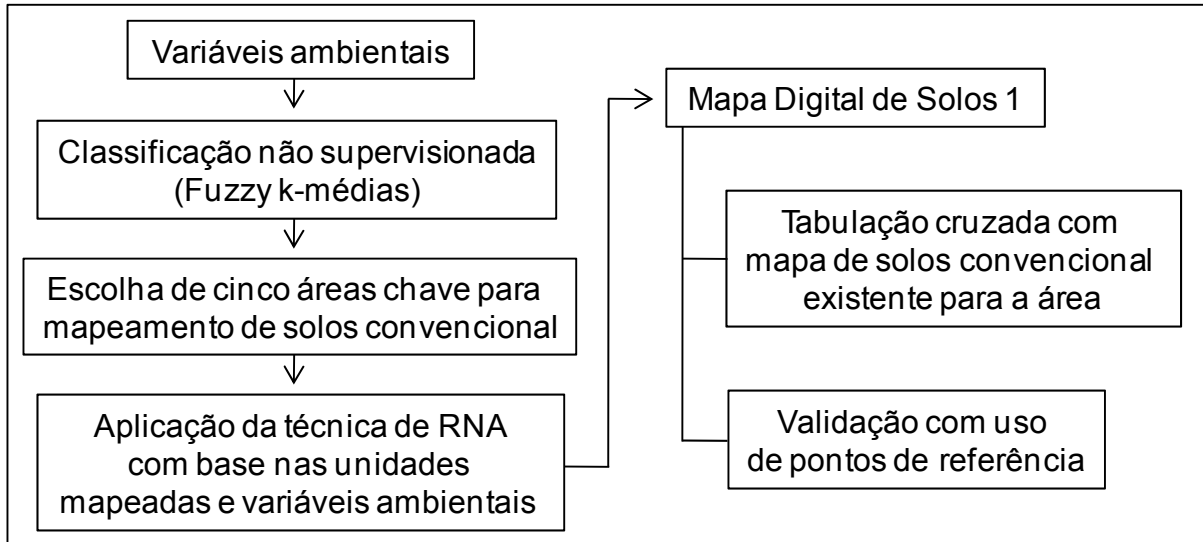


Figura 4 - Fluxograma para a estratégia 1

3.3.1 Organização dos dados

Com o objetivo de se obter uma planilha contendo os valores de cada variável ambiental em cada pixel, foi criado um banco de dados contendo os arquivos *raster* da elevação, declividade, índice de convergência, perfil de curvatura, plano de curvatura, geologia e superfície geomórfica. Cada arquivo foi convertido para um novo arquivo de pontos, possibilitando a extração das informações de cada pixel. Com isso, foi elaborada uma planilha no formato .xls denominada “planilha matriz”, na qual as variáveis foram alocadas em colunas e nas linhas foram alocadas os valores de cada variável em cada célula de 20X20m georreferenciada (Figura 5).




Figura 5 - Esquema de elaboração da planilha matriz

3.3.2 Classificação não-supervisionada (Fuzzy k-médias)

A partir dos dados da planilha matriz (com exceção da “superfície geomórfica”, pois foi gerada após a presente etapa) foi realizada uma análise de agrupamento Fuzzy k-médias (BEZDEK; EHRLICH; FULL, 1984). Nessa análise cada dado (informações do pixel) é reconhecido como pertencente em maior ou menor grau a todos os grupos criados (clusters). Esta técnica de classificação tem como característica não forçar o programador a definir regras rígidas com contatos normalmente artificiais que diminuem a habilidade de articular eficientemente soluções para problemas complexos, tão comuns em processos naturais (TANSCHKEIT, 2011).

O cálculo feito pelo algoritmo inicia-se a partir de valores pré-selecionados de número clusters, número de interações e valor do coeficiente Fuzzy. Este coeficiente pondera quanto o grau de pertinência influencia na métrica de distância empregada, sendo tal grau um indicativo da relação entre um objeto e um cluster. Para a escolha do número de clusters que melhor se ajustassem aos dados, foi aplicado o cálculo do algoritmo para 5 a 10 classes e avaliado o índice de desempenho dos agrupamentos (ID) (XIE; BENI, 1991). No processamento da técnica Fuzzy foi utilizado o pacote estatístico e1071 (DIMITRIADOU et al., 2008), implementado no programa R (R DEVELOPMENT CORE TEAM, 2008). O cálculo do ID foi realizado no pacote estatístico Tiger (REUSSER, 2008).

A aplicação do algoritmo, em função da planilha matriz, número de clusters, interações e valor do coeficiente Fuzzy com melhor desempenho, resultou em um arquivo de saída registrando o cluster classificado em cada pixel. Esse arquivo foi inserido em ambiente SIG dando origem ao “Mapa de classes por agrupamento das variáveis ambientais”. Observando a localização e distribuição dos clusters no mapa, foram escolhidas cinco áreas chaves capazes de representar a variabilidade dos clusters na área de estudo. Nesses locais, realizou-se o mapeamento dos solos com uso de metodologia convencional.

3.3.3 Mapeamento de solos pelo método convencional

Em incursão ao campo, foram coletadas amostras nas profundidades de 0-20 cm e 80-100 cm com o uso de trado holandês, totalizando 28 pontos amostrais. Estas foram secas em estufa a 50 °C por 48 horas e peneiradas; as frações menores que 2 mm foram utilizadas para análises laboratoriais. A análise granulométrica foi realizada a pelo método do densímetro (CAMARGO et al., 1986), tendo sido determinados os teores de areia total, silte e argila. Para as análises químicas, determinou-se o pH em água e KCl e os teores de Ca^{2+} , Mg^{2+} , K^+ , Na^+ , Al^{3+} , $\text{H}^+ + \text{Al}^{3+}$, P e matéria orgânica (MO) de acordo com Raij et al. (2001). Foram então calculadas a soma de bases (SB), capacidade de troca de cátions (CTC), saturação por bases (V%) e saturação por alumínio (m%). A cor da amostra úmida foi obtida utilizando-se um colorímetro Minolta CR - 300, com chip para cor Munsell (CAMPOS; DEMATTÊ; QUARTAROLI, 2003).

De acordo com os resultados das análises granulométricas e químicas dos pontos amostrais, juntamente com observações de campo, foram estabelecidas as unidades de mapeamento e as respectivas classes de solos. As informações de campo consistiram de observações morfológicas de perfis de solos e de amostras extras que não foram analisadas em laboratório. As unidades foram classificadas até o 3º nível categórico (EMBRAPA, 2006) mais informação de textura, obtendo-se assim os mapas de solos para as cinco áreas chaves, em nível semidetalhado.

3.3.4 Aplicação da técnica de RNA

O fluxograma apresentado na Figura 6 identifica as atividades realizadas na aplicação da técnica de RNA.

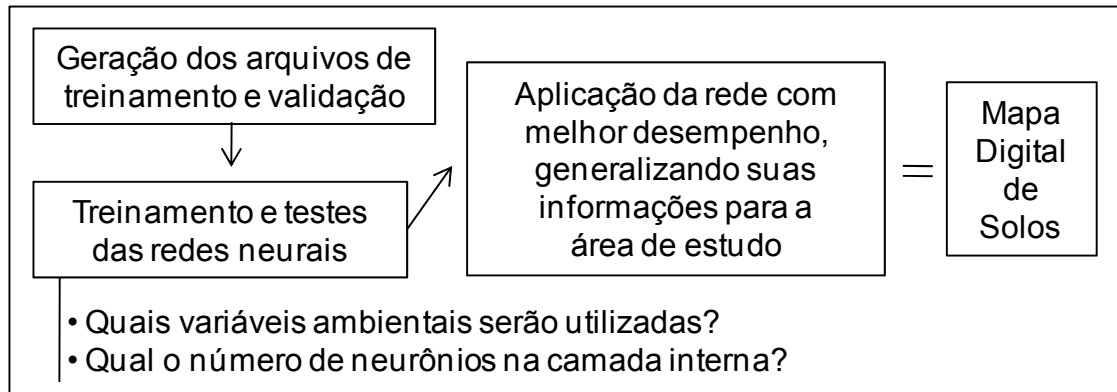


Figura 6 - Fluxograma das atividades na aplicação das RNA

A primeira etapa para a aplicação da técnica foi a elaboração de arquivos contendo: (i) os dados para o treinamento de cada arquitetura de rede neural e (ii) os dados para a validação de cada uma delas. O arquivo de treinamento permite que o algoritmo estabeleça, por aprendizagem, uma relação entre as variáveis ambientais utilizadas em cada rede e as unidades de mapeamento. Já o de validação testa essa relação por meios estatísticos. Anterior a esta etapa e de modo a facilitar o processo de treinamento das RNA, as informações de cada variável no formato *raster* foram reescaladas em um intervalo de 0 a 1. Com isso, evitou-se a saturação das redes neurais, uma vez que altos valores podem impedir a solução do problema; também foi prevenido que grandes variações de uma mesma variável pouco importante inibissem pequenas variações em outras variáveis (CHAGAS; CARVALHO JÚNIOR; BHERING, 2011).

Após o reescalonamento, foram extraídas, em ambiente SIG, as informações contidas nos pixels de cada unidade de mapeamento identificada nas áreas chaves, originando os arquivos de treinamento e de validação para cada conjunto de variáveis utilizado na camada de entrada das redes neurais. Tais arquivos foram gerados de forma independente. Quanto ao tamanho de cada um, procurou-se seguir as recomendações de Zhu (2000). O autor preconiza que para o treinamento o número de pixels coletados em cada unidade de mapeamento deve ser 30 vezes o número de unidades estabelecidas no estudo. No caso da validação,

o valor dos pixels é 50% do obtido para o treinamento. Após coleta, os arquivos gerados foram convertidos para serem inseridos no software “Java Neural Network Simulator” (JavaNNS), o qual é baseado no “Stuttgart Neural Network Simulator 4.2 Kernel” (ZELL et al., 1996).

Os conjuntos de entrada aplicados no presente estudo foram: Todas as Variáveis (TV), Todas exceto Declividade (TV-D), Todas exceto Elevação (TV-E), Todas exceto Geologia (TV-G), Todas exceto Índice de Convergência (TV-IC), Todas exceto Perfil de Curvatura (TV-PfC), Todas exceto Plano de curvatura (TV-PnC) e Todas exceto Superfície Geomórfica (TV-SG). Dessa forma pode-se avaliar a importância de cada variável na predição das unidades de mapeamento pela técnica aplicada.

Por meio de tentativa e erro o número de neurônios na única camada interna foi sendo alterado a cada treinamento (HIROSE; YAMASHITA; HIJIYA, 1991), sempre sendo avaliado o comportamento do erro quadrático médio (EQM) como critério para a continuação ou término dos treinamentos. O EQM mede a diferença entre os valores estimados e os valores desejados para o treinamento (Equação 3).

$$EQM = \frac{1}{n} \sum (e - d)^2 \quad (3)$$

em que:

e = valores estimados para cada pixel;

d = valores desejados.

O número de neurônios na camada de saída se manteve constante, sendo equivalente ao número de unidades de mapeamento identificadas nas áreas chaves. No treinamento das RNA aplicou-se o algoritmo de aprendizado *backpropagation* (VICENTE, 1999), com alocação aleatória dos pesos interneurônios entre -1,0 e 1,0 e taxa de aprendizado de 0,2. O número de ciclos de aprendizagem foi de 10 mil.

Na etapa de testes foram realizadas análises estatísticas em cada uma das arquiteturas de rede treinadas. O objetivo foi avaliar o conhecimento adquirido em cada rede. Para tanto, foram utilizados os dados dos arquivos de validação gerados. As análises consistiram da avaliação do índice Kappa de todas as redes,

obtidos a partir de uma matriz de confusão (CONGALTON; GREEN, 1999), e da análise de uma matriz de significância obtida pelos resultados de Kappa e variância das redes de melhor desempenho em cada conjunto. Por meio da aplicação do teste estatístico Z, foi possível analisar a ocorrência de diferença significativa entre os valores de Kappa. Com base nos resultados estatísticos foi feita a escolha da rede com melhor desempenho, para uso na geração do MDS1. O resultado da matriz de confusão obtida para a rede escolhida foi apresentado, podendo ser analisado seu potencial em classificar as unidades de mapeamento em função das variáveis ambientais.

Para a generalização das informações da rede neural optada, foram processados no software JavaNNS o arquivo referente a esta rede e um arquivo de imagem contendo as informações nos pixels dos arquivos *raster*. Nessa etapa, a rede, tendo sido treinada com as informações referentes às áreas chaves, é apresentada para todos os pixels da área de estudo, contendo cada um deles as informações das variáveis ambientais. Com isso, gera-se um arquivo de imagem final com a classificação de cada pixel de acordo com as relações entre as unidades de mapeamento e as variáveis ambientais estabelecidas pela rede. Essa imagem foi importada para o software ERDAS Imagine 9.2, após conversão para formato compatível com o programa, permitindo sua visualização e adequação de projeção cartográfica, resultando no MDS1.

3.3.5 Comparação e validação do mapa digital de solos

Foi gerada uma tabulação cruzada entre o MDS1 e um mapa de solos de escala 1:100.000 nível semidetalhado obtido por método convencional (ALMEIDA; OLIVEIRA; PRADO, 1982a; 1982b) (Anexo B). O propósito foi o de verificar a correspondência espacial existente entre as unidades identificadas no mapa digital com as unidades do mapa convencional. A comparação foi feita de três maneiras: considerando a classificação dos solos até o segundo nível categórico (i), até o terceiro nível categórico (ii) até o segundo nível categórico mais a informação de textura (iii). Como no mapa semidetalhado foi utilizada um sistema de classificação anterior à Embrapa (2006), foi feita a correspondência entre ambas.

De forma a validar o MDS1, foram coletadas amostras georreferenciadas nas profundidades de 0-20 cm e 80-100 cm em 22 pontos de

referência, totalizando 44 amostras, distribuídas aleatoriamente sobre a área de estudo. Realizou-se análise granulométrica de acordo com Camargo et al. (1986) e obtenção da cor do solo com uso de colorímetro Minolta CR - 300, com chip para cor Munsell (CAMPOS; DEMATTÊ; QUARTAROLI, 2003). Tais observações foram classificadas até o segundo nível categórico, de acordo com Embrapa (2006). Após inserção dessas informações em um banco de dados, fez-se uma verificação do tipo “verdadeiro-falso” entre cada ponto classificado (verdade de campo) e sua respectiva localização no MDS1. Os solos foram comparados até o segundo nível categórico mais a informação de textura.

3.4 Estratégia de mapeamento digital de solos 2

A Figura 7 apresenta um fluxograma com as atividades desenvolvidas na estratégia 2 para a obtenção do Mapa Digital de Solos 2 (MDS2).

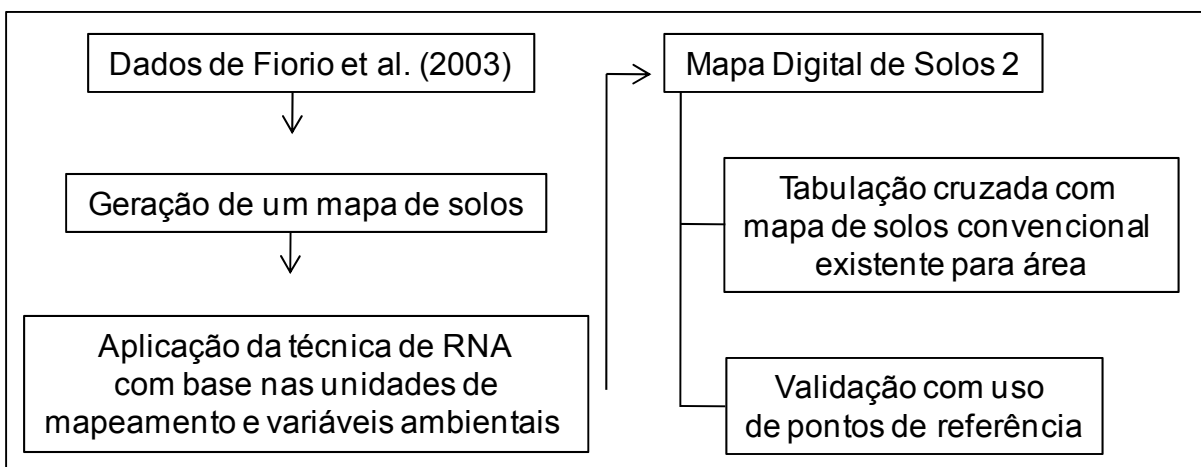


Figura 7 - Fluxograma para a estratégia 2

3.4.1 Obtenção das unidades de mapeamento

Nessa estratégia foram utilizados dados obtidos no trabalho de Fiorio et al. (2003), que consistiram de resultados de análises físicas e granulométricas de uma área chave de aproximadamente 501 ha. Esta se localiza aproximadamente no centro da região do presente estudo. Os autores utilizaram uma grade regular de 100 x 100 m demarcada no campo com distanciômetros (feixe de infravermelho), onde cada interseção da grade gerou um ponto de amostragem, perfazendo um total

de 473 pontos. Esses foram numerados, georreferenciados e amostrados com trado nas profundidades 0-20 cm e 80-100 cm, totalizando 946 amostras. Também foram realizadas avaliações de perfis para caracterização das unidades de mapeamento. Esses dados permitiram a classificação de cada ponto amostral de acordo com EMBRAPA (2006) e gerou um mapa de solos nível detalhado obtido com auxílio de uma grade de amostragem regular.

As informações das análises e das classes de solos estabelecidas pelos autores foram inseridas em um SIG (ArcMap 9.3) para que fosse gerado um novo mapa de solos na área chave. Dessa forma, foram obtidas unidades de mapeamento na forma de polígonos e não em células de 100x100 m com a classificação dos pontos amostrados. Como auxílio para a elaboração das unidades de mapeamento foram analisadas: as características do relevo por meio da visualização, em ambiente SIG, das curvas-de-nível e declividade do terreno; análise estereoscópica com uso de fotografias aéreas na escala de 1:30.000 para interpretação da relação solo-paisagem e delimitação dos limites entre as unidades.

Tendo como objetivo caracterizar as unidades de mapeamento estabelecidas, foram analisadas três topossequências na área chave. Para isso, foram selecionadas três sequências de pontos amostrais da grade regular que contemplasse todas as unidades presentes. Estas foram caracterizadas em função dos resultados das análises químicas e granulométricas, dos atributos do terreno derivados, geologia e superfícies geomórficas identificadas. Gráficos dos perfis topográficos, teores de argila, areia, Al^{3+} , SB e CTC foram gerados para cada topossequência como auxílio na caracterização dos solos da área.

3.4.2 Aplicação da técnica de RNA

Os procedimentos executados nessa etapa foram equivalentes aos realizados na Estratégia anterior, ou seja: obtenção dos arquivos de treinamento e validação para cada arquitetura de rede neural, extraíndo informações dos pixels de cada unidade mapeada na única área chave, com uso dos *rasters* reescalados; treinamento das redes neurais alterando o número de variáveis ambientais na camada de entrada (conjuntos) e o número de neurônios na camada interna; testes estatísticos para a escolha da melhor rede neural; generalização das informações da rede com melhor desempenho para obtenção do MDS2.

3.4.3 Comparação e validação do mapa digital de solos

Assim como na Estratégia 1, aplicou-se tabulações cruzadas entre o MDS2 obtido e o mapa de solos de escala 1:100.000 nível semidetalhado obtido por método convencional (ALMEIDA; OLIVEIRA; PRADO, 1982a; 1982b) (Anexo B), com o objetivo de comparação entre as unidades ocorrentes nos mapas. Os 22 pontos utilizados na validação da MDS1 também foram aplicados no MDS2, procedendo-se a mesma forma de avaliação.

4 RESULTADOS E DISCUSSÃO

4.1 Caracterização das variáveis ambientais utilizadas nas estratégias digitais.

A distribuição espacial dos atributos do terreno obtidos pela derivação do MDE e o mapa com as superfícies geomórficas são apresentados na Figura 8. Os valores de elevação da região tiveram variações de 515 a 754 m, com predomínio de maiores altitudes nas áreas a sudeste e menores a noroeste. Apesar de ter apresentado uma amplitude altimétrica de 239 m em toda a sua extensão, a maior parte da área (70%) situou-se entre 580 e 680 m, sendo que apenas 9% encontraram-se em posições mais elevadas que 700 m e 3% inferiores a 550 m.

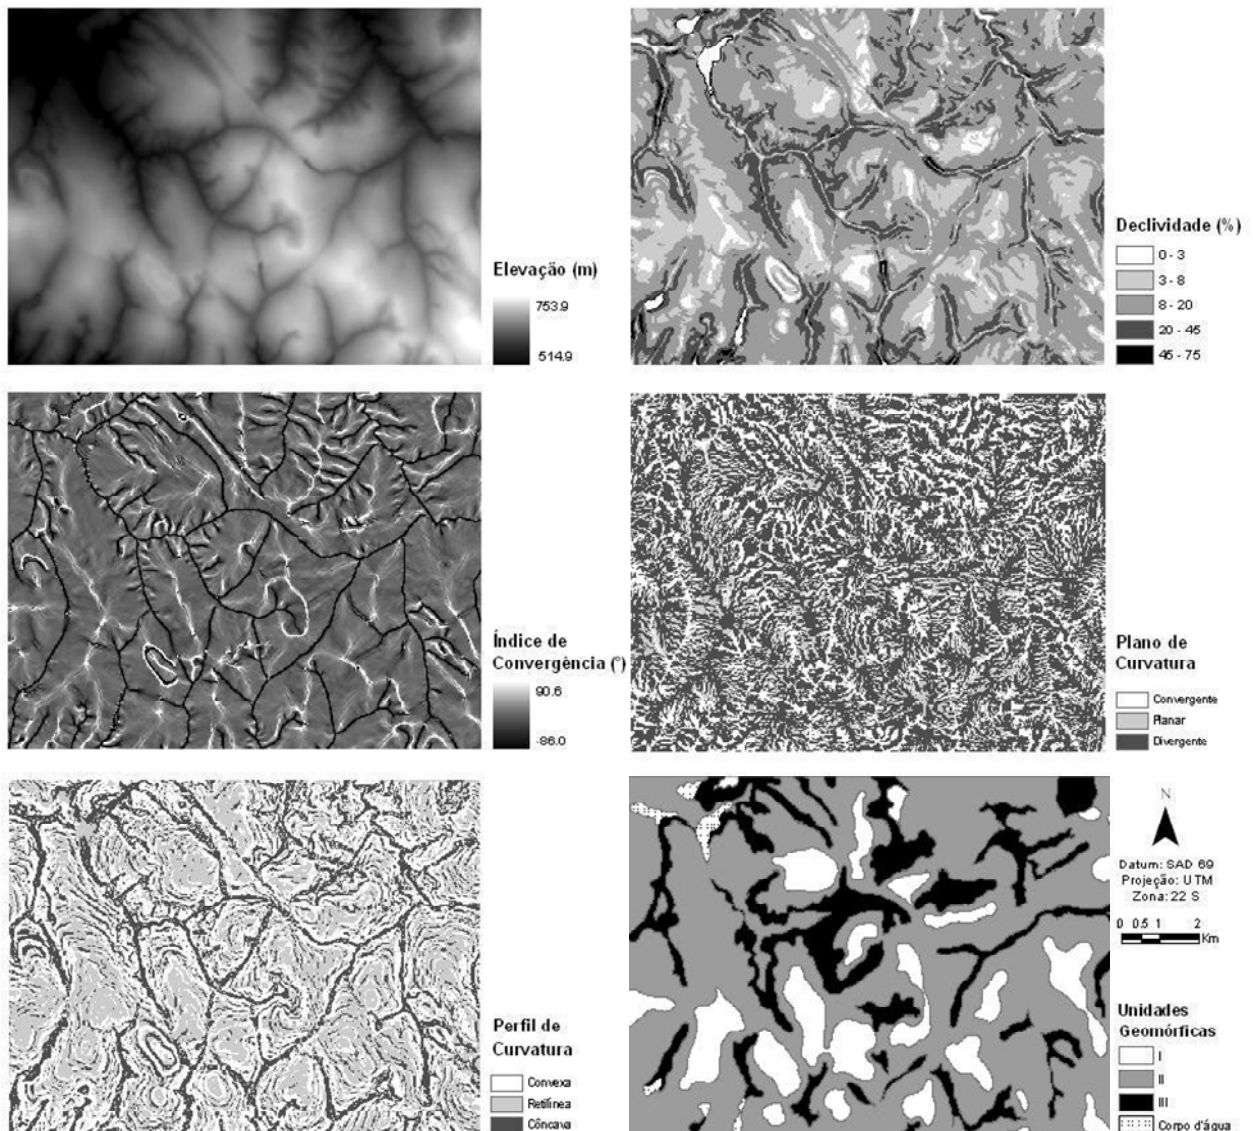


Figura 8 - Espacialização dos atributos do terreno e das superfícies geomórficas

A declividade, classificada de acordo com Embrapa (1999), e o perfil de curvatura, apresentaram um comportamento padrão quando analisadas suas alterações no sentido topo-talvegue das encostas. Nas áreas mais elevadas, predominou relevo plano (0 - 3%) e suave ondulado (3 - 8%) com perfil de curvatura retilíneo, gradando suavemente para vertentes de perfil retilíneo e ligeiramente convexo com declives variando de 3 a 20% (suave ondulado a ondulado) nos terço superior e médio. No terço inferior das encostas, ora ocorreu continuidade de declives menores que 20% até a drenagem, ora exibiu relevo forte ondulado e montanhoso (entre 20 e 75%) tendo predomínio de perfil de curvatura côncava.

O índice de convergência e o plano de curvatura permitiram a identificação dos locais que atuam como divisores de água e canais de córregos, onde predominam a dispersão e a concentração de água na paisagem, respectivamente. Exceto nesses dois locais da paisagem citados, o comportamento desses atributos em toda a região exibiu grande heterogeneidade quando comparados às outras variáveis ambientais. Este fato dificultou melhor caracterização dessas informações de acordo com a posição na paisagem.

A interpretação das variações no relevo permitiu a identificação de três superfícies geomórficas. Uma vez que não foram realizadas incursões ao campo para a delimitação das superfícies geomórficas, estas foram consideradas como informações aproximadas, não perdendo, com isso, sua importância para utilização nas estratégias digitais. Isto porque foi constatada, em posterior atividade de campo (análise visual), coerência entre o resultado obtido e as diferentes feições do relevo.

A superfície geomórfica I, pela sua posição a montante das outras duas, representou a superfície mais antiga. Ocorreu em áreas mais elevadas e de interflúvios, com topografia mais aplainada, declividades inferiores a 8%, plano de curvatura planar/divergente e perfil retilíneo/convexo. Os limites entre as superfícies I e II ocorreram em locais de transição da inclinação do terreno, passando de uma menor para outra maior. A superfície geomórfica II cortou a primeira no sentido desta para a jusante, logo, foi considerada como de idade mais recente. Esta caracterizou-se por apresentar relevo suave ondulado e ondulado e perfil de curvatura convexo/retilíneo. A superfície geomórfica III foi a que apresentou maior inclinação, com predominância de declividades maiores que 20%, ocupando as posições inferiores das vertentes. Ocorreu abaixo da superfície II, sendo fácil a distinção entre as duas devido à notável quebra de relevo. Dessa forma, foi a superfície

considerada com idade mais jovem da região. Apresentou no geral, perfil de curvatura côncavo e plano de curvatura convergente.

As conclusões a respeito das origens de três segmentos geomorfológicos presentes em Coelho; Lepsch e Menk (1994) podem aqui ser aplicadas, pelo fato do estudo ter sido realizado em local próximo ao do presente trabalho e em condições estratigráficas e de relevo similares. Dessa forma a primeira superfície geomórfica provavelmente foi formada por processos deposicionais eólicos ou pedimentares, sendo a segunda superfície um pedimento que depois pode ter sido retrabalhado por coluvionamento. A última superfície identificada caracterizou-se como sendo de origem erosional com uma pequena faixa deposicional.

Portanto, após a identificação e mapeamento das superfícies geomórficas encontradas na área de estudo, foi possível estabelecer uma relação entre cada superfície e a idade relativa dos solos que nelas ocorrem (COELHO; LEPSCH; MENK, 1994; LEPSCH; BUOL; DANIELS, 1977; MARQUES JÚNIOR; LEPSCH, 2000; CUNHA et al., 2005). Sendo assim, os solos das superfícies geomórfica I, II e III são respectivamente os mais velhos, de idade intermediária e o mais recentes. Com isso, a utilização da variável ambiental “superfície geomórfica” nas estratégias de mapeamento digital carrega consigo a informação do fator de formação “tempo”.

4.2 Estratégia de mapeamento digital de solos 1

4.2.1 Classificação não supervisionada (Fuzzy k-médias)

Com o objetivo de se optar por um número ótimo de clusters, foi avaliado o índice de desempenho dos agrupamentos gerado pela aplicação da técnica estatística Fuzzy k-médias. Para os resultados desse índice, quanto mais próximo ao zero melhor a divisão em clusters realizada pelo algoritmo (XIE; BENI, 1991). O resultado obtido com o uso de 5 a 10 cluster é apresentado na Figura 9.

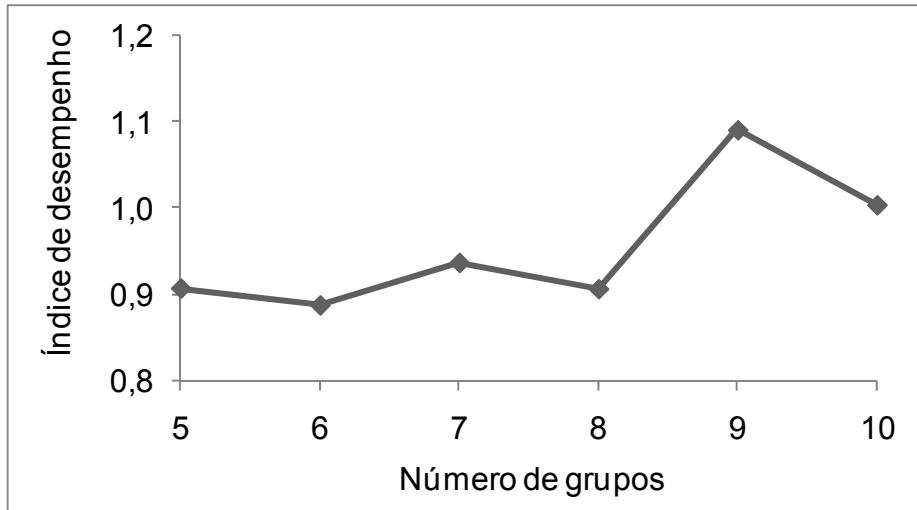


Figura 9 - Índice de desempenho de agrupamento

O agrupamento em 6 clusters apresentou o melhor índice de desempenho (0,88), seguidos da divisão dos dados em 5 (0,91), 8 (0,91) e 7 (0,94) clusters. Com o objetivo de discriminar solos na paisagem por espectrometria de reflectância, Rizzo (2011) agrupou dados das componentes principais de espectros de solos utilizando a mesma técnica. O autor testou treze agrupamentos, obtendo para o índice de desempenho três valores abaixo de 0,40 (3, 4 e 7 clusters) e outros nove entre 0,80 e 1,10. Apesar de o melhor índice obtido ter sido com 3 clusters, o autor optou pelo agrupamento dos dados em 7, devido esse valor indicar um maior número de classes de solos, permitindo melhor representação da variabilidade destes na área de estudo.

Como o objetivo da aplicação da análise Fuzzy no presente estudo relaciona-se à escolha de áreas a serem mapeadas convencionalmente, sem ter conhecimento prévio da área, foi optado pelo agrupamento que apresentou melhor desempenho (6 clusters). O resultado final da aplicação da técnica de classificação não supervisionada pode ser constatado no “Mapa de classes por agrupamento das variáveis ambientais” (Figura 10).

Esta etapa possibilitou a escolha do melhor número de clusters sem necessidade de visita prévia à área de estudo por parte do pesquisador/especialista. Tal fato representa uma grande vantagem da técnica aplicada, já que é obtida uma única informação calculada em função de outras diversas que estão relacionadas aos processos e fatores formadores dos solos. Isto facilita não só a interpretação

pele usuário, mas também sua rotina, uma vez que inferências podem ser feitas em apenas uma análise.




Figura 10 - Mapa de classes por agrupamento das variáveis ambientais e localização das cinco áreas chaves

Analisando a localização dos clusters na região e considerando a geologia e as características do relevo ocorrentes em cada um deles, foi possível subdividi-los, para fins de caracterização, em quatro grupos: (i) clusters 2 e 4, com ocorrência nas áreas de maiores elevações, topo e meia encosta com declives mais suaves e tendo como litologia os arenitos da Formação Itaqueri; (ii) cluster 1, de topografia semelhante ao primeiro grupo, aparecendo também em relevo mais acidentado, porém, ocorrendo em regiões de basaltos da Formação Serra Geral; (iii) clusters 3 e 6, localizados principalmente nos terços finais das encostas próximos ao talvegue dos rios, de relevo forte ondulado a montanhoso, com litologia basáltica; e (iiii) cluster 5, que é representado pelos canais de drenagem.

Considerando as características distintas de cada cluster, foram selecionadas cinco áreas chaves dentro da área de estudo para realização de mapeamento de solos pelo método convencional. Dessa forma, foram identificadas

as unidades de mapeamento representativas da região. A localização de cada área chave pode ser observada na Figura 10. A menor área chave apresentou um total de 170 ha e a maior 450 ha, totalizando cerca de 1.370 ha as cinco áreas (12% da área total).

4.2.2 Mapa de solos convencional e caracterização das unidades de mapeamento

Foram encontradas nove unidades de mapeamento nas cinco áreas chaves, sendo: LATOSSOLO VERMELHO Distrófico textura média (LVd3), LATOSSOLO VERMELHO Eutrófico textura média (LVe3), LATOSSOLO VERMELHO Eutrófico textura argilosa (LVe2), LATOSSOLO VERMELHO Eutróférico textura muito argilosa (LVef1), NITOSSOLO VERMELHO Eutróférico textura muito argilosa (NVe1), ARGISSOLO VERMELHO Eutrófico textura média/muito argilosa (PVe3/1), ARGISSOLO VERMELHO Eutrófico textura média (PVe3/3), CAMBISSOLO HÁPLICO Tb Eutrófico textura muito argilosa (CXbe1) e CAMBISSOLO HÁPLICO Ta Eutrófico textura argilosa (CXve2) (Figura 11). Amostras de solos representativas de cada unidade são apresentadas na Tabela 1.

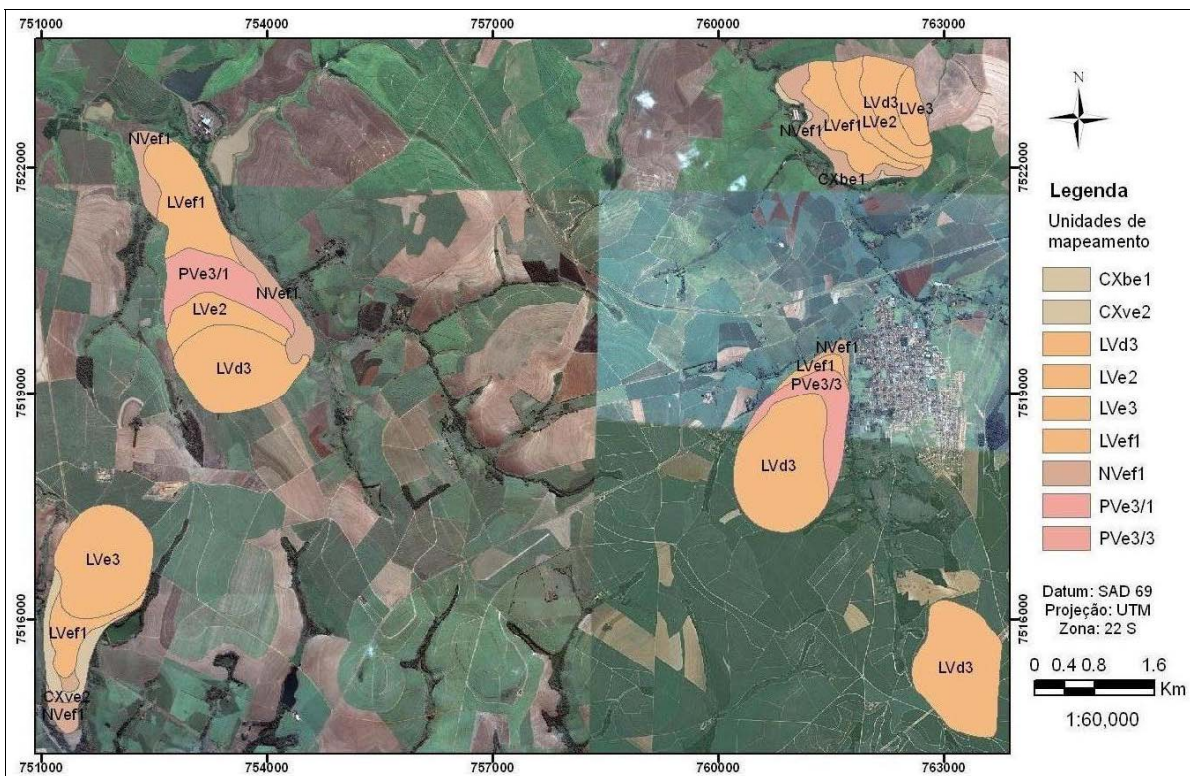


Figura 11 - Mapa de solos convencional para a estratégia 1

Tabela 1 - Amostras de solos representativas das unidades de mapeamento

Ponto	Prof. (cm)	Solo	Areia Total	Silte	Argila	pH		MO (g.Kg)	P (ppm)	K	Na	Ca	Mg	Al	H+Al	SB	CTC	V	m	Matiz (YR)	Valor	Croma	Gradiente	Silte/Argila
						H2O	KCl																	
				g.kg ⁻¹																				
1A	0-20	CXbe1	208,7	249,0	542,4	5,9	5,3	26,4	37	2,4	0,4	46,7	31,7	0,4	9,2	81,1	90,3	89,8	0,49	2,7	3,3	1,7		
1C	40-60		143,6	223,7	632,7	6,1	5,5	11,5	43	0,2	0,2	30,7	9,1	0,4	12,0	40,2	52,2	77,0	0,99	2,5	3,3	2,1	1,17	0,35
36A	0-20	CXve2	316,1	272,4	411,5	5,6	4,5	20,9	40	1,5	0,2	52,1	18,1	1,2	34,4	72,0	106,4	67,7	1,64	3,7	3,4	1,7		
36C	50-70		318,0	303,8	378,2	5,6	4,6	19,3	34	0,8	0,4	71,4	18,1	0,4	28,0	90,7	118,7	76,4	0,44	4,4	3,5	2,1	0,92	0,80
19A	0-20	LVd3	851,7	9,8	138,5	5,2	4,2	11,5	36,3	0,6	0,1	6,6	2,7	3,4	15,0	10,0	25,0	40,1	25,3	4,6	3,3	1,7		
19C	80-100		801,7	3,3	195,0	5,0	4,1	6,8	25,6	0,1	0,0	3,8	1,8	5,6	13,4	5,8	19,2	30,1	49,2	3,2	3,6	2,6	1,41	0,02
10A	0-20	LVef1	206,2	191,9	601,9	6,2	5,3	16,7	47	0,8	0,2	32,4	22,6	0,4	13,6	56,1	69,7	80,5	0,71	2,4	3,3	1,8		
10C	80-100		159,2	152,0	688,8	6,2	5,1	11,0	45	0,3	0,1	26,3	8,1	0,6	13,0	34,9	47,9	72,8	1,69	2,3	3,4	1,8	1,14	0,22
27A	0-20	LVe2	655,4	40,3	304,3	6,2	6,3	11,5	55	1,2	0,2	44,5	2,7	0,0	11,4	48,6	59,9	80,9	0,00	2,7	3,2	1,6		
27C	80-100		622,5	9,1	368,4	6,5	6,1	5,7	32	0,4	0,1	25,3	2,7	0,4	8,6	28,5	37,1	76,8	1,38	1,6	3,3	1,9	1,21	0,02
31A	0-20	LVe3	773,9	12,1	214,0	6,4	5,3	8,9	39	3,0	0,1	10,4	5,4	0,4	4,4	19,0	23,4	81,2	2,07	3,1	3,5	2,3		
31C	80-100		709,6	25,3	265,2	5,6	4,3	6,8	27	0,4	0,0	7,7	3,6	4,4	9,0	11,7	20,7	56,5	27,35	2,8	3,5	2,3	1,24	0,10
13A	0-20	Nvef1	134,7	199,3	666,0	5,8	4,9	24,0	54	0,9	0,2	45,0	22,6	0,9	29,0	68,7	97,7	70,3	1,29	1,9	3,3	1,7		
13C	80-100		85,9	147,2	766,9	5,5	4,3	13,6	66	0,3	0,1	28,5	8,1	6,3	28,0	37,1	65,1	57,0	14,51	1,9	3,3	1,8	1,15	0,19
28A	0-20	PVe3/1	670,0	76,7	253,3	6,4	5,7	15,7	42	1,8	0,1	22,5	13,6	0,0	5,0	38,0	43,0	88,4	0,00	3,3	3,2	1,5		
28C	80-100		287,6	85,5	626,9	6,4	5,7	9,4	28	0,4	0,2	32,4	10,9	0,3	2,0	43,8	45,8	95,6	0,68	2,3	3,4	1,7	2,48	0,14
20A	0-20	PVe3/3	824,0	11,9	164,1	5,2	4,3	5,7	27,7	0,3	0,1	7,1	2,7	1,8	10,2	10,3	20,5	50,2	14,9	3,0	3,3	1,8		
20C	80-100		681,6	21,2	297,2	5,6	4,8	6,3	26,8	0,2	0,1	12,6	2,7	0,4	5,4	15,6	21,0	74,3	2,5	2,2	3,3	2,0	1,81	0,07

De acordo com a posição no relevo e material de origem, notou-se uma tendência de ocorrência de determinadas classes de solos nas áreas mapeadas. Nas posições mais elevadas e em relevo plano e suave ondulado, houve o predomínio do arenito como material de origem, ocorrendo os Latossolos Vermelhos de textura média. Por estarem localizados na superfície geomórfica I foram considerados os solos mais antigos da paisagem. No entanto, também foram mapeados na superfície II. Os teores de argila variaram de 195 à 265 g.kg⁻¹ de solo em subsuperfície. Apesar de algumas unidades com caráter eutrófico terem sido mapeadas, predominou o caráter distrófico nesses Latossolos, com valores de CTC entre 19,2 e 20,7 mmol_c.kg⁻¹ de solo e SB de 5,8 a 11,7 mmol_c.kg⁻¹, evidenciando o intenso intemperismo e lixiviação a que esses solos foram submetidos nessas posições do relevo.

A transição dos Latossolos de textura média foi feita, no sentido encosta abaixo, para unidades de mapeamento localizadas na superfície geomórfica II, apresentando acréscimos mais ou menos significativos nos teores de argila nos horizontes subsuperficiais. Dessa forma, em posições intermediárias das vertentes ocorreram as unidades de mapeamento PVe3/3, LVe2, PVe3/1 e LVe1. Tais acréscimos puderam ser observados nas encostas de áreas chaves que apresentaram Latossolos de textura argilosa transitando para solos da mesma classe, porém de textura muito argilosa. Em encostas onde ocorreram Argissolos vertendo para Latossolos também foi possível constatar o aumento dos teores de argila em subsuperfície. Uma provável causa para a ocorrência do gradiente textural encontrado nos Argissolos está relacionada com a sua posição na paisagem. Esta, favoreceu o acúmulo de material mais grosseiro em superfície, proveniente da erosão de áreas areníticas em posições mais alta (coluvionamento). Devido o incremento de argila em subsuperfície proveniente do intemperismo do basalto, nas condições mencionadas, originou-se o gradiente textural encontrado em algumas posições da paisagem.

A diferença das características químicas e granulométricas das quatro unidades identificadas nas posições intermediárias das encostas se fez, entre outros fatores, pela contribuição do basalto a jusante e do arenito a montante na paisagem. A influência do basalto na formação desses solos no sentido topo-talvegue foi constatada pelo aumento nos teores de argila já mencionado, e pelo aumento nos teores de cátions básicos, apresentando valores de soma de bases que vão de 28,5

$\text{mmol}_c.\text{kg}^{-1}$ (LVe2) até $43,8 \text{ mmol}_c.\text{kg}^{-1}$ (PVe3/1), e valores de CTC de 37,1 à 47,9 $\text{mmol}_c.\text{kg}^{-1}$ na transição do mesmo Latossolo de textura argilosa para um Latossolo muito argiloso (dados de subsuperfície) (Tabela 1).

No terço final das encostas, localizados na superfície geomórfica III e considerados os solos mais jovens da região, ocorreram os NVe1, CXbe1 e CXve2, sendo desenvolvidos dos produtos da alteração dos basaltos com menor contribuição do arenito. A presença desses solos argilosos e muito argilosos (teores entre 378 e 766 $\text{g}.\text{kg}^{-1}$ de solo), subjacentes ao material de origem basáltico, confirmou o potencial desse material no fornecimento de quantidades significativas de argila como produto do intemperismo. Por sua vez, a dissecação da paisagem com consequente exposição de intrusões da rocha máfica e formação dos solos nessas condições, refletiu no caráter eutrófico desses solos devido o predomínio de minerais ferromagnesianos (valores para saturação de bases de 57% a 77% e soma de bases entre 37,1 e 90,7 $\text{mmol}_c.\text{kg}^{-1}$). As condições de relevo mais íngreme ocorrentes no terço final das encostas fez com que a morfogênese predominasse sobre a pedogênese em alguns locais, sendo mapeadas inclusões de Neossolos Litólicos nas unidades de mapeamento CXbe1 e CXve2.

De maneira geral, as áreas-chaves apresentaram um comportamento similar quanto a ocorrência de classes de solos e de suas propriedades químicas e granulométricas no sentido da superfície geomórfica mais antiga para a mais jovem. Em uma sequência litoestratigráfica arenito-basalto localizada em área próxima a do presente estudo, Coelho; Lepsch e Menk (1994), discutindo relações solo-relevo com ênfase no material de origem, identificaram três superfícies geomórficas com características muito próximas às aqui estabelecidas. No trabalho foram mapeadas, desde a porção superior da transeção estudada até sua parte inferior, as seguintes classes de solos: Latossolo Vermelho-Escuro e Podzólico Vermelho-Escuro latossólicos, ambos em posição de topo quase plano e de textura média, demonstrando maior influência do material arenítico na composição desses solos. Na posição de meia encosta, foram identificados Podzólico Vermelho-Escuro textura arenosa/média, Latossolo Vermelho-Escuro de textura argilosa e Latossolo Roxo de textura argilosa. Já na posição sopé e terço inferior próximo à drenagem, os solos ocorrentes foram: Latossolo Roxo e Terra Roxa Estruturada, com maior influência do basalto. Os autores concluíram que a distribuição das classes de solo ao longo da transeção foi determinada por uma associação de fatores ligados à posição

topográfica e ao material de origem; e que a maior ou a menor contribuição dos materiais de origem arenito e basalto na formação dos solos, ficou expressa na química, mineralogia e granulometria destes.

Cunha et al. (2005) observaram variações similares às do presente estudo para os atributos químicos e granulométricos em solos de uma sequência arenítico-basáltica na região de Jaboticabal, SP. Das três superfícies geomórficas identificadas, a primeira, localizada na parte mais elevada e de menor inclinação, exibiu os menores valores de CTC do solo e de teores de argila, quando comparadas às outras duas superfícies à sua jusante. Nas superfícies II e III, ocorreram solos eutróficos que, de acordo com os autores, confirmaram a influência do basalto rico em feldspato calco-sódico e piroxênio e, ou, o menor tempo de lixiviação de bases, uma vez que aí se encontram os solos mais jovens.

De acordo com os resultados discutidos anteriormente, as modificações das propriedades químicas e granulométricas dos solos seguiu um padrão nas regiões estudadas em virtude da contribuição material de origem e da respectiva posição na paisagem. Partindo-se do pressuposto de que esses padrões possam ser reconhecidos em áreas adjacentes, onde não foram realizados levantamentos pedológicos, acredita-se que a extrapolação de uma informação local para a região como um todo, na tentativa de mapear os solos por técnicas de classificação supervisionada, possa gerar um resultado satisfatório. O fato dos resultados obtidos por Coelho et al. (1994) e do presente estudo serem muito similares, tanto nas características do relevo e geologia quanto nas unidades de mapeamento identificadas, e por estes dois trabalhos estarem em regiões muito próximas, ratifica a premissa de extrapolação estabelecida.

4.2.3 Avaliação das redes neurais artificiais

O desempenho do índice Kappa obtido nos testes das redes neurais (Figura 12) permitiu avaliar o conhecimento de cada rede quanto à predição das unidades de mapeamento em função das variáveis ambientais. Em todos os conjuntos testados, os resultados variaram em razão do número de neurônios na camada interna. O melhor resultado para o índice (0,745) foi obtido no conjunto TV com 11 neurônios na camada interna, seguidos dos conjuntos TV-PnC (0,733) com o mesmo número de neurônios internos e TV-IC (0,703) com 7 neurônios. Os piores

desempenhos encontrados ocorreram quando as variáveis declividade, superfície geomórfica e elevação foram excluídas do conjunto de entrada. Nestes casos, os maiores valores do índice Kappa foram de apenas 0,633, 0,629 e 0,516, respectivamente, com 11, 3 e 15 neurônios internos.

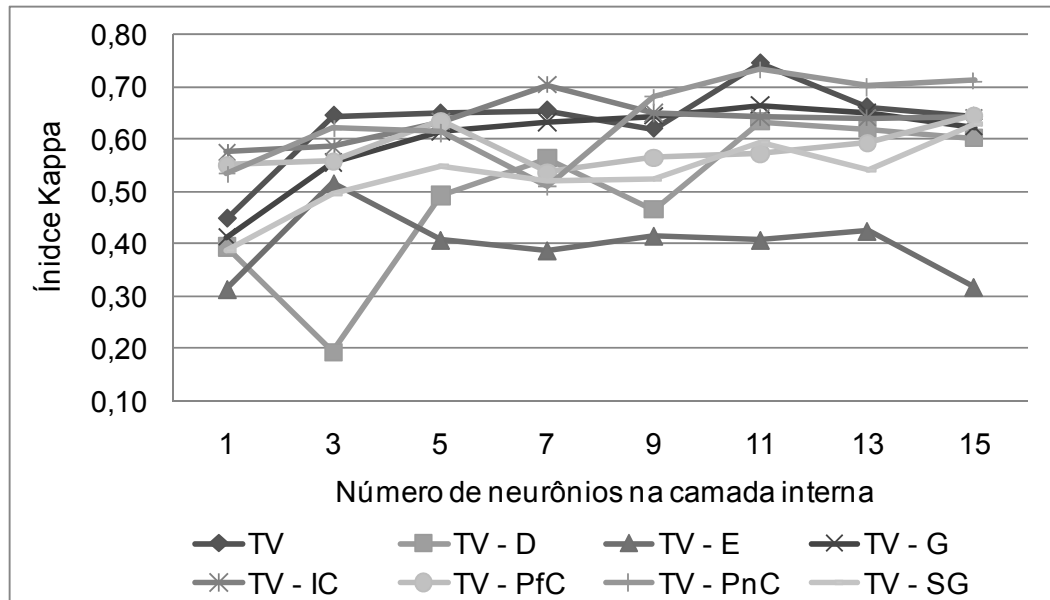


Figura 12 - Valores do índice Kappa das arquiteturas testadas (TV - todas as variáveis; D - declividade; E - elevação; G - geologia; IC - índice de convergência; PfC - perfil de curvatura; PnC - plano de curvatura; SG - superfície geomórfica)

Com os resultados do índice Kappa e variância das arquiteturas de rede com melhor desempenho em cada conjunto, foi calculada uma matriz de significância de Kappa (Tabela 2). Assim, foi possível comparar os diferentes resultados e optar pela rede neural a ser utilizada na geração do mapa digital de solos. Os conjuntos TV, TV-IC e TV-PnC com 11, 7 e 11 neurônios na camada interna, respectivamente, não apresentaram diferenças significativas, demonstrando que apesar da exclusão do índice de convergência ou plano de curvatura na camada da entrada, um bom desempenho foi mantido. O comportamento heterogêneo dessas duas variáveis na região de estudo, mencionado quando discutidos os dados da Figura 8, corrobora com seus baixos desempenhos nos testes das RNA. Portanto, estes dois atributos tiveram menor importância na distinção entre as classes de solos para os dados em questão.

Chagas et al. (2010) constataram que o plano de curvatura exibiu pouca diferenciação entre as classes, mas que, mesmo assim, foi muito importante na separação de três classes de solos das demais. No mesmo estudo os autores

obtiveram os melhores desempenhos para Kappa quando utilizado o conjunto com todas as variáveis (cinco atributos do terreno e três índices derivados de uma imagem Landsat7).

Tabela 2 - Matriz de significância de Kappa

Conjunto	TV (11) ^a	TV - D (11)	TV - E (3)	TV - G (11)	TV - IC (7)	TV - PfC (15)	TV - PnC (11)	TV - SG (15)
Exatidão global	77,5	67,5	57,7	70,4	73,8	68,8	76,5	67,3
Kappa	0,745	0,633	0,516	0,665	0,703	0,645	0,733	0,629
Variância ^b	0,240	0,289	0,326	0,289	0,262	0,289	0,250	0,291
TV	48,09							
TV - D	4,87*	37,24						
TV - E	9,62*	4,71*	28,58					
TV - G	3,47*	1,33	6,00*	39,12				
TV - IC	1,88	2,98*	7,71*	1,62	43,43			
TV - PfC	4,34*	0,50	5,20*	0,83	2,47*	37,94		
TV - PnC	0,54	4,30*	9,04*	2,92*	1,33	3,79*	46,36	
TV - SG	5,03*	0,17	4,54*	1,50	3,14*	0,66	4,47*	36,87

* existe diferença significativa ao nível de 95%; ^a número de neurônios na camada interna; ^b valores multiplicados por 1000; TV - todas as variáveis; D - declividade; E - elevação; G - geologia; IC - índice de convergência; PfC - perfil de curvatura; PnC - plano de curvatura; SG - superfície geomórfica.

Por apresentarem comportamento mais distinto entre as classes de solos (Figura 13) a declividade e elevação foram os atributos do terreno que melhor contribuíram para a melhoria do desempenho na fase de testes, concordando com Chagas et al. (2010). Os baixos valores de índice Kappa obtidos nos conjuntos TV-D e TV-E (Figura 12) ratifica a importâncias dessas informações na predição de solos por técnicas supervisionadas. Gallant e Wilson (2000) destacaram a forte influência que esses atributos tem sobre os processos pedogenéticos e, conseqüentemente, sobre a distribuição dos solos na paisagem. Rizzo (2011), caracterizando solos de acordo com a elevação e a declividade constatou que tais atributos podem ser utilizados como indicativo da variação espacial de classes de solos. Souza Júnior (2008) caracterizou unidades de mapeamento de solos desenvolvidos de basalto e arenito em função da declividade e altitudes correspondentes, baseados em modelo digital de elevação. O autor concluiu que o comportamento dos solos com a declividade foi variável, podendo ocorrer um mesmo solo em diferentes declives, mas que existe uma predominância de ocorrência de cada solo em uma faixa

específica de declividade. As mesmas considerações foram estabelecidas para o atributo elevação.




Figura 13 - Valores médios dos atributos do terreno entre as unidades de mapeamento

A inclusão da variável superfície geomórfica demonstrou contribuir para a discriminação dos solos. De maneira geral, o conjunto TV-SG exibiu valores de Kappa inferiores aos outros conjuntos (Figura 12), exceto em TV-E e TV-D. Com isso, a compartimentação da paisagem pode ser mais uma dentre as variáveis utilizadas no mapeamento digital de solos, sendo comprovada sua importância de acordo com os dados apresentados, exibindo inclusive melhores desempenhos que outras variáveis comumente aplicadas em técnicas digitais de classificação de solos. Ressalta-se que com o uso das superfícies geomórficas, mais um fator de formação é inserido no modelo de predição de classes de solos: o tempo (Cunha et al., 2005).

O índice de convergência e plano de curvatura apresentaram valores médios das amostras de treinamento muito próximos (Figura 13), assim como o perfil de curvatura. Em consequência disto, demonstraram ter menor importância na separação entre as classes, o que foi ratificado pela não diferenciação estatística encontrada entre os grupos TV, TV-IC e TV-PnC. No entanto, os três atributos foram muito importante para a separação dos CXbe1 e CXve2 das demais unidades. Os Cambissolos ocorreram em áreas da paisagem com encostas de perfil côncavo e de plano de curvatura convergente, acarretando em solos mais rasos e menos evoluídos, onde o maior fluxo convergente da água favoreceu a morfogênese em

relação à pedogênese. Por outro lado, nas demais unidades de mapeamento, os valores médios desses atributos demonstraram que tais unidades ocorreram predominantemente em encostas com perfil de curvatura convexo e retilíneo, plano de curvatura divergente e planar, com maior tendência divergente para o fluxo de água, dando origem a solos mais profundos e evoluídos.

Como não houve diferença estatística entre os desempenhos dos três melhores conjuntos na etapa de testes das redes, optou-se por aquela que apresentou maior valor absoluto para Kappa. Neste caso, foi selecionado o conjunto com todas as variáveis ambientais. Foram utilizados onze neurônios na camada interna. Esse foi o número com melhor desempenho na matriz de significância de Kappa obtida no conjunto TV (Anexo C). Sendo assim, o termo TV/11 (todas as variáveis na camada de entrada/onze neurônios na camada interna) foi criado para expressar a rede neural aplicada na geração do MDS1.

A matriz de confusão (Tabela 3) gerada pela aplicação da TV/11 no arquivo de validação avaliou a capacidade dessa rede neural em discriminar as classes de solos em função das variáveis ambientais. Ou seja, o aprendizado obtido pela rede na etapa de treinamento pode ser avaliado por meio da concordância entre o que ela classifica e o que ocorre na realidade.

Tabela 3 - Matriz de confusão obtida pelo uso da TV/11

Unidade	CXbe1	CXve2	LVd3	LVEf1	LVE2	LVE3	NVEf1	PVE3/1	PVE3/3	Total	Exatidão do usuário	Z
CXbe1	42	1	0	2	0	1	0	0	0	46	91,3	20,64
CXve2	4	76	1	3	0	0	1	0	0	85	89,4	24,37
LVd3	0	0	83	2	0	5	1	0	3	94	88,2	22,22
LVEf1	3	3	0	29	0	0	0	3	0	38	76,3	9,28
LVE2	0	0	2	26	51	2	1	2	0	84	60,7	10,27
LVE3	0	0	32	0	0	109	0	0	0	141	77,3	18,95
NVEf1	3	0	0	0	0	0	101	0	0	104	97,1	52,19
PVE3/1	0	1	0	47	0	0	0	130	1	179	72,6	18,42
PVE3/3	2	0	17	9	22	1	3	0	85	139	61,2	13,25
Total	54	81	135	118	73	118	107	135	89	910		
Exatidão do produtor	77,8	93,8	60,7	24,6	69,9	92,4	94,4	96,3	95,5			
Exatidão global = 77,5; Kappa = 0,745; Variância = 0,000240; Z calculado = 48,13; Z tabelado = 1,96												

Nas unidades de mapeamento CXve2, LVE3, NVEf1, PVE3/1 e PVE3/3 as concordâncias, representadas pela exatidão do produtor, foram acima de 90%. Isto significa que menos de 10% dos pixels classificados com essas unidades, na validação da rede, não foram classificados corretamente. As unidades CXbe1 e

LVe2 apresentaram concordâncias de 77,8% e 69,9%, respectivamente. Esta unidade de Latossolo foi confundida em 22 dos 73 pixels com a unidade PVe3/3. Este erro coincidiu com a dificuldade de distinção no campo entre os Argissolos e Latossolos. Os valores médios das variáveis ambientais obtidas para essas duas unidades confirmam tal dificuldade (Figura 14), uma vez que, dos atributos do terreno, apenas a elevação mostrou alguma diferença, ainda assim pequena. A informação geológica foi fundamental na distinção entre esses solos, sendo que a unidade LVe2 foi identificada em áreas basálticas e o PVe3/3 em área de transição dessa rocha para o arenito Itaqueri.

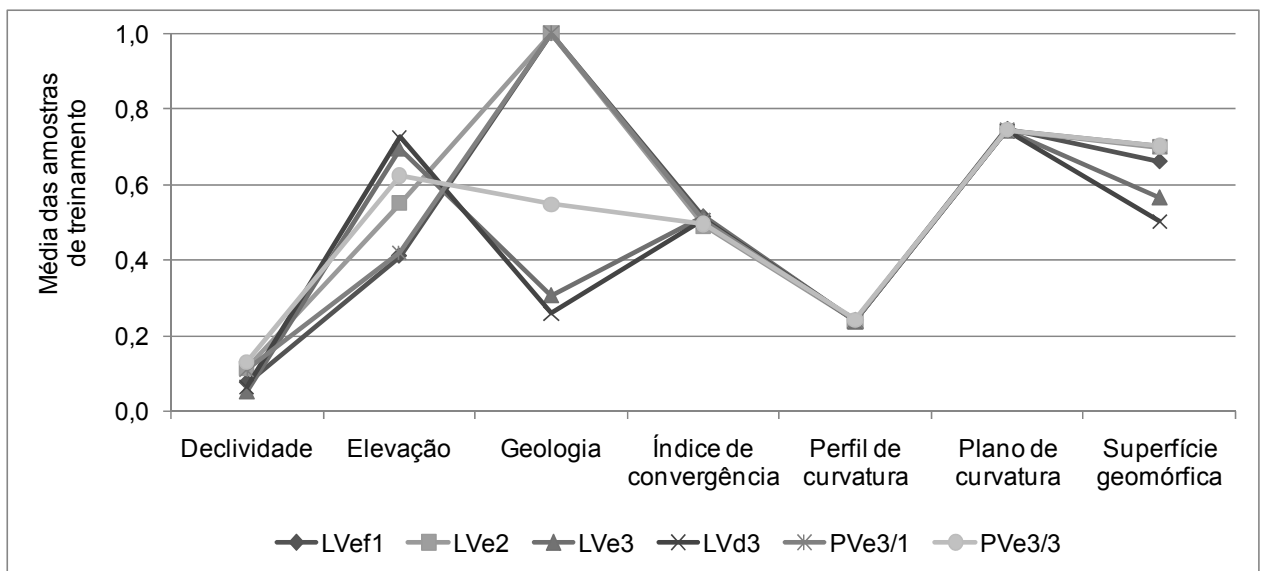


Figura 14 - Comportamento das variáveis ambientais para algumas classes de solos

A classe LVd3 apresentou 60,7% de concordância, classificando erroneamente 32 pixels como LVe3 e 17 pixels como PVe3/3. Os Latossolos de textura média com caráter eutrófico apresentaram valores de saturação de bases próximos do limite que os classificariam como sendo solos distróficos. Assim, a rede neural teve dificuldade em distinguir as duas unidades de Latossolos que apresentaram pequenas diferenças no comportamento de seus atributos químicos. Outro fator que justifica os pixels erroneamente classificados em questão, relaciona-se à semelhança encontrada nos valores médios das variáveis ambientais para essas três unidades. Apenas nas variáveis elevação, geologia e superfície geomórfica foram notadas diferenças. Mesmo sendo duas unidades de solos que tem como principal material de origem o arenito, a maior média obtida para a

variável geologia na unidade LVe3, em comparação com o LVd3, indica que o basalto teve maior contribuição na formação do solo eutrófico.

Na validação da unidade LVe1, dos 118 pixels 47 foram classificados como PVe3/1 e 26 como LVe2. Somente 29 pixels estavam corretos, resultando em uma concordância de 24,6%. As três unidades ocorreram exclusivamente em áreas de basalto e sem distinção nos valores médios para os atributos índice de convergência, perfil e plano de curvatura, dificultando a discriminação entre essas unidades. Pequenas diferenças foram encontradas nos valores de declividade e superfície geomórfica, com menores médias para a unidade LVe1, enquanto que para o atributo elevação a unidade LVe2 se destacou com maior ocorrência em maiores altitudes. A melhoria dos resultados para treinamento e validação das arquiteturas, aumentando a qualidade das correspondências, principalmente na validação da unidade LVe1, poderia ser obtida se fossem eliminadas amostras próximas às áreas de transição entre unidades de mapeamento ou se fosse optado somente pelo uso de amostras de campo na geração dos arquivos de treinamento e validação (ZHU, 2000).

4.2.4 Geração e caracterização do mapa digital de solos

Após a validação da arquitetura de rede TV/11 fez-se a generalização de suas informações para toda a área de estudo. Nessa etapa, os valores das variáveis ambientais em cada pixel da área de estudo foram apresentados à rede neural. Como resultado, cada pixel é classificado com valores de similaridade para cada unidade de mapeamento (camada de saída). O mapa final foi obtido por meio da conversão da representação de similaridade (ZHU, 2000) para uma representação booleana. A conversão foi feita adicionando a cada pixel o valor correspondente à unidade de mapeamento que apresentou a maior porcentagem entre todas as envolvidas (ZHU, 1997). A Figura 15 apresenta o Mapa Digital de Solos obtido na estratégia 1 (MDS1).




Figura 15 - MDS1

A classificação das unidades de mapeamento na área de estudo pelas redes neurais apresentou relação com as características do relevo e da litologia. Algumas unidades tiveram maior representatividade, como os LVd3 com 4.317,8 ha (39,0%) e os PVe3/3 com 3.175,9 ha (28,7%), enquanto que as unidades com as menores áreas classificadas foram os LVe1 com 101,7 ha (0,9%), LVe2 com 170,1 ha (1,5%) e PVe3/1 com 189,4 ha (1,7%). As outras unidades foram identificadas com as seguintes áreas: CXve2 com 1.584,1 ha (14,3%), LVe3 com 1.104,2 ha (10,0%), NVe1 com 1.087,9 ha (9,8%) e CXbe1 com 448,8 ha (4,1%).

Nas áreas de topo, onde ocorreram as menores declividades e maiores elevações das vertentes, com predomínio do arenito na formação dos solos, foram classificados apenas os LVd3 e LVe3. De maneira geral, esses Latossolos de textura média transitaram para os PVe3/3 em áreas de terço médio à terço final das encostas, nas transições de arenito para basalto. Provavelmente, parte do erro de aprendizagem obtido para a classe LVd3, na etapa de validação da rede TV/11, se expressou no grande número de pixels classificados como PVe3/3 no mapa digital. Ressalta-se aqui a dificuldade na distinção entre essas três unidades durante as

atividades de campo para o mapeamento convencional das áreas chaves, sendo devido: a ocorrência dessas unidades em locais da paisagem muito semelhantes e adjacentes; o nível de detalhe selecionado para o desenvolvimento dessa estratégia, proporcionando um reduzido número de informações para delineamento das unidades de mapeamento; a transição muito gradual entre esses solos. Uma vez que tais unidades são padrões de referência na elaboração das amostras de treinamento e validação das redes neurais, erros na determinação dos limites entre as unidades no mapa convencional refletem em uma classificação equivocada por parte da técnica digital.

Em locais com o predomínio do basalto como material de origem e nos terços finais das encostas foram classificados principalmente os CXbe1, CXve2 e NVef1. Invariavelmente, ambos os Cambissolos foram classificados nos locais representados pelos talwegues dos rios. A inexistência de um neurônio na camada de saída das redes neurais que representasse os leitos dos rios, e o fato desses Cambissolos serem mapeados próximos e nesses locais da paisagem, justificou o resultado obtido no mapa digital (Figura 15). Deste modo, as áreas dessas duas unidades classificadas digitalmente foram superestimadas.

A unidade LVe1, com grande representatividade no mapa convencional, não manteve o mesmo comportamento no mapa digital, sendo inclusive a unidade com menor área classificada. Isto ficou evidente pela sua baixa concordância obtida na matriz de confusão (etapa de teste da rede TV/11). Como consequência, o processo de generalização da rede para o padrão estabelecido nesta unidade apresentou desempenho abaixo do esperado. De maneira análoga, a unidade LVe2 também foi classificada em pequenas áreas da região. Sua distribuição revelou coerência com o que foi constatado no mapa convencional, sendo que esta unidade foi classificada intermediando solos mais arenosos à montante e mais argilosos à jusante. Comportamento interessante foi observado para a unidade PVe3/1, em que a maior parte dos pixels com sua identificação localizaram-se em cabeceiras de drenagem.

4.2.5 Comparação e validação do mapa digital de solos

Os resultados da aplicação de tabulações cruzadas entre os mapas de solos digital e convencional são apresentados na Tabela 4. Este último mapa foi

obtido de (ALMEIDA; OLIVEIRA; PRADO, 1982a; 1982b) (ANEXO B), contemplando toda a região de estudo. Tais resultados apresentam as correspondências espaciais entre as unidades de mapeamento considerando dois níveis categóricos, sendo que em um deles é acrescida a informação da textura dos solos. Como no mapa convencional ocorrem associações de solos, considerou-se separadamente cada componente da associação. Quando observada equivalência de algum destes componentes com a unidade correspondente no mapa digital, as unidades foram classificadas como concordantes. Resultados detalhado das tabulações cruzadas encontram-se nos Anexo D, E e F. A legenda para cada unidade de mapeamento do mapa convencional pode ser vista no Anexo G.

Tabela 4 - Correspondência espacial entre as unidades de mapeamento dos mapas digital e convencional em diferentes níveis categóricos

2° nível	CX	LV	NV	PV	Total*				
Concordância (%)	3,3	96,8	76,8	0,0	49,2				
3° nível	CXe	LVd	LVe	NVef	PVe	Total			
Concordância (%)	3,3	96,4	9,4	15,1	0,0	38,0			
2° nível + textura	CX2	CX1	LV3	LV2	LV1	NV1	PV3/3	PV3/1	Total
Concordância (%)	2,7	0,0	94,6	31,2	82,6	76,8	0,0	0,0	46,0

* Valor de concordância obtida em toda a área de estudo para o respectivo nível categórico

A maior (49,2%) e a menor (38,0%) concordâncias foram encontradas quando considerados, respectivamente, o 2° e o 3° nível categórico das unidades mapeadas. Com a adição da informação da textura dos solos ao 2° nível categórico, a concordância foi de 46,0%. De maneira geral, dentro de cada nível considerado, os Latossolos apresentaram as maiores correspondências espaciais, seguidos dos Nitossolos. Os Cambissolos mostraram baixos valores e na classe dos Argissolos não foi encontrada concordância entre os mapas. São duas as possíveis causas do baixo desempenho encontrado para a classe dos Cambissolos: (i) o nível de detalhamento no mapa convencional não permitiu a correta identificação dessa classe na região, já que nas etapas de incursão ao campo realizadas neste trabalho foram constatadas ocorrências em locais não representados no mapa convencional; (ii) a superestimação da área identificada como Cambissolo no mapa digital aumentou a discordância entre os mapas.

Referente aos Argissolos, possíveis explicações para os valores nulos de concordâncias seriam: reduzido tamanho das duas unidades de mapeamento

classificadas como Argissolos no mapa convencional, diferindo da elevada área classificada digitalmente; diferença entre as cores no horizonte subsuperficial que classifica o segundo nível categórico desses solos, já que no mapa convencional ocorreram Argissolos Vermelhos-Amarelos e no digital Argissolos Vermelhos; na região estudada esses solos foram mapeados em posições da paisagem semelhantes aos locais em que foram identificados os Latossolos. Presume-se que a abordagem convencional, no nível de detalhe aplicado, não permitiu a identificação dos Argissolos na região, sendo subestimada a representação desses solos pelo mapeamento de Latossolos.

Chagas (2010) empregou a mesma abordagem utilizada no presente estudo para a predição de classes de solos em uma região montanhosa no Noroeste Fluminense. Neste trabalho o autor obteve concordâncias, entre mapa digital e convencional, de 44,76% e 37,87% para o 2º e 3º nível categórico, respectivamente. O autor destacou que o padrão espacial das classes resultantes do uso de redes neurais foi bastante complexo e distinto, sendo poucas as áreas que reuniram muitos pixels. Este fato não ocorre em mapas convencionais, que exibem grandes e extensos polígonos representando as unidades de mapeamento. Dessa forma, as elevadas discordâncias obtidas podem ser atribuídas em grande parte à natureza generalizada do mapa de solos convencional (ZHU, 2000).

Com a finalidade de validar o mapa digital de maneira pontual, a Tabela 5 apresenta a classificação de 22 pontos de referência coletados e classificados até o 2º nível categórico mais a informação da textura. A localização na região e os resultados das análises granulométricas e colorimétricas desses pontos se encontram nos Anexos H e I, respectivamente. Do total avaliado na classificação digital, foram inferidas corretamente 16 observações (72,7%). Das seis discordantes, três delas (7, 13 e 17) foi devido à textura, sendo idênticas as classificações até o nível de subordem. Ou seja, quando considerado até o segundo nível categórico, ausentando a informação de textura, a concordância entre os mapas foi de 86,4%.

Tabela 5 - Validação pontual do mapa digital de solos

Id ⁽¹⁾	Campo	Digital	V/F ⁽²⁾	Id	Campo	Digital	V/F
1	NV1	NV1	V	12	LV3	LV3	V
2	LV3	LV3	V	13	PV4/3	PV3/3	F
3	LV3	LV3	V	14	LV3	LV3	V
4	NV1	NV1	V	15	NV1	NV1	V
5	LV3	LV3	V	16	NV1	PV3/3	F
6	LV3	LV3	V	17	PV3/2	PV3/3	F
7	LV2	LV3	F	18	NV1	NV1	V
8	LV3	LV3	V	19	LV3	LV3	V
9	LV3	PV3/1	F	20	NV1	NV1	V
10	LVA3	PV3/3	F	21	LV3	LV3	V
11	LV3	LV3	V	22	NV1	NV1	V

⁽¹⁾ identificação da amostra; ⁽²⁾ classificação verdadeiro-falsa

Tais resultados de concordâncias foram semelhantes aos encontrados por Zhu (2000) que, aplicando estratégia de mapeamento de solos com uso de redes neurais, inferiu corretamente 77% dos 64 locais amostrados no campo. Chagas et al. (2007) obtiveram 70,8% de acerto na classificação de 288 pontos de referência, que incluíam perfis de solos, amostras extras e pontos de observação. De acordo com os autores o mapa produzido pela abordagem de redes neurais teve um desempenho melhor que a abordagem convencional (53,7% de concordância com os pontos de referência).

Possíveis motivos que podem ser citados como causas das divergências na validação pontual entre o mapa digital de solos e o convencional são: a variação dos solos pode ter ocorrido sem relação com as variáveis ambientais utilizadas na estratégia aplicada (CHAGAS et al., 2010); o uso das informações geológicas pode não ter representado adequadamente a geologia da área devido a limitações de escala (THOMAS et al., 1999); dificuldade no processo de aprendizado das redes neurais, confundindo unidades de mapeamento de comportamentos similares para as variáveis ambientais (ZHU, 2000); obtenção de amostras para treinamento e validação das RNA a partir de polígonos de unidades de mapeamento oriundos de abordagem convencional, os quais podem não representar as unidades presentes devido o nível de mapeamento efetuado ser considerado semidetalhado.

4.3 Estratégia de mapeamento digital de solos 2

4.3.1 Mapa de solos convencional e caracterização das unidades de mapeamento

Como base para a aplicação da segunda estratégia, foram obtidas unidades de mapeamento com uso de dados obtidos no trabalho de Fiorio et al. (2003), e elaborado um mapa de solos (Figura 16). A área mapeada apresentou, da região central aplanada para a direção noroeste/oeste, solos de textura média nas maiores altitudes, variando para solos mais argilosos nas áreas próximas à drenagem. Esse comportamento foi devido a ocorrência de arenito nas áreas de topo e basalto nas partes inferiores das encostas, havendo na transição entre esses materiais solos de texturas intermediárias. Ou seja, a mesma influência do material de origem nas características dos solos, observadas nas áreas chaves da estratégia 1. Já no sentido que vai do centro da área para a direção leste, praticamente não se observou variação na textura dos solos, o que pode ser explicado pelo material de origem ser predominantemente o arenito.

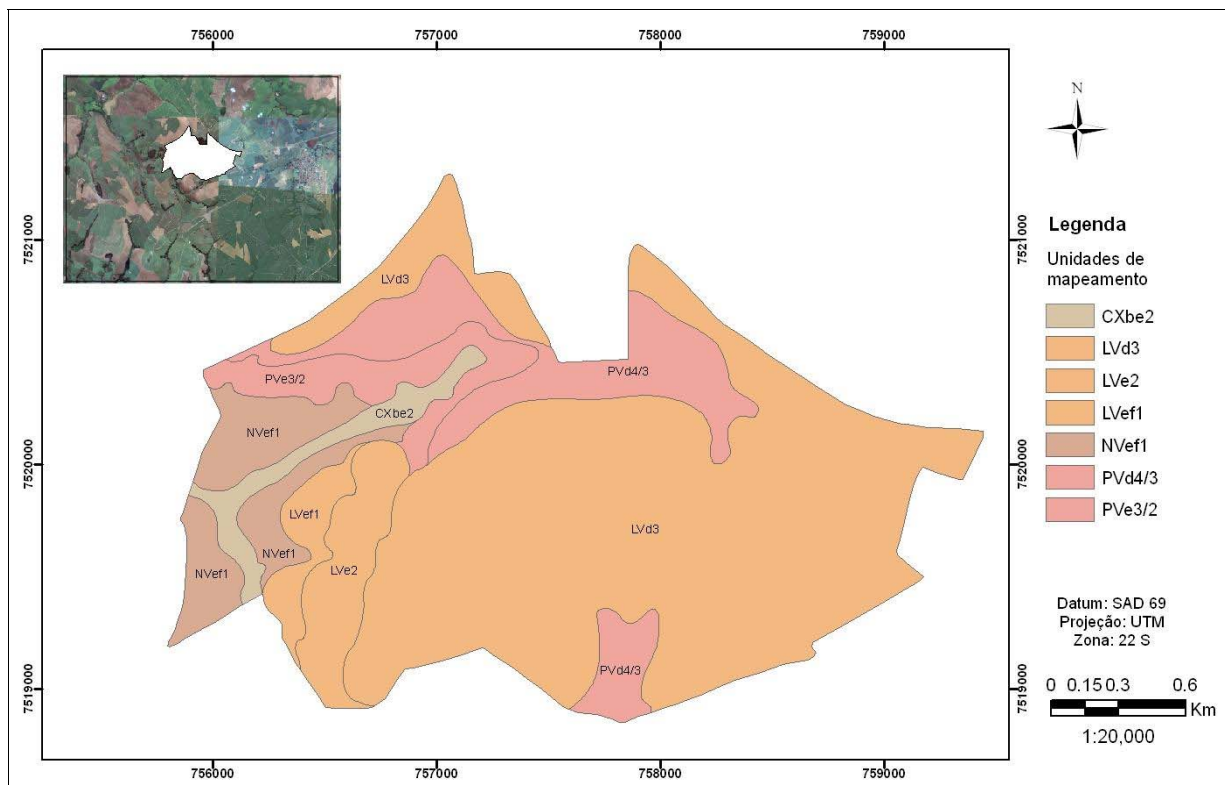


Figura 16 - Mapa de solos convencional da área chave e localização na área de estudo
(Adaptado de FIORIO et al., 2003)

Na maior parte da área verificou-se a predominância do LATOSSOLO VERMELHO Distrófico textura média (LVd3), com 61,2% do total mapeado. Nos locais classificados com essa unidade foram identificadas inclusões de LATOSSOLO VERMELHO-AMARELO Distrófico textura média (LVAd3). Em seguida, ocorreram o ARGISSOLO VERMELHO Distrófico textura arenosa/média (PVd4/3) (13,3%), NITOSSOLO VERMELHO Eutrófico textura muito argilosa (NVef1) (8,4%), LATOSSOLO VERMELHO Eutrófico textura argilosa (LVe2) (5,5%), ARGISSOLO VERMELHO Eutrófico textura média/argilosa (PVe3/2) (5,4%), CAMBISSOLO HÁPLICO Tb Eutrófico textura argilosa (CXbe2) (3,5%) e LATOSSOLO VERMELHO Eutrófico textura muito argilosa (LVef1) (2,7%).

A partir de dados disponíveis em Fiorio et al. (2003) foram plotadas três topossequências (Anexo J) com o objetivo de caracterizar as unidades de mapeamento nelas ocorrentes em função das características do relevo e da estratigrafia local. Para tanto, foram utilizados dados gerados por tabulações cruzadas entre as unidades de mapeamento, atributos do terreno derivados do MDE, superfície geomórfica e geologia (Tabela 6), permitindo a compreensão das diferentes condições em que os solos ocorrem na paisagem. Resultados das análises químicas e granulométricas de amostras representativas de cada unidade mapeada nas topossequências podem ser consultados no Anexo K.

A topossequência A, com aproximadamente 1850 m de extensão, caracterizou-se por apresentar altitudes que variaram de 704 a 610 m, onde nas partes mais altas ocorreram solos com maior influência do arenito e nas partes próximas da drenagem o basalto foi material de origem predominante. Os teores dos atributos químicos e granulométricos discutidos na sequência, são referentes à camada de 80-100 cm. O LVd3 foi a unidade com maior ocorrência na área chave, apresentando teor médio de argila de 160 g.kg^{-1} de solo e CTC média de $24,3 \text{ mmol}_c.\text{kg}^{-1}$ de solo. Localizou-se principalmente em relevo ondulado (60,6%) e suave ondulado (23,6%). De maneira geral, apresentou plano de curvatura divergente e perfil de curvatura côncavo e retilíneo. Foi a única unidade que ocorreu na superfície geomórfica I (19,4%), ocupando em sua maior parte a superfície II (53,4%).

Tabela 6 - Variáveis ambientais utilizadas na caracterização dos solos

Variáveis		CXbe2	LVd3	LVe2	LVEf1	NVef1	PVe3/2	PVd4/3	Total
Área	(ha)	17,36	306,56	27,8	13,56	42,08	27,16	66,72	501,24
Elevação (m)	Máx	641	721	663	646	651	661	685	721
	Mín	603	632	621	618	603	635	647	603
Declividade (%)	0 a 3%	2,6%	2,3%	0,0%	0,0%	0,0%	0,0%	0,0%	1,5%
	3 a 8%	15,6%	23,6%	0,0%	0,0%	5,2%	0,0%	4,3%	16,0%
	8 a 20%	35,7%	60,6%	50,7%	69,8%	42,0%	24,9%	58,2%	55,6%
	20 a 45%	42,1%	13,4%	49,3%	30,2%	52,8%	75,1%	37,5%	26,7%
	45 a 75%	4,0%	0,0%	0,0%	0,0%	0,0%	0,0%	0,0%	0,1%
Plano de Curvatura	Convergente	48,2%	20,0%	22,4%	25,7%	23,0%	27,7%	31,5%	23,4%
	Planar	7,6%	17,1%	6,6%	8,6%	10,4%	10,0%	19,1%	15,3%
	Divergente	44,2%	63,0%	70,9%	65,8%	66,6%	62,3%	49,3%	61,3%
Perfil de Curvatura	Côncavo	10,1%	40,8%	45,0%	42,8%	53,0%	49,9%	40,0%	41,4%
	Retilíneo	4,8%	37,5%	29,5%	27,1%	19,0%	19,3%	21,0%	30,9%
	Convexo	85,0%	21,7%	25,5%	30,1%	27,9%	30,8%	39,0%	27,7%
Superfície Geomórfica	I	0,0%	19,4%	0,0%	0,0%	0,0%	0,0%	0,0%	11,8%
	II	24,7%	53,4%	0,0%	0,0%	42,2%	9,6%	9,5%	38,8%
	III	75,3%	27,2%	100,0%	100,0%	57,8%	90,4%	90,5%	49,3%
Geologia	Basalto	100,0%	28,5%	93,5%	100,0%	99,0%	88,7%	36,9%	46,8%
	Arenito	0,0%	71,5%	6,5%	0,0%	1,0%	11,3%	63,1%	53,2%

Em sequência verificou-se o LVe2, sendo o material de origem um produto da alteração de arenito com retrabalhamento e mistura de material proveniente de basalto. Deste modo, houve incremento no teor de argila observado para essa unidade (média de 490 g.kg^{-1}) e aumento da CTC ($38,1 \text{ mmol.c.kg}^{-1}$). Localizou-se em relevo ondulado e forte ondulado, com plano de curvatura divergente e perfil de curvatura predominantemente côncavo. A superfície geomórfica II foi a de maior expressão.

No terço final da topossequência foram identificadas as unidades LVEf1 e NVef1. Apresentaram teores médios de argila de 710 e 780 g.kg^{-1} e CTC de $38,2$ e $59,1 \text{ mmol.c.kg}^{-1}$, respectivamente, denotando a maior influência do basalto nas características desses solos. Quanto ao relevo, foram encontrados em declividades superiores a 8%, com maior ocorrência de Nitossolo em relevo forte ondulado. O plano de curvatura foi predominantemente divergente, enquanto que o perfil de curvatura foi classificado como côncavo, na maior parte da área com essas unidades. A superfície geomórfica III foi identificada em 100% dos locais mapeados com LVEf1 e 57,8% com NVef1.

A última unidade mapeada na topossequência A constou de um CXbe2, localizado próximo à calha da drenagem. Ocorreu nas menores altitudes

(603 m), em classes de declividades variadas, indo desde plano até montanhoso com predomínio de forte ondulado (42,1%), com plano curvatura convergente e divergente, perfil convexo e superfícies geomórficas classificadas como II e III, principalmente.

A topossequência B teve início no mesmo local da topossequência anterior. Dessa forma, a unidade LVd3 foi a primeira identificada. Na sequência, ocorreu um PVd4/3 em declividades onduladas e forte onduladas, com predomínio de plano de curvatura divergente e perfil de curvatura côncavo e convexo. Ocorreu quase que inteiramente dentro da superfície geomórfica III.

Com a proximidade da drenagem e a maior contribuição do basalto como material de origem, mas havendo ainda contribuição de material de alteração do arenito, foi mapeada a unidade PVe3/2. Comparando os Argissolos identificados, constatou-se que o que mais se destacou na diferenciação entre as duas unidades foram a contribuição do material de origem para a formação de ambos e a predominância de um relevo mais acidentado para essa última unidade (75,1% é forte ondulado para PVe3/2). Por fim, foi mapeado o mesmo CXbe2 encontrado na primeira topossequência.

Analisando alguns atributos dos solos nas duas topossequências, tais como os teores de Al^{3+} , SB, CTC, e os teores de argila e areia na profundidade de 80-100 cm (Figura 17), notou-se que a variação desses atributos manteve uma relação direta com a variação do provável material de origem dos solos. Amostras com menores teores de cátions básicos, CTC, argila e maiores teores de alumínio trocável e areia ocorreram nas posições mais elevadas da paisagem e de meia encosta. Este comportamento mostrou a maior influência de material do arenito nas composições das amostras, refletindo em baixa fertilidade natural nesses locais da paisagem. Nos terços finais das duas topossequências, esse comportamento foi invertido, comprovando a maior contribuição do basalto na constituição química e granulométricas dos solos nesses locais.

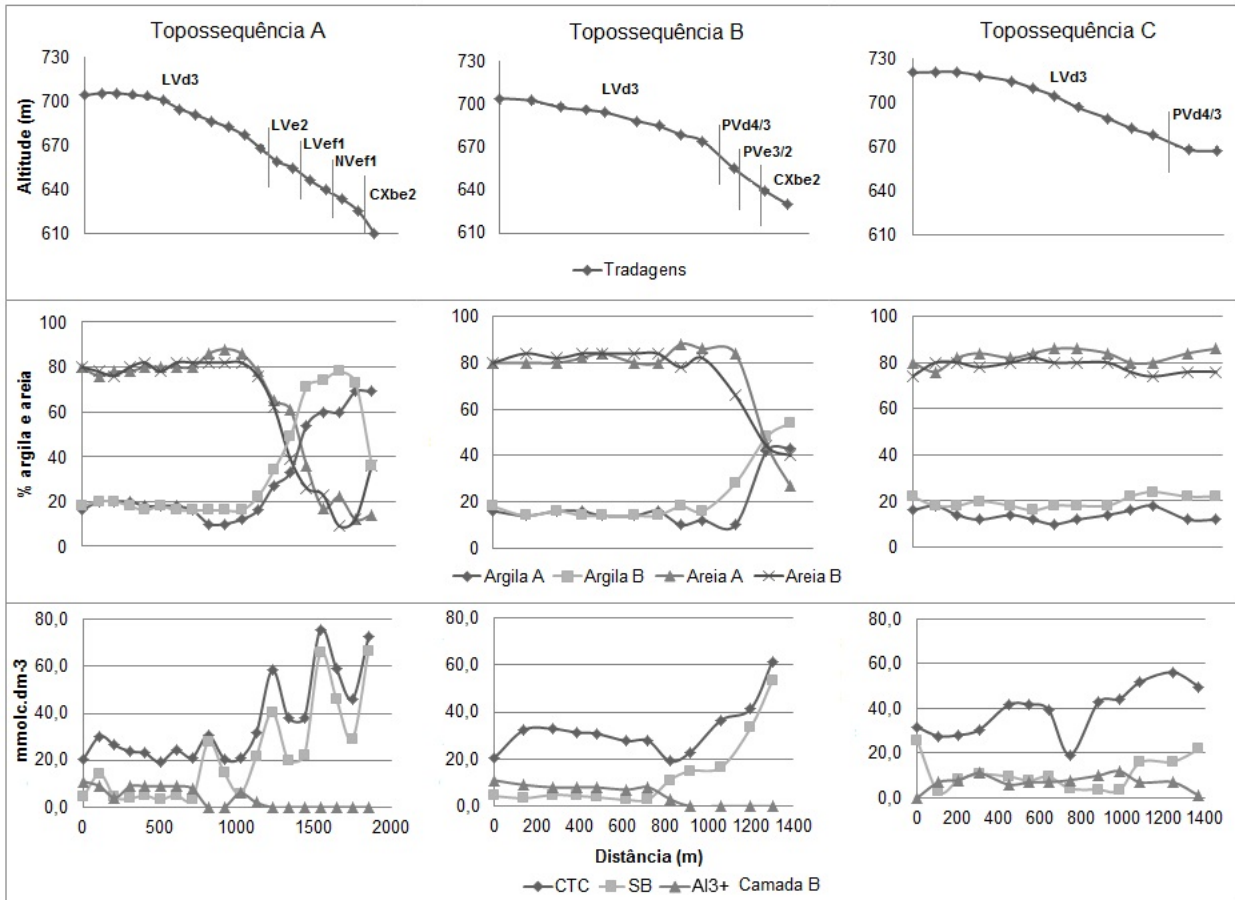


Figura 17 – Perfil topográfico e comportamento de atributos químicos e granulométricos nas topossequências

Para retratar corretamente a área chave, elaborou-se a topossequência C, em que em uma extensão de aproximadamente 1370 m, foram mapeadas apenas duas unidades, sendo elas: LVd3 e PVd4/3. De acordo com os resultados das amostras obtidas para essas unidades e com o conhecimento da estratigrafia local, ficou evidente a predominância do arenito na formação desses solos. Os teores de argila e areia mantiveram uma distribuição constante ao longo da vertente, com valores entre 180 a 220 g.kg⁻¹ e 760 a 800 g.kg⁻¹ de solo, respectivamente. Diferentemente do comportamento observado nas outras topossequências, os teores de alumínio trocável e soma de bases se mantiveram praticamente constantes na parte final da vertente.

A distribuição das unidades de mapeamento ao longo das topossequências localizadas na área chave apresentou estreita relação com as características do relevo e o material de origem. Dois comportamentos distintos foram observados: (i) alteração dos atributos químicos e granulométricos nas encostas com litossequência de transição arenito-basalto; (ii) valores constantes

para esses atributos no sentido topo-talvegue de uma encosta com solos sobre o arenito.

Uma vez caracterizadas as unidades de mapeamento da área chave utilizada na aplicação da técnica digital, deu-se início às etapas de treinamento e validação das arquiteturas de redes neurais.

4.3.2 Avaliação das redes neurais artificiais

A análise do comportamento do índice Kappa nas diferentes arquiteturas de rede testadas (Figura 18) subsidiou a escolha do conjunto de variáveis a ser utilizado na obtenção do mapa digital de solos. O maior valor para o índice Kappa (0,809) foi obtido quando todas as variáveis foram consideradas e quando o número de neurônios na camada interna foi igual a 3. Para os conjuntos TV-D e TV-E os melhores desempenhos de índice Kappa foram de 0,635 e 0,466 com 7 e 13 neurônios na camada interna, respectivamente, sendo os conjuntos que apresentaram os piores valores do índice. Assim como observado na estratégia 1, foi constatado que a retirada das informações de declividade e elevação da rede neural compromete significativamente o resultado da classificação, principalmente pela ausência do último atributo.




Figura 18 - Valores do índice Kappa das arquiteturas testadas (TV - todas as variáveis; D - declividade; E - elevação; G - geologia; IC - índice de convergência; PfC - perfil de curvatura; PnC - plano de curvatura; SG - superfície geomórfica)

Nos demais conjuntos de variáveis, os melhores desempenhos foram de 0,730 para o grupo TV-IC com 5 neurônios na camada interna; 0,757 em TV-SG e 0,724 para TV-PfC com 9 neurônios internos em ambos os casos. Os conjuntos TV-G e TV-PnC exibiram valores próximos do melhor obtido (TV), sendo de 0,778 e 0,806, com mesmo número de neurônios na camada interna (3 neurônios).

Os resultados dos índices Kappa, provenientes das alterações do número de neurônios na camada interna, não apresentaram comportamentos similares nos conjuntos de variáveis. Em alguns conjuntos, a tendência foi de melhoria do índice e para outros foi de decaimento. Chagas (2005) obteve melhores resultados aplicando arquiteturas de redes com menos de 10 neurônios na camada interna. Isso corrobora com os dados apresentados, pois os três grupos com melhor desempenho de índice foram alcançados quando aplicados 3 neurônios na camada interna. Além disso, dos oito grupos testados, sete apresentaram os melhores índices com menos de 10 neurônios nessa camada. Foody e Arora (1997) citam que redes maiores e mais complexas possuem maior eficiência na caracterização de um conjunto de treinamento, ao passo que podem ter menor eficiência para generalizar, em relação a redes mais simples.

Para efeito comparativo entre o índice Kappa dos diferentes conjuntos testados, foi gerada uma matriz de significância de Kappa (Tabela 7). A avaliação da matriz permitiu a escolha da melhor da rede neural para uso na predição das unidades de mapeamento.

Tabela 7 - Matriz de significância de Kappa

Conjunto	TV (3) ^a	TV - D (7)	TV - E (13)	TV - G (3)	TV - IC (5)	TV - PfC (9)	TV - PnC (3)	TV - SG (9)
Exatidão global	83,7	69,1	54,5	81,1	77,0	76,5	81,4	79,3
Kappa	0,809	0,635	0,466	0,778	0,730	0,724	0,786	0,757
Variância ^b	0,305	0,445	0,512	0,341	0,390	0,391	0,338	0,361
TV	46,32							
TV - D	6.35*	30,10						
TV - E	12.00*	5.46*	20,59					
TV - G	1,22	5.10*	10.68*	42,13				
TV - IC	2.99*	3.28*	8.70*	1,77	36,97			
TV - PfC	3.22*	3.07*	8.58*	1.99*	0,22	36,61		
TV - PnC	0,91	5.39*	10.97*	0,31	2.07*	2.29*	42,75	
TV - SG	2.01*	4.29*	9.84*	0,79	0,99	1,20	1,10	39,84

* existe diferença significativa ao nível de 95%; ^a número de neurônios na camada interna; ^b valores multiplicados por 1000; TV - todas as variáveis; D - declividade; E - elevação; G - geologia; IC - índice de convergência; PfC - perfil de curvatura; PnC - plano de curvatura; SG - superfície geomórfica

Os melhores resultados foram obtidos com os conjuntos TV, TV-G e TV-PnC, não diferindo estatisticamente entre eles. Tais resultados foram alcançados com uso de três neurônios na camada interna. A ausência das informações geológicas ou do plano de curvatura, na etapa de validação das redes, demonstrou não interferir significativamente no desempenho do índice Kappa, quando comparadas à ausência das outras variáveis. No entanto, quando utilizado o conjunto TV, o índice Kappa apresentou seu melhor resultado em valor absoluto (0.809), concordando com o encontrado na estratégia 1. A rede neural que não utilizou o atributo elevação diferiu de todas as outras, fato também constatado quando retiradas as informações de declividade, o que evidenciou mais uma vez a importância dessas duas variáveis na classificação digital de solos.

O comportamento de cada atributo do terreno pode ser observado na Figura 19. Os valores no eixo y referem-se às médias das amostras de treinamento reescaladas entre 0 e 1. As maiores variações nos valores de elevação e declividade para os dados ratificam a discussão anterior e explicam a maior influência desses atributos na discriminação dos solos. Assim como na estratégia anterior, os atributos índice de convergência, plano de curvatura e perfil de curvatura exibiram comportamento menos discrepantes entre os solos.

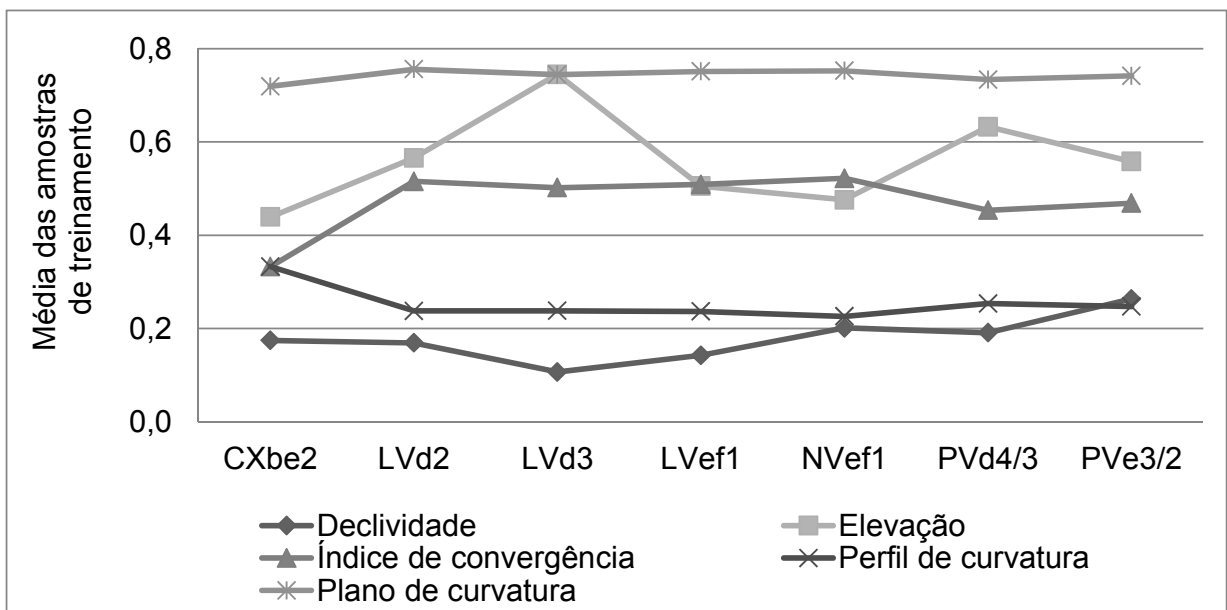


Figura 19 - Valores médios dos atributos do terreno entre as unidades de mapeamento

Avaliando os desempenhos dos conjuntos gerados, optou-se pelo uso de todas as variáveis ambientais para a discriminação dos solos na área estudada, sendo elas: cinco atributos do terreno derivados do MDE, geologia e superfícies geomórficas. Por meio da avaliação de uma matriz de significância de Kappa (Anexo L) aplicada nos dados das redes neurais que utilizaram o conjunto TV como camada de entrada, optou-se pelo uso de três neurônios na camada interna. De maneira análoga à estratégia 1, foi dado um nome para a rede neural utilizada na classificação dos dados finais, sendo referida como TV/3.

Na tabela 8 é apresentado o resultado da matriz de confusão proveniente do processamento da TV/3 nos dados do arquivo de validação. A unidade de mapeamento LVef1 exibiu o pior desempenho, com exatidão de 63,6%, sendo que 18 pixels da unidade foram classificados como NVef1. Quando analisadas as características das variáveis ambientais obtidas para essas unidades (Figura 20), constatou-se que seus valores próximos ocasionaram tal erro na classificação. A confusão na classificação da unidade LVef1 foi atribuída, principalmente, aos valores do índice de convergência, perfil e plano de curvatura, que apresentaram um comportamento muito semelhante com os valores para NVef1; enquanto que para a declividade e elevação é possível notar, mesmo que sutil, uma diferença entre eles, ocorrendo o LVef1 em menores declividades e maiores valores de elevação, fato que se inverte para a unidade NVef1. Como a distinção entre Latossolos e Nitossolos é realizada principalmente por observações morfológicas como estrutura e cerosidade (COOPER; VIDAL TORRADO, 2005), a classificação digital foi dificultada nesse caso, pela ausência de informações dos solos em profundidade, já que essas duas classes ocorreram em locais da paisagem muito semelhantes.

Tabela 8 - Matriz de confusão obtida pelo uso da TV/3

Unidade	CXbe2	LVd3	LVe2	LVEf1	NVef1	PVd4/3	PVe3/2	Total	Exatidão do usuário	Z
CXbe2	61	2	0	0	0	1	0	64	95,3	31,14
LVd3	0	94	3	0	0	1	0	98	95,9	39,65
LVe2	2	0	59	1	0	3	4	69	85,5	17,34
LVEf1	5	0	6	35	1	1	3	51	68,6	9,43
NVef1	8	0	3	18	104	0	0	133	78,2	17,97
PVd4/3	3	9	0	0	0	83	8	103	80,6	17,42
PVe3/2	3	0	10	1	0	3	74	91	81,3	16,83
Total	82	105	81	55	105	92	89	609		
Exatidão do produtor	74,4	89,5	72,8	63,6	99	90,2	83,1			

Exatidão global = 83,7; Kappa = 0,809; Variância = 0,000305; Z calculado = 46,319; Z tabelado = 1,96

A unidade LVe2 exibiu o segundo pior desempenho, confundindo 10 dos 81 pixels com a unidade PVe3/2 e 6 com LVEf1, sendo 59 o número de pixels classificados corretamente nessa fase de testes. Assim como na estratégia anterior, a técnica digital encontrou dificuldades para a distinção entre Latossolos e Argissolos, embora na presente estratégia isto tenha ocorrido com menor intensidade. O desempenho na classificação das outras unidades resultou em valores de exatidão maiores que 80% para as unidades PVE3/2, LVd3, PVd4/3 e NVef1, e de 74,4% no CXbe2.




Figura 20 - Comportamento das variáveis ambientais para algumas classes de solos

4.3.3 Geração e caracterização do mapa digital de solos

Após treinamento das redes neurais e validação da arquitetura escolhida, fez-se a predição das unidades de mapeamento em toda a área de estudo, ou seja, a generalização do conhecimento da rede TV/3. A Figura 21 apresenta o mapa obtido, denominado de Mapa Digital de Solos 2 (MDS2).




Figura 21 - MDS2

A ocorrência dos solos na região, discriminada pelas redes neurais, mostrou-se coerente com o que foi obtido na área chave, podendo ser observado o mesmo comportamento da relação solo-paisagem-material de origem descrita naquela área. Os LVd3 predominaram nas altitudes mais elevadas, de topo, até posições de meia encosta, onde transitaram para unidades como PVd4/3, PVe3/2 e LVe2. Nas regiões com predomínio do arenito em toda a vertente, os Argissolos ocorreram em estreita faixa no terço final das encostas, até serem classificados os CXbe2 em posição próxima ou referente à calha dos rios. Esse padrão de distribuição dos Cambissolos foi observado em toda a região estudada, sendo dois os principais motivos que explicam tal comportamento: o fato de na etapa de

aprendizagem das redes neurais não ter sido criada uma camada de saída que representasse o canal de drenagem e/ou o leito aparente dos rios e riachos; e devido na área chave essa classe ter sido mapeada nesses locais da paisagem.

Nas áreas que tem o basalto como material de origem, foram encontrados os N_{Vef1}, L_{Ve2}, C_{Xbe2} e uma quantidade muito pequena de pixels classificado como L_{Vef1}. Devido à grande similaridade dos valores das variáveis ambientais entre o Nitossolo e o Latossolo de textura muito argilosa, a rede neural, aparentemente, não conseguiu generalizar esta última classe. A matriz de confusão da rede TV/3 (Tabela 8) ratifica essa afirmativa, mostrando que grande parte dos pixels da amostra de validação para os L_{Vef1} foram classificados como sendo de Nitossolos. O classificador digital constatou a dificuldade existente, em certos casos, para a separação dessas duas classes na ausência de observações de campo, por meio de análises morfológicas de perfis representativos.

4.3.4 Comparação e validação do mapa digital de solos

Maior riqueza de detalhamento espacial pode ser verificada no mapa digital em comparação ao mapa convencional (Anexo B). Chagas (2006), utilizando os mesmos conjuntos de perfis de solos usados na elaboração de um mapa convencional, gerou mapas digitais de solos por RNA e Máxima Verossimilhança mais detalhados espacialmente, estabelecendo com maior precisão as relações ocorrentes na área da bacia estudada. Zhu (2000) e Carvalho Júnior (2005) obtiveram resultados semelhantes quanto ao melhor nível de detalhamento dos mapas digitais.

A Tabela 9, 10 e 11 apresentam os dados das tabulações cruzadas entre o mapa digital e o convencional para a avaliação da correspondência espacial das unidades de mapeamento existentes nos mapas. No Anexo G, tem-se a descrição das unidades que ocorrem no mapa convencional. Nas associações deste mapa, foram considerados todos os componentes ocorrentes, ou seja, quando um membro da associação foi concordante com a unidade de mapeamento presente no mapa digital, a concordância foi computada (valores em negrito).

Os mapas coincidiram em 59,0%, 42,3% e 52,8% quando analisados os 2°, 3° e 2° nível categórico mais a textura, respectivamente. Thomas et al. (1999), comparando um mapa convencional na escala de 1:100.000 com um mapa de solos

obtido a partir de atributos do terreno derivados de um MDE e dados de geologia, obtiveram concordância de 55%. Em Chagas (2010) a aplicação de redes neurais utilizando dados de geologia, atributos do terreno e índices derivados da imagem do sensor ETM+ do LANDSAT 7, resultou em concordância de 37,15% entre o mapa convencional (1:50.000) e o digital. O autor cita que uma possível fonte de discordância entre a comparação dos mapas seria a dificuldade em estabelecer relação solo-paisagem devido à complexidade da natureza geológica da área. No entanto, no presente estudo, a entendimento dessa relação foi facilitada, uma vez que aparentemente se tratava de uma área com geologia simples.

Tabela 9 - Tabulação cruzada entre mapa digital e convencional considerando até o 2º nível categórico

Unidades	CX	LV	NV	PV
TE1+Li2	54.6	15.3	37.2	5.4
LE1+LE2	162.4	3086.8	63.5	1409.1
LE2+LE1	5.3	198.5	1.2	118.1
LE2	126.2	419.9	107.7	409.9
LV2+LE1	10.5	1025.3	0.3	117.8
LV2+LV3	0.0	23.1	0.0	1.0
LV4	0.0	28.9	0.0	0.0
LE3	24.6	206.1	10.7	186.6
LE3+LRd+TE2	74.6	39.1	56.5	213.4
LRd+LE3+TE2	473.1	331.1	913.9	335.6
LRd+LRd	37.3	29.2	90.1	43.7
TE1	80.2	10.3	94.0	13.8
TE1+TE2	7.0	0.8	5.1	11.2
TE2+TE1	109.8	48.6	31.8	14.3
PV1	5.8	5.8	8.8	15.2
PV3	4.9	79.6	0.0	35.0
Total (ha)	1176.3	5548.4	1420.8	2930.1
Coincidem (ha)	54.6	5336.0	1138.6	0.0
(%)	4.6%	96.2%	80.1%	0.0%
Área total mapeada = 11.075,7 ha; Área coincidente = 6.529,2 ha (59,0%)				

Tabela 10 - Tabulação cruzada entre mapa digital e convencional considerando até o 3º nível categórico

Unidades	Cxbe	LVd	LVef	NVef	PVd	PVe
TE1+Li2	54.6	0.0	15.3	37.2	0.0	5.4
LE1+LE2	162.4	2668.2	418.6	63.5	806.7	602.4
LE2+LE1	5.3	196.8	1.7	1.2	63.5	54.6
LE2	126.2	368.4	51.5	107.7	96.7	313.2
LV2+LE1	10.5	1019.6	5.7	0.3	112.9	4.9
LV2+LV3	0.0	23.1	0.0	0.0	1.0	0.0
LV4	0.0	28.9	0.0	0.0	0.0	0.0
LE3	24.6	108.8	97.3	10.7	48.1	138.5
LE3+LRd+TE2	74.6	18.4	20.7	56.5	49.7	163.7
LRd+LE3+TE2	473.1	52.1	279.0	913.9	17.8	317.7
LRe+LRd	37.3	19.2	10.0	90.1	2.6	41.0
TE1	80.2	3.1	7.2	94.0	1.2	12.6
TE1+TE2	7.0	0.7	0.1	5.1	0.0	11.2
TE2+TE1	109.8	2.8	45.9	31.8	0.3	14.0
PV1	5.8	4.5	1.3	8.8	0.0	15.2
PV3	4.9	64.9	14.7	0.0	29.8	5.2
Total (ha)	1176.3	4579.5	969.0	1420.8	1230.6	1699.6
Coincidem (ha)	54.6	4451.6	10.0	168.2	0.0	0.0
(%)	4.6%	97.2%	1.0%	11.8%	0.0%	0.0%
Área total mapeada = 11.075,7 ha; Área coincidente = 4.684,4 (42,3%)						

Tabela 11 - Tabulação cruzada entre mapa digital e convencional considerando até o 2º nível categórico mais a textura

Unidades	CX2	LV3	LV2	LV1	NV1	PV4/3	PV3/2
TE1+Li2	54.6	0.0	15.2	0.1	37.2	0.0	5.4
LE1+LE2	162.4	2668.2	412.0	6.6	63.5	806.7	602.4
LE2+LE1	5.3	196.8	0.8	0.9	1.2	63.5	54.6
LE2	126.2	368.4	50.5	1.0	107.7	96.7	313.2
LV2+LE1	10.5	1019.6	5.5	0.2	0.3	112.9	4.9
LV2+LV3	0.0	23.1	0.0	0.0	0.0	1.0	0.0
LV4	0.0	28.9	0.0	0.0	0.0	0.0	0.0
LE3	24.6	108.8	97.0	0.3	10.7	48.1	138.5
LE3+LRd+TE2	74.6	18.4	19.4	1.3	56.5	49.7	163.7
LRd+LE3+TE2	473.1	52.1	275.1	3.9	913.9	17.8	317.7
LRe+LRd	37.3	19.2	9.7	0.3	90.1	2.6	41.0
TE1	80.2	3.1	7.2	0.0	94.0	1.2	12.6
TE1+TE2	7.0	0.7	0.1	0.0	5.1	0.0	11.2
TE2+TE1	109.8	2.8	45.8	0.0	31.8	0.3	14.0
PV1	5.8	4.5	1.0	0.3	8.8	0.0	15.2
PV3	4.9	64.9	14.7	0.0	0.0	29.8	5.2
Total (ha)	1176.3	4579.5	954.1	14.8	1420.8	1230.6	1699.6
Coincidem (ha)	54.6	4253.0	391.5	5.5	1138.6	0.0	0.0
(%)	4.6%	92.9%	41.0%	37.2%	80.1%	0.0%	0.0%
Área total mapeada = 11.075,7 ha; Área coincidente = 5.843,3 ha (52,8%)							

As menores concordâncias espaciais foram obtidas nas unidades: PV (0,0%) e CX (4,6%), contemplando o 2º nível categórico; PVd e PVe (0,0%), LVe (1,0%), CXbe (4,6%) e NVef (11,8%) para o 3º nível; e, CX2 (4,6%), PV4/3 e PV3/2 (0,0%) no 2º nível categórico mais a textura. Nota-se que para os pixels classificados com Argissolos, não houve correspondência entre os mapas digital e convencional e que essa classe foi mapeada, principalmente, em locais correspondentes aos LE1 e LE2 (Latosolos de textura média). O menor detalhamento apresentado na abordagem convencional, aliado à aparente semelhança de ocorrência na paisagem dos Argissolos e Latossolos de textura média na região, pode explicar parte da discordância encontrada.

Já para os Cambissolos, a reduzida concordância foi devido à RNA classificar praticamente todos os leitos de rios e riachos como pertencente a esta classe, aumentando sua representatividade na região e diminuindo o percentual de concordância com a unidade mapeada sob o método convencional (TE1+Li2).

As unidades LVe e NVef só não exibiram maiores percentuais pelo fato de exibir o caráter eutroférico e não eutrófico. Ficou evidente, observando os resultados para essas duas unidades, que a estratégia aplicada nessa região apresentou as menores concordâncias quando se buscou correspondência entre a parte química dos solos. Nesse sentido, acredita-se que o maior detalhamento da abordagem convencional poderia elucidar melhor essa questão da extrapolação do caráter químico dos solos feita por uma classificação supervisionada.

Nas comparações estabelecidas até o 2º nível categórico, valores acima de 50% foram obtidos para a área total coincidente, sendo que a maior parte dos erros de concordância ocorreu entre classes de solos com características semelhantes. Os Latossolos Vermelhos se equivaleram espacialmente em 96,2% da área, enquanto que para os Nitossolos Vermelhos esse valor foi de 80,1%. A maior parte dos Latossolos de textura argilosa, LV2 (412 dos 954 ha) (Tabela 11), foi identificada como pertencentes à unidade LE1+LE2, diminuindo o percentual de concordância. Porém, quando analisada sua ocorrência no mapa digital, tais Latossolos argilosos mostraram grande coerência com sua posição na paisagem, localizados entre Latossolos de textura média à montante e Nitossolos muito argilosos à jusante.

Apesar de grande parte da concordância dos Nitossolos (80,1%) ser proveniente de unidades de mapeamento com associações, analisando a

classificação desses solos no mapa digital constatou-se coerência do resultado obtido devido: ocorrerem nas maiores declividades e nas menores altitudes, locais com maior dessecamento da cobertura arenítica pela drenagem e, por isso, maior proximidade e contribuição do basalto sobrejacente. Dos 19,9% dos Nitossolos não condizentes espacialmente com as unidades TE1 e TE2 do mapa convencional, 6,3% ocorreram em área de Latossolo Roxo e 12,0% em locais com Latossolos de textura média, situando estas duas últimas unidades próximas dos limites para os Nitossolos mapeados.

A comparação realizada espacialmente apresentou algumas limitações como: confrontar mapas com nível de detalhamento diferente; apresentar muitas associações no mapa convencional; não expressar caráter validativo; ser subjetivo, uma vez que a maior parte das informações nos mapas são geradas por extrapolações de informações pontuais. Sendo assim, com o objetivo de validar o MDS2, o resultado da comparação entre as informações do mapa digital e 22 pontos de referências coletados e classificados até o 2º nível categórico mais a textura são apresentados na Tabela 12. A localização destes pontos pode ser visualizada no Anexo M.

Tabela 12 - Validação pontual do MDS2

Id ⁽¹⁾	Campo	Digital	V/F ⁽²⁾	Id	Campo	Digital	V/F
1	NV1	NV1	V	12	LV3	LV3	V
2	LV3	LV3	V	13	PV4/3	PV4/3	V
3	LV3	LV3	V	14	LV3	LV3	V
4	NV1	NV1	V	15	NV1	NV1	V
5	LV3	LV3	V	16	NV1	PV3/2	F
6	LV3	LV3	V	17	PV3/2	PV3/2	V
7	LV2	PV3/2	F	18	NV1	NV1	V
8	LV3	LV3	V	19	LV3	LV3	V
9	LV3	PV4/3	F	20	NV1	NV1	V
10	LVA3	PV3/2	F	21	LV3	LV3	V
11	LV3	LV3	V	22	NV1	NV1	V

⁽¹⁾ identificação da amostra; ⁽²⁾ classificação verdadeiro-falsa

O percentual de concordância entre os pontos de referências e a classificação do mapa digital de solos foi de 81,8%, sendo que 18 amostras foram classificadas como verdadeiras e quatro como falsas. Os pontos 7 e 9 apresentaram falsa concordância, indicando a possível confusão feita pela rede neural na

diferenciação entre Latossolos e Argissolos, devido essas duas classes se apresentarem em condições similares de relevo na região de estudo.

O desempenho da validação mostrou-se superior ao obtido na primeira estratégia do presente trabalho (72,7%) e aos trabalhos de Chagas et al. (2007) com 70,8% e Zhu (2000) com 77%, citados anteriormente na estratégia 1. Uma vez que as variáveis ambientais foram as mesmas em ambas as estratégias, presumiu-se que a melhora obtida na concordância para a estratégia 2 foi devido, principalmente, ao maior número de informações de solo para identificação das unidades de mapeamento na área chave. Como estas definiram o aprendizado das redes neurais pela relação entre unidades mapeadas e variáveis ambientais, a maior precisão no delineamento das unidades reduziu incoerências entre ocorrência natural do solo e a predição no mapa digital. Assim, o mapa digital de solos elaborado a partir de unidades de mapeamento de um levantamento pedológico de nível detalhado apresentou maiores correspondências com a verdade de campo, quando comparado à estratégia baseada em um mapa de solos de nível semidetalhado.

5 CONCLUSÕES

Os atributos do terreno elevação e declividade apresentaram comportamento mais heterogêneo entre as variáveis ambientais analisadas, resultando em maior contribuição na distinção entre as classes de solos. A variável superfície geomórfica, que expressou o fator de formação dos solos “tempo”, revelou grande potencial de uso para mapeamento digital de solos.

O comportamento semelhante das variáveis ambientais observadas nos Latossolos e Argissolos, na região estudada, dificultou a separação dessas classes pela técnica de MDS empregada. A mesma dificuldade foi constatada no campo, já que esses solos ocorreram em condições de relevo muito parecidas e tem transição gradual.

O padrão de ocorrência dos solos nas áreas chaves, mapeadas de forma convencional, foi observado em toda a região quando se analisou a classificação e espacialização dos solos nos mapas digitais. O estudo relatou que técnicas digitais na elaboração de mapas de solos podem apresentar resultados compatíveis com a ocorrência natural dos solos na paisagem.

O nível de detalhamento dos levantamentos pedológicos convencionais refletiu no desempenho dos mapas digitais. O maior número de informações obtidos no estabelecimento de limites entre unidades de mapeamento resultou em maior correspondência entre a classificação digital e a ocorrência natural dos solos.

A generalização do conhecimento adquirido pelas redes neurais, a partir de áreas chaves, para áreas adjacentes, e com uso de variáveis ambientais que expressaram a relação solo-paisagem, gerou resultados coerentes com a realidade de campo. Com isso, unidades de mapeamento foram obtidas em locais não visitados, servindo como dados preliminares para atividades que demandam esse tipo de informação. A abordagem torna-se interessante por permitir que com um grupo de informações de um dado local obtenham-se informações de solos em áreas vizinhas, sem necessidade de custos adicionais e atividades de campo.

REFERÊNCIAS

ALMEIDA, C.L.F. de; OLIVEIRA, J.B. de; PRADO, H. do. Levantamento pedológico semidetalhado do Estado de São Paulo: quadrícula de Brotas. I. Mapas de solos. Campinas: Instituto Agrônômico, 1981a. Mapa. Escala 1:100.000

ALMEIDA, C.L.F. de; OLIVEIRA, J.B. de; PRADO, H. do. Levantamento pedológico semidetalhado do Estado de São Paulo: quadrícula de Jaú. I. Mapas de solos. Campinas: Instituto Agrônômico, 1981b. Mapa. Escala 1:100.000

ATKINSON, P.M.; TATNALL, A.R.L. Neural networks in remote sensing. **International Journal of Remote Sensing**, Oxon, v.18, n. 4, p.699-709, 1997.

BEZDEK, J.C; EHRLICH, R.; FULL, W. The fuzzy c-means clustering algorithm. **Computers & Geosciences**, Oxford, v. 10, n. 2, p. 191-203, 1984.

BLASZCZYNSKI, J.S. Landform characterization with geographic information Systems. **Photogrammetric Engineering and Remote Sensing**, Bethesda, v.3, n. 2, p. 183-191, 1997.

BRAGA, A.P.; CARVALHO, A.C.P.L.F.; LUDERMIR, T.B. **Fundamentos de redes neurais artificiais**. Rio de Janeiro: IX Escola Brasileira de Computação, 1998. v.1. 245 p.

BROWN, W.M.; GEDEON, T.D.; GROVES, D.I.; BARNES, R. G. Artificial neural networks: a new method for mineral prospectivity mapping. **Australian Journal of Earth Sciences**, Nedlands, v.47, n. 4, p. 757-770,2000.

BUI, E.N. Soil survey as a knowledge system. **Geoderma**, Amsterdam, v.120, n. 2, p. 17-26, 2004.

CAMARGO, A.O.; MONIZ, A.C.; JORGE, J.A.; VALADARES, J.M. **Métodos de análise química, mineralógica e física de solos do IAC**. Campinas: Instituto Agrônômico, 1986. 94p. (IAC. Boletim Técnico, 106).

CAMPOS, M.C.C.; MARQUES JÚNIOR, J.;PEREIRA, G.T. Influência das superfícies geomórficas na distribuição espacial dos atributos do solo em área sob cultivo de cana-de-açúcar. **Pesquisa Agropecuária Tropical**, Goiânia, v. 40, n. 2, p. 133-141, abr./jun. 2010.

CAMPOS, M.C.C.; MARQUES JÚNIOR, J.; PEREIRA, G.T.; MONTANARI, R.; CAMARGO, L.A. Relações solo-paisagem em uma litossequência arenito-basalto na região de Pereira Barreto, SP. **Revista Brasileira de Ciência do Solo**, Viçosa, v.31, n. 3, p. 519-529, 2007.

CAMPOS, R.C.; DEMATTÊ, J.A.M.; QUARTAROLI, C.F. Determinação indireta do teor de hematita no solo a partir de dados de colorimetria e radiometria. **Pesquisa Agropecuária Brasileira**, Brasília, v. 38, n. 4, p. 521- 528, 2003.

CARVALHO JUNIOR, W. **Classificação supervisionada de pedopaisagens do domínio dos mares de morros utilizando redes neurais artificiais**. 2005. 143p. Tese (Doutorado em Solos e Nutrição de Plantas) - Universidade Federal de Viçosa, Viçosa, 2005.

CHAGAS, C.S.; CARVALHO JÚNIOR, W. de; BHERING, S.B. Integração de dados dos quickbird e atributos do terreno no mapeamento digital de solos por redes neurais artificiais. **Revista Brasileira de Ciência do Solo**, Viçosa, v.35, p. 693-704, 2011.

CHAGAS, C.S.; FERNANDES FILHO, E.I.; VIEIRA, C.A.O.; SCHAEFER, C.E.G.R.; CARVALHO JÚNIOR, W. de. Atributos topográficos e dados do Landsat7 no mapeamento digital de solos com uso de redes neurais. **Pesquisa Agropecuária Brasileira**, Brasília, v.45, n.5, p.497-507, 2010.

CHAGAS, C. da S.; FERNANDES FILHO, E.I.; VIEIRA, C.A.O.; CARVALHO JÚNIOR, W. Utilização de redes neurais artificiais para predição de classes de solo em uma bacia hidrográfica no Domínio de Mar de Morros. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007. Florianópolis. **Anais...** Florianópolis: INPE. Brasil, 21-26 abril, 2007. p. 2421-2428.

CHAGAS, C.S. **Mapeamento digital de solos por correlação ambiental e redes neurais em uma bacia hidrográfica no domínio de mar de morros**. 2006. 223p. Tese (Doutorado em Solos e Nutrição de Plantas) - Universidade Federal de Viçosa, Viçosa, 2006.

COELHO, F.F. **Comparação de métodos de mapeamento digital de solos através de variáveis geomorfométricas e sistemas de informações geográficas**. 2010. 80p. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.

COELHO, R.M.; LEPSCH, I.F.; MENK, J.F. Relações solo-relevo em uma encosta com transição arenito-basalto em Jaú (SP). **Revista Brasileira de Ciência do Solo**, Viçosa, v. 18, p.125-137, 1994.

CONGALTON, R.G.; GREEN, K. **Assessing the accuracy of remotely sensed data: principle and practices**. New York: Lewis Publishers, 1999. 137p.

COOPER M.; VIDAL-TORRADO, P. Caracterização morfológica, micromorfológica e físico-hídrica de solos com horizonte B nítico. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 29, p. 581-595, 2005.

CRIVELANTI, R.C.; COELHO, R.M.; ADAMI, S.F.; OLIVEIRA, S.R.M. Mineração de dados para inferência de relações solo-paisagem em mapeamentos digitais de solo. **Pesquisa Agropecuária Brasileira**, Brasília, v.44, n. 12, p.1707-1715, 2009.

CUNHA, P.; MARQUES JÚNIOR, J.; CURI, N.; PEREIRA, G.T.; LEPSCH, I.F. Superfícies geomórficas e atributos de Latossolos em uma seqüência arenítico-basáltica da região de Jaboticabal (SP). **Revista Brasileira de Ciência do Solo**, Viçosa, v. 29, n. 1, p.81-90, 2005.

DANIELS, R.B.; GAMBLE, E.F.; CADY, J.G. The relation between geomorphology and soil morphology and genesis. In: N.C. Brady. **Advances in Agronomy**, New York, v.23, p. 51-87, 1971.

DEBELLA-GILO, M.; ETZELMÜLLER, B. Spatial prediction of soil classes using digital terrain analysis and multinomial logistic regression modeling integrated in GIS: Examples from Vestfold County, Norway. **CATENA**, Amsterdam, v. 77, p. 8-18, 2009.

DIMITRIADOU, E.; HORNIK, K.; LEISCH, F.; MEYER, D.; WEINGESSEL, A.: **e1071: Misc Functions of the Department of Statistics (e1071)**, TU Wien, r package version 1.5-18, 2008. Disponível em: <<http://cran.r-project.org/web/packages/e1071/index.html>> Acesso em: 23 maio 2011.

DOYLE, F.J. Digital terrain models: an overview. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v.44, n.12, p.1481-1485, 1978.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA. **Sistema brasileiro de classificação de solos**. Brasília, Serviço de Produção de Informação, 1999. 412p

_____. **Sistema brasileiro de classificação de solos**. 2 ed. Rio de Janeiro: EMBRAPA Solos, 2006. 306p.

ESRI, ArcGIS Desktop Developer Guide ArcGIS 9. ESRI Press, Redlands, California.2006. 1 CD-ROM.

FIGUEREDO, S.R.; GIASSON, E.; TORNQUIST, C.G.; NASCIMENTO, P.C. Uso de regressões logísticas múltiplas para mapeamento digital de solos no planalto médio do RS. **Revista Brasileira de Ciência do Solo**, Viçosa, v.32, n. especial, p. 2779-2785, 2008.

FIORIO, P.R.; DEMATTÊ, J.A.M.; FORMAGGIO, A.R.; EPIPHANIO, J.C.N. Geoprocessamento e topossequências na determinação de levantamentos de solos em diferentes escalas. **Magistra**, Cruz das Almas, v. 15, n. 2, p. 173-185,2003.

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**, Oxon, v.18, n. 4, p.799-810, 1997.

GERRARD, J. Soil geomorphology - present dilemmas and future challenges. **Geomorphology**, Amsterdam, v.7, n. 1, p. 61-84, 1993.

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

HALL, G.F. Pedology and geomorphology. In: WILDING, L.P.; SMECK, N.E.; HALL, G.F. **Pedogenesis and Soil Taxonomy: The Soil Orders (Developments in Soil Science)**. New York: Elsevier, v.11b, p.118-140, 1983.

HANSEN, M.K.; BROWN, D.J.; DENNISON, P.E.; GRAVES, S.A.; BRICKLEMYER, R.S. Inductively mapping expert-derived soil-landscape units within dambowetle CATENA, AMSTERDAM, e using multispectral and topographic data. **Geoderma**, Amsterdam, v. 150, p. 72-84, 2009.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. New York: Macmillan College Publishing; Prentice Hall, 1994. 716p.

HIROSE, Y.; YAMASHITA, K.; HIJIYA, S. Back-propagation algorithm which varies the number of hidden units. **Neural Networks**, Washington, v. 4, n. 1, p.61-66, 1991.

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

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

INSTITUTO DE PESQUISAS TECNOLÓGICAS DO ESTADO DE SÃO PAULO.
Mapa Geológico do Estado de São Paulo. Escala - 1:500.000. São Paulo, ITP,
 1981a.v.1. 126p

IPPOLITI, R.G.A.; COSTA, L.M.; SCHAEFER, C.E.G.R.; FILHO, E.I.F.; AGGERO,
 M.R.; SOUZA, E. Análise digital de terreno: Ferramenta na identificação de
 pedoformas em microbacia na região de “mar de morros” (MG). **Revista Brasileira
 de Ciência do Solo**, Viçosa, v. 29, n. 2, p. 269-276, 2005.

JENNY, H. **Factors of soil formation:** a system of quantitative pedology. New York:
 McGraw-Hill, 1941. 1v.

KISS, R. Determination of drainage network in digital elevation model, utilities and
 limitations. **Journal of Hungarian Geomathematics**, Budapest, v.2, p. 16-29, 2004.

LEPSCH, I.F.; BUOL, S.W.; DANIELS, R.B. Soil-landscape relationships in the
 Occidental Plateau of São Paulo State, Brazil: I. Geomorphic surfaces and soil
 mapping units. **Soil Science Society of America Journal**, London, v.41, p.104-109,
 1977.

MARQUES JÚNIOR, J.; LEPSCH, I.F. Depósitos superficiais neoceno-zóicos,
 superfícies geomórficas e solos em Monte Alto, SP. **Geociências**, São Paulo, v.19,
 n. 1, p.90-106, 2000.

MASTER, T. **Practical neural network recipes in C++.** San Diego, California:
 Academic, 1993. 493p.

McBRATNEY, A.B.; MENDONÇA-SANTOS, M.L.; MINASNYA, B. On digital soil
 mapping. **Geoderma**, Amsterdam, v.117, p. 3-52, 2003.

MOORE, I.D.; GESSLER, P.E.; NIELSEN, G.A.; PETERSON, G. Soil attribute
 prediction using terrain analysis. **Soil Science Society of American Journal**,
 London, v.57, p. 443-452, 1993.

MOTTA, P.E.F. da; CARVALHO FILHO, A. de; KER, J.C.; PEREIRA, N.R.;
 CARVALHO JUNIOR, W. de; BLANCANEUX, P. Relações solo-superfície
 geomórfica e evolução da paisagem em uma área do planalto central brasileiro.
Pesquisa Agropecuária Brasileira, Brasília, v.37, n.6, p. 869-878, jun.2002.

MULLA, D.J.; McBRATNEY, A.B. Soil spatial variability. In: SUMMER, M.E.
Handbook of soil science. New York, 1999. p. A321-A351.

NUNES, T.V.L. **Método de previsão de defeitos em estradas vicinais de terra com base no uso das redes neurais artificiais: trecho de Aquiraz – CE.** 2003. 118p. Dissertação (Mestrado em Engenharia de Transportes) - Universidade Federal do Ceará, Fortaleza, 2003.

OLIVEIRA, V.A. O Brasil carece de novos pedólogos. **Boletim Informativo**, Viçosa , v.25,n. 4, p. 25-28, out./dez. 1999.

R DEVELOPMENT CORE TEAM: R: A Language and Environment for Statistical Computing, R Foundation for Statistical Computing, Vienna, 2008. Acesso em: <<http://www.R-project.org>, ISBN 3- 900051-07-0>. Acesso em: 23 maio. 2011.

RAIA JR., A.A. **Acessibilidade e Mobilidade na Estimativa de um Índice de Potencial de Viagens Utilizando Redes Neurais Artificiais e Sistemas de Informação Geográfica.** 2000. 196p. Tese (Doutorado em Engenharia Civil) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2000.

RAIJ, B. van.; ANDRADE, J.C.; CANTARELA, H.; QUAGGIO, J.A. **Análise química para avaliação de solos tropicais.** Campinas: IAC, 2001. 285p.

REUSSER, D.T. **Analysing time series of grouped errors, r package version 0.1, 2009.** Disponível em: <<http://cran.r-project.org/web/packages/tiger/index.html>> Acesso em: 23 maio. 2011.

RIZZO, R. **Técnicas espectroscópicas e atributos do terreno no mapeamento digital de solos.** 2011. 171p. Dissertação (Mestrado em Agronomia) - Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2011.

RODRIGUES, T.E.; KLAMT, E. Mineralogia e gênese de uma seqüência de solos do Distrito Federal. **Revista Brasileira de Ciência do Solo**, Viçosa, v.2, p.132-139, 1978.

RUHE, R.V. **Quaternary landscape in Iowa.** Ames; Iowa State University Press, 1969. 255p.

SANCHEZ, R.B.; MARQUES JÚNIOR, J.; SOUZA, Z.M. de; PEREIRA, G.T.; MARTINS FILHO, M.V. Variabilidade espacial de atributos do solo e de fatores de erosão em diferentes pedoformas. **Bragantia**, Campinas, v.68, n.4, p.1095-1103, 2009.

SCHMIDT, K.; BEHRENS, T.; SCHOLTEN, T. Instance selection and classification tree analysis for large spatial datasets in digital soil mapping. **Geoderma**, Amsterdam, v.146, p.138-146, 2008.

SIRTOLI, A.E. **Mapeamento de solos com auxílio da geologia, atributos do terreno e índices espectrais integrados por redes neurais artificiais**. 2008. 102p. Tese (Doutorado em Geologia) - Universidade Federal do Paraná, Curitiba, 2008.

SIRTOLI, A.E.; SILVEIRA, C.T. da; MANTOVANI, L.E.; SIRTOLI, A.R.A.; OKAFIORI, C. Atributos do relevo derivados de modelo digital de elevação e suas relações com solos. **Scientia Agraria**, Curitiba, v.9, n.3, p.317-329, 2008.

SOUZA, E.C.B.de. **Modelagem do relevo oceânico usando redes neurais artificiais**. 2006. 208p. Tese (Doutorado em Ciências Geodésicas) - Universidade Federal do Paraná, Curitiba, 2006.

SOUZA JUNIOR, J.G.A; DEMATTÊ, J.A.M. Modelo digital de elevação na caracterização de solos desenvolvidos de basalto e material arenítico. **Revista Brasileira de Ciência do Solo**, Viçosa, v.32, p. 449-456, 2008.

TANSCHKEIT, R. **Fundamentos da lógica Fuzzy e controle Fuzzy**. Disponível em: <http://tcs.eng.br/PUC/Fuzzy/SI-Logica_Control_Fuzzy.pdf>. Acesso em: 02 jul. 2011.

TEN CATEN, A.; DALMOLIN, R.S.D.; PEDRON, F.A.; QUOOS, J.H. Mapeamento digital: probabilidade associada à distribuição espacial de classes de solos. **Geomática**, Santa Maria, v.4, n. 2, p. 87-97, 2009.

TERAMOTO, E.R.; LEPSCH, I.F.; VIDAL-TORRADO, P. Relações solo, superfície geomórfica e substrato geológico na microbacia do ribeirão Marins (Piracicaba-SP). **Scientia Agrícola**, Piracicaba, v.58, n. 2, p. 361-371, 2001

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**, Amsterdam, v.90, n. 3, p.291-305, 1999.

VICENTE, P.P.B. **Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais**. Porto Alegre: Ed. Universidade; UFRGS/ABRH, 1999. 246p.

VIDAL-TORRADO, P. **Pedogênese e morfogênese no distrito de Tupi (Piracicaba, SP)**. 1994. 212p. (Tese de Doutorado em Agronomia) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, - Piracicaba, 1994.

VIEIRA, C.A.O. **Accuracy of remotely sensing classification of agricultural crops: a comparative study**. 2000. 327p. (PhD Thesis) - University of Nottingham, Nottingham, UK, 2000.

XIE, X.; BENI, G.: A validity measure for fuzzy clustering, **IEEE T. Pattern analysis and applications**, London, v. 13, p.841-847, 1991.

WOLOCK, D. Simulating the variable-source-area concept of stream flow generation with the watershed mode TOPMODEL. **Water-Resources Report**, USGS, 1993.

ZELL, A.; MAMIER, G.; VOGT, M.; MACHE, N.; HÜBNER, R.; DÖRING, S.; HERRMANN, K.; SOYEZ, T.; SCHMALZL, M.; SOMMER, T.; HATZIGEORGIU, A.; POSSELT, D.; SCHREINER, T.; KETT, B.; CLEMENTE, G.; WIELAND, J.; GATTER, J. **Stuttgart Neural Network Simulator v4.2**. Stuttgart, 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. 338p

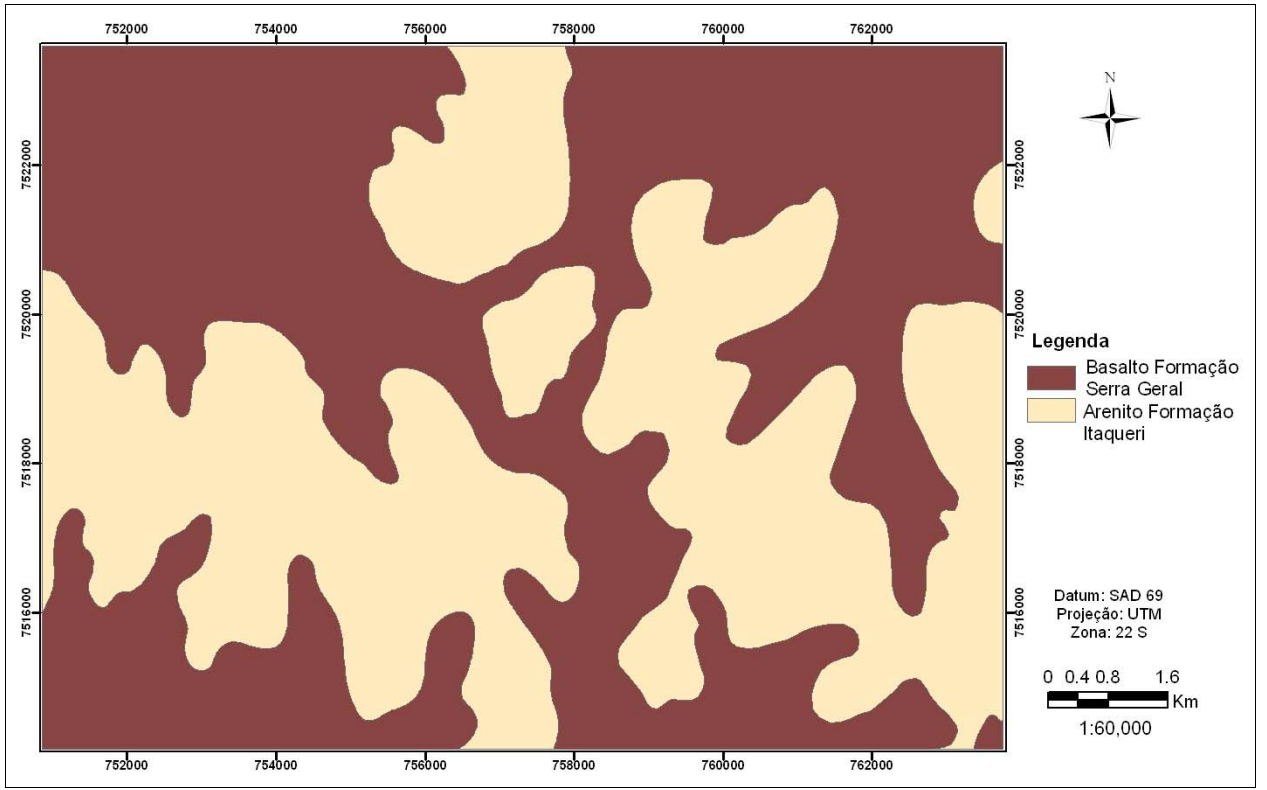
ZHU, A.X.; HUDSON, B.; BURT, J.; LUBICH, K.; SIMONSON, D. Soil Mapping Using GIS, Expert Knowledge, and Fuzzy Logic. **Soil Science Society American Journal**, London, v.65, p.1463-1472, 2001.

ZHU, A.X. A similarity model for representing soil spatial information. **Geoderma**, Amsterdam, v.77, n. 2, p.217-242, 1997.

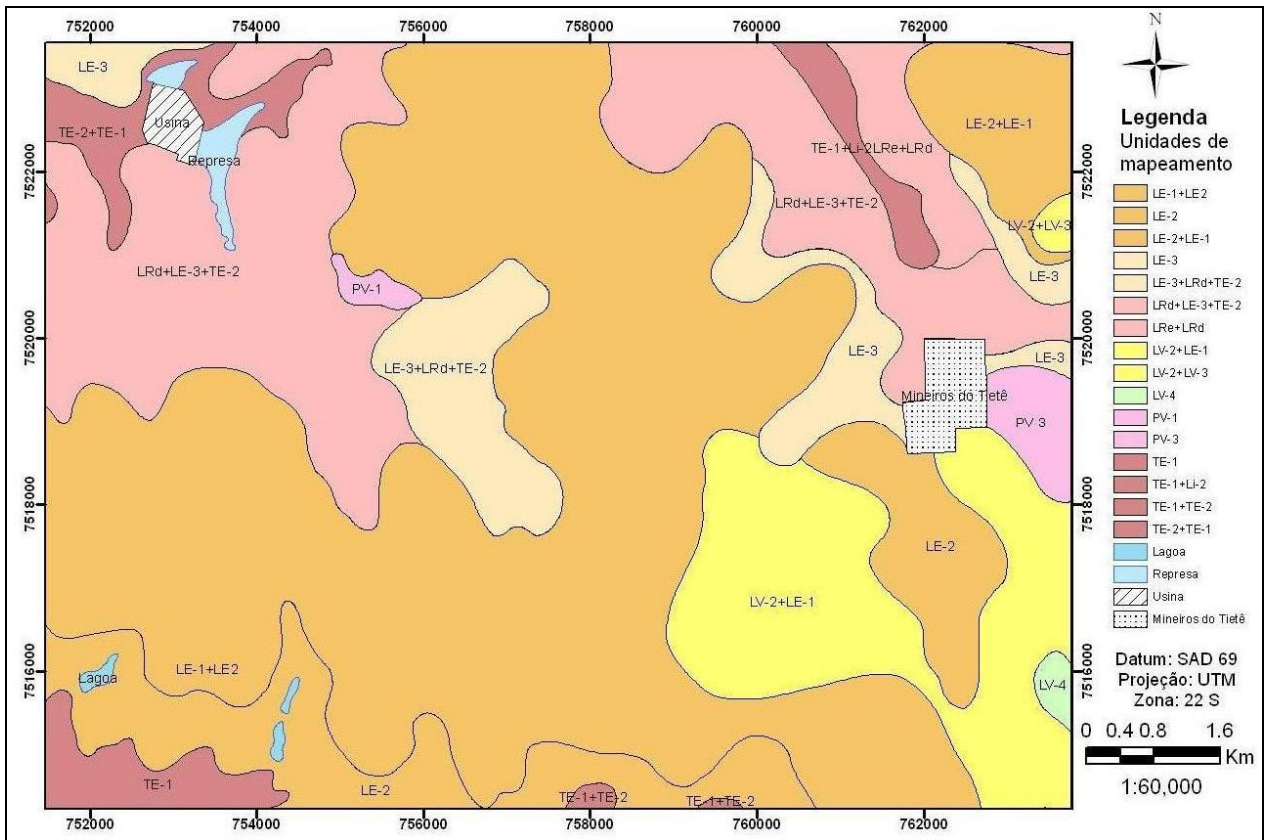
_____. Mapping soil landscape as spatial continua: the neural network approach. **Water Resources Research**, Washington, v.36, n. 3, p. 663-677, 2000.

ANEXOS

ANEXO A



ANEXO B



ANEXO C - Matriz de significância de Kappa para o conjunto TV alterando o número de neurônios na camada interna (Estratégia 1)

Redes	R1 ^a	R3	R5	R7	R9	R11	R13	R15
Exatidão global	50,8	68,8	69,1	69,6	66,5	77,5	70,2	68,4
Kappa	0,45	0,65	0,65	0,66	0,62	0,75	0,66	0,64
Variância ^b	0,300	0,285	0,287	0,285	0,293	0,024	0,284	0,285
R1	25,87							
R3	8,14*	38,21						
R5	8,29*	0,17	38,31					
R7	8,55*	0,42	0,25	38,80				
R9	7,06*	1,04	1,20	1,46	36,22			
R11	12,78*	4,36*	4,18*	3,92*	5,41*	48,09		
R13	8,81*	0,67	0,50	0,25	1,71	3,67*	39,22	
R15	8,06*	0,08	0,25	0,53	0,95	4,45*	0,75	38,08

. * existe diferença significativa ao nível de 95%; ^arede neural com 1 neurônio na camada interna. ^b valores multiplicados por 1000.

ANEXO D

2° Nível Categórico

UNIDADE	CX	LV	NV	PV
TE-1+Li-2	68,0	1,0	40,7	3,0
LE-1+LE2	358,6	2824,4	89,8	1449,0
LE-2+LE-1	19,9	114,8	12,6	175,9
LE-2	187,4	230,3	44,7	601,3
LV-2+LE-1	36,2	1035,4	2,5	79,9
LV-2+LV-3	0,3	23,7	0,0	0,2
LV-4	0,1	27,1	0,0	1,7
LE-3	101,2	36,9	34,4	255,4
LE-3+LRd+TE-2	99,4	19,0	66,4	198,7
LRd+LE-3+TE-2	844,2	167,8	604,7	437,0
LRe+LRd	63,3	14,6	63,6	58,8
TE-1	100,6	4,6	51,2	41,9
TE-1+TE-2	7,2	0,3	2,8	13,8
TE-2+TE-1	130,2	3,6	69,2	1,6
PV-1	7,0	6,4	4,6	17,7
PV-3	9,4	79,9	0,8	29,4
Total (ha)	2032,9	4589,6	1087,9	3365,2
Coincidem (ha)	68,0	4443,2	835,0	0,0
(%)	3,3%	96,8%	76,8%	0,0%
Área total mapeada = 11.075,72 ha; Área coincidente = 5.346,1 ha (49,2%)				

ANEXO E

3° Nível Categórico

UNIDADE	CXe	LVd	LVe	NVe	PVe
TE-1+Li-2	68,0	0,3	0,6	40,7	3,0
LE-1+LE2	358,6	2120,2	704,2	89,8	1449,0
LE-2+LE-1	19,9	7,0	107,8	12,6	175,9
LE-2	187,4	127,3	103,0	44,7	601,3
LV-2+LE-1	36,2	763,0	272,4	2,5	79,9
LV-2+LV-3	0,3	18,5	5,2	0,0	0,2
LV-4	0,1	14,8	12,4	0,0	1,7
LE-3	101,2	15,5	21,4	34,4	255,4
LE-3+LRd+TE-2	99,4	10,5	8,5	66,4	198,7
LRd+LE-3+TE-2	844,2	53,1	114,7	604,7	437,0
LRd+LRd	63,3	2,0	12,6	63,6	58,8
TE-1	100,6	1,9	2,6	51,2	41,9
TE-1+TE-2	7,2	0,0	0,2	2,8	13,8
TE-2+TE-1	130,2	1,4	2,2	69,2	1,6
PV-1	7,0	0,9	5,5	4,6	17,7
PV-3	9,4	77,4	2,5	0,8	29,4
Total (ha)	2032,9	3213,7	1376,0	1087,9	3365,2
Coincidem (ha)	68,0	3096,5	12,6	163,9	0,0
(%)	3,3%	96,4%	0,9%	15,1%	0,0%
Área total mapeada = 11.075,7 ha; Área coincidente = 3.457,4 ha (38,0%)					

ANEXO F

2º Nível Categórico + Textura

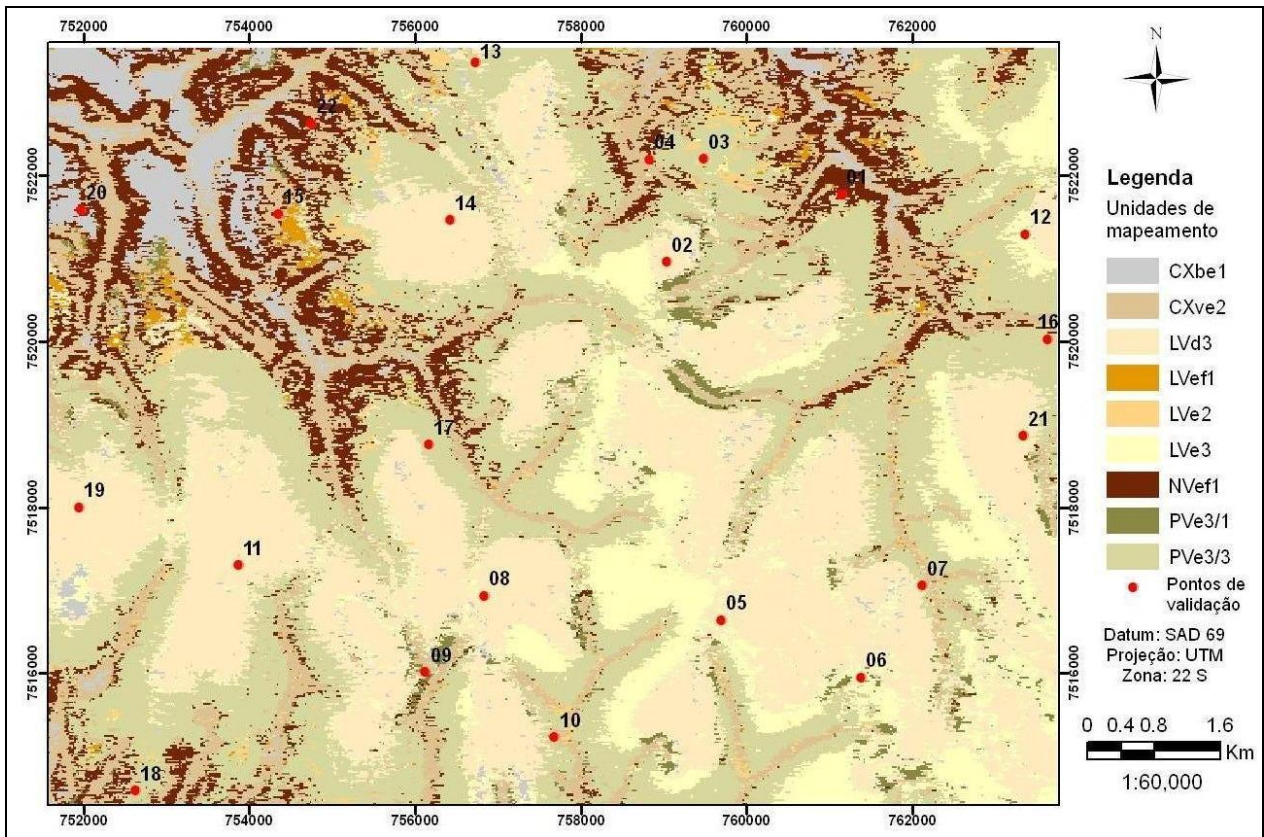
UNIDADE	CX2	CX1	LV3	LV2	LV1	NV1	PV3/3	PV3/1
TE-1+Li-2	42,1	25,9	0,3	0,0	0,6	40,7	2,0	1,0
LE-1+LE2	297,5	61,0	2756,1	62,4	5,9	89,8	1345,4	103,6
LE-2+LE-1	19,8	0,0	101,2	13,0	0,6	12,6	175,1	0,8
LE-2	177,6	9,8	196,2	29,7	4,5	44,7	584,8	16,5
LV-2+LE-1	27,3	8,9	1030,9	4,1	0,4	2,5	56,7	23,2
LV-2+LV-3	0,0	0,3	23,7	0,0	0,0	0,0	0,1	0,1
LV-4	0,0	0,1	27,1	0,0	0,0	0,0	0,0	1,7
LE-3	49,4	51,8	28,1	8,1	0,6	34,4	253,7	1,7
LE-3+LRd+TE-2	94,7	4,8	10,8	4,8	3,4	66,4	196,6	2,1
LRd+LE-3+TE-2	615,1	229,0	54,7	40,2	73,0	604,7	407,1	30,0
LRd+LRd	56,4	6,9	2,0	4,9	7,6	63,6	57,8	0,9
TE-1	91,5	9,2	3,0	0,1	1,5	51,2	37,1	4,8
TE-1+TE-2	7,2	0,0	0,0	0,2	0,1	2,8	13,1	0,8
TE-2+TE-1	90,8	39,4	3,3	0,0	0,3	69,2	1,1	0,5
PV-1	6,1	0,8	0,9	2,5	3,0	4,6	17,6	0,0
PV-3	8,5	0,9	79,5	0,2	0,2	0,8	27,6	1,9
Total (ha)	1584,1	448,8	4317,8	170,1	101,7	1087,9	3175,9	189,4
Coincidem (ha)	42,1	0,0	4084,4	53,1	84,0	835,0	0,0	0,0
(%)	2,7%	0,0%	94,6%	31,2%	82,6%	76,8%	0,0%	0,0%

Área total mapeada = 11.075,7 ha; Área coincidente = 5.098,5 ha (46,0%)

ANEXO G- Descrição das unidades ocorrentes no mapa convencional

Unidade	Classificação
LE1	Latossolo Vermelho Escuro álico textura média, Un. Dois Córregos
LE2	Latossolo Vermelho Escuro álico textura média, Un. Hortolândia
LE3	Latossolo Vermelho Escuro álico textura argilosa
Li2	Solos Litólicos eutróficos ou distróficos textura argilosa
LRd	Latossolo Roxo distrófico
LRe	Latossolo Roxo eutrófico
LV2	Latossolo Vermelho Amarelo álico textura média, Un. Coqueiro
LV3	Latossolo Vermelho Amarelo álico textura média, Un. Laranja
LV4	Latossolo Vermelho Amarelo álico textura média, Un. Três Barras
PV1	Podzólico Vermelho Amarelo eutrófico ou álico textura média/argilosa, arenosa/argilosa, arenosa/média
PV3	Podzólico Vermelho Amarelo distrófico textura média ou arenosa/média
TE1	Terra Roxa Estruturada eutrófica ou distrófica textura argilosa ou muito argilosa, Un. Estruturada
TE2	Terra Roxa Estruturada eutrófica ou distrófica textura argilosa ou muito argilosa, Un. Itaguaçu

ANEXO H

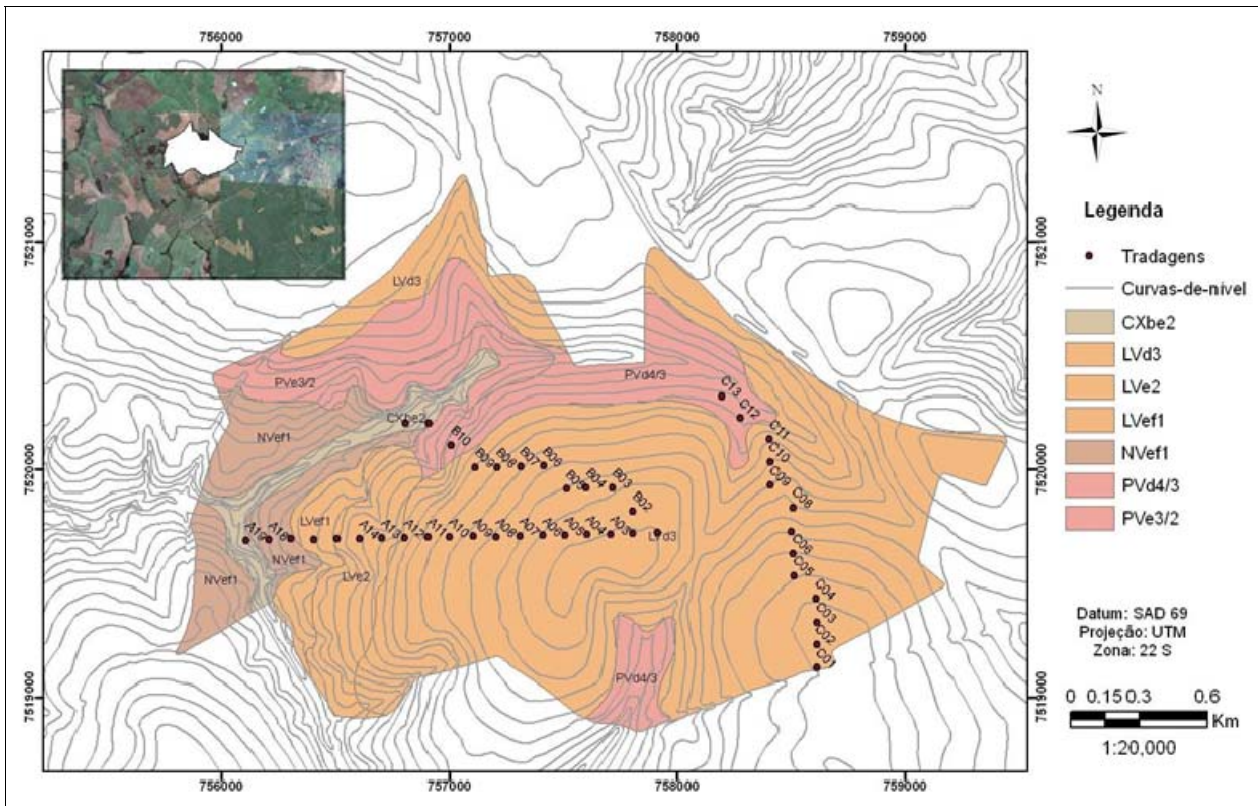


ANEXO I

Ponto	Profundidade ----- cm -----	Solo	Granulometria			Grad	Sil/Arg	Cor - Colorímetro			
			Argila	Silte	Areia			Matiz	Valor	Croma	Conversão*
			----- % -----								
1A	0-20	NV1	56,1	18,6	25,3	1,13	0,33	2,2 YR	3,3	1,7	2.5YR
1B	80-100		63,6	14,8	21,7		0,23	1,8 YR	3,1	1,9	2.5YR
2A	0-20	LV3	12,6	2,4	84,9	1,60	0,19	2,9 YR	3,2	2,1	2.5YR
2B	80-100		20,2	2,7	77,1		0,14	2,0 YR	3,6	2,5	2.5YR
3A	0-20	LV3	17,6	1,8	80,7	1,00	0,10	2,9 YR	3,4	1,9	2.5YR
3B	80-100		17,6	3,3	79,1		0,19	2,0 YR	3,4	2,4	2.5YR
4A	0-20	NV1	55,3	27,2	17,5	1,32	0,49	3,6 YR	3,1	1,7	2.5YR
4B	80-100		73,2	16,7	10,1		0,23	2,7 YR	3,4	2,1	2.5YR
5A	0-20	LV3	17,6	2,6	79,8	0,91	0,15	4,6 YR	3,2	1,5	5YR
5B	80-100		16,0	3,1	80,9		0,19	3,1 YR	3,5	2,5	2.5YR
6A	0-20	LV3	13,8	3,3	82,9	1,17	0,24	4,7 YR	3,4	1,6	5YR
6B	80-100		16,2	1,7	82,1		0,10	2,9 YR	3,6	2,7	2.5YR
7A	0-20	LV2	40,6	6,4	53,1	1,17	0,16	3,7 YR	3,3	1,9	2.5YR
7B	80-100		47,5	7,1	45,4		0,15	3,0 YR	3,6	2,0	2.5YR
8A	0-20	LV3	22,7	5,1	72,1	1,22	0,23	4,6 YR	3,2	1,2	5YR
8B	80-100		27,7	3,5	68,8		0,13	2,6 YR	3,3	2,2	2.5YR
9A	0-20	LV3	22,5	2,4	75,1	1,12	0,11	3,6 YR	3,4	2,1	2.5YR
9B	80-100		25,2	1,2	73,6		0,05	3,2 YR	3,5	2,4	2.5YR
10A	0-20	LVA3	20,1	3,7	76,2	1,25	0,18	4,8 YR	3,3	1,6	5YR
10B	80-100		25,2	3,3	71,6		0,13	4,0 YR	3,3	2,2	5YR
11A	0-20	LV3	17,6	1,7	80,7	1,15	0,10	3,5 YR	3,3	1,9	2.5YR
11B	80-100		20,2	3,4	76,4		0,17	2,0 YR	3,4	2,4	2.5YR
12A	0-20	LV3	20,1	1,3	78,7	1,25	0,06	3,4 YR	3,4	1,9	2.5YR
12B	80-100		25,2	1,5	73,4		0,06	2,2 YR	3,6	2,3	2.5YR
13A	0-20	PV4/3	10,1	3,5	86,5	1,85	0,34	5,0 YR	3,2	1,4	5YR
13B	80-100		18,7	2,3	79,0		0,12	2,9 YR	3,6	2,4	2.5YR
14A	0-20	LV3	10,1	2,8	87,1	1,65	0,28	3,3 YR	3,4	1,9	2.5YR
14B	80-100		16,6	2,0	81,4		0,12	2,3 YR	3,4	2,4	2.5YR
15A	0-20	NV1	60,1	11,3	28,6	1,05	0,19	2,6 YR	3,3	1,9	2.5YR
15B	80-100		63,0	11,2	25,8		0,18	0,4 YR	3,3	1,7	10R
16A	0-20	NV1	50,2	4,1	45,7	1,30	0,08	3,6 YR	3,3	1,7	2.5YR
16B	80-100		65,4	5,5	29,1		0,08	2,7 YR	3,4	2,0	2.5YR
17A	0-20	PV3/2	26,7	4,1	69,3	1,72	0,15	2,5 YR	3,2	1,7	2.5YR
17B	80-100		45,9	7,1	47,0		0,15	2,1 YR	3,2	2,1	2.5YR
18A	0-20	NV1	77,7	8,3	14,0	1,07	0,11	1,9 YR	3,3	1,8	2.5YR
18B	80-100		82,9	9,5	7,6		0,11	1,8 YR	3,4	2,1	2.5YR
19A	0-20	LV3	12,6	3,0	84,5	1,40	0,24	3,7 YR	3,3	1,9	2.5YR
19B	80-100		17,5	3,2	79,3		0,18	2,7 YR	3,5	2,6	2.5YR
20A	0-20	NV1	62,8	12,9	24,3	1,12	0,21	2,4 YR	3,3	1,7	2.5YR
20B	80-100		70,4	12,1	17,5		0,17	1,9 YR	3,3	1,9	2.5YR
21A	0-20	LV3	16,3	4,4	79,3	1,46	0,27	3,2 YR	3,3	1,8	2.5YR
21B	80-100		23,8	3,1	73,1		0,13	2,0 YR	3,5	2,3	2.5YR
22A	0-20	NV1	43,7	15,2	41,1	1,41	0,35	2,3 YR	3,2	1,4	2.5YR
22B	80-100		61,8	9,1	29,1		0,15	2,1 YR	3,3	2,0	2.5YR

*Campos et al. (2003)

ANEXO J



ANEXO K

Ponto	Camada	Solo	Areia	Silte	Argila	pH		MO g.Kg ⁻¹	P ppm	K	Ca	Mg	Al	H	SB	CTC	V %	m	Matiz (YR)	Valor	Croma	Gradiente	Sil/Arg
			Total	H2O	KCl	mmolc.Kg ⁻¹																	
			g.kg ⁻¹																				
Topossequência A																							
A07	A	LVd3	800	20	180	5,6	5,1	1,3	4,0	1,3	13,0	2,0	1,0	7,0	16,3	23,3	70	6					0,11
A07	B		820	20	160	4,4	4,1	1,9	2,0	0,3	4,0	1,0	9,0	19,0	5,3	24,3	22	62,9	1,0	3,7	2,5	0,89	0,13
A14	A	LVe2	610	60	330	5,7	4,9	1,8	10,0	6,9	27,0	13,0	0,0	20,0	46,9	66,9	70	0					0,18
A14	B		390	120	490	5,6	4,8	2,3	2,0	0,1	14,0	6,0	0,0	18,0	20,1	38,1	53	0,0	2,0	3,4	1,8	1,48	0,24
A15	A	LVef1	360	100	540	5,4	4,9	2,0	7,0	5,3	26,0	10,0	0,0	30,0	41,3	71,3	58	0					0,19
A15	B		260	30	710	5,5	4,9	2,3	3,0	1,2	17,0	4,0	0,0	16,0	22,2	38,2	58	0,0	2,2	3,5	1,8	1,31	0,04
A17	A	NVef1	220	180	600	5,4	4,7	2,3	7,0	2,6	35,0	16,0	2,0	32,0	53,6	85,6	63	4					0,30
A17	B		90	130	780	6,0	5,3	2,1	3,0	0,1	40,0	6,0	0,0	13,0	46,1	59,1	78	0,0	1,7	3,4	1,6	1,30	0,17
A19	A	CXbe2	140	170	690	5,5	5,0	2,0	9,0	3,6	42,0	14,0	0,0	21,0	59,6	80,6	74	0					0,25
A19	B		360	280	360	6,2	5,3	1,5	3,0	0,6	33,0	33,0	0,0	6,0	66,6	72,6	92	0,0	3,4	3,8	2,6	0,52	0,78
Topossequência B																							
B06	A	LVd3	800	60	140	5,1	4,6	0,5	4,0	1,4	7,0	4,0	2,0	6,0	12,4	18,4	67	14					0,43
B06	B		840	20	140	4,4	3,8	0,9	3,0	0,7	1,0	1,0	7,0	25,0	2,7	27,7	10	72,2	1,1	3,5	2,2	1,00	0,14
B10	A	PVd4/3	840	60	100	5,1	4,9	1,9	4,0	1,9	11,0	5,0	3,0	20,0	17,9	37,9	47	14					0,60
B10	B		660	60	280	5,4	4,7	0,3	3,0	0,5	15,0	1,0	0,0	20,0	16,5	36,5	45	0,0	2,2	3,9	2,9	2,80	0,21
B11	A	CXbe2	450	130	420	5,4	5,0	1,7	8,0	5,3	35,0	12,0	1,0	39,0	52,3	91,3	57	2					0,31
B11	B		440	80	480	5,4	5,3	0,4	4,0	0,3	22,0	11,0	0,0	8,0	33,3	41,3	81	0,0	2,8	3,6	2,2	1,14	0,17
B12	A	CXbe2	270	300	430	5,3	4,9	1,9	9,0	1,6	44,0	12,0	1,0	37,0	57,6	94,6	61	2					0,70
B12	B		400	60	540	5,4	5,3	0,9	6,0	0,5	42,0	11,0	0,0	8,0	53,5	61,5	87	0,0	1,9	3,4	1,8	1,26	0,11
Topossequência C																							
C09	A	LVd3	840	20	140	5,6	5,0	1,0	10,0	1,4	9,0	4,0	0,0	6,0	14,4	20,4	71	0					0,14
C09	B		800	20	180	4,2	3,9	0,9	2,0	0,7	2,0	1,0	10,0	39,0	3,7	42,7	9	73,0	1,8	3,6	2,4	1,29	0,11
C12	A	PVd4/3	840	40	120	5,3	4,6	0,8	3,0	0,8	10,0	8,0	2,0	1,0	18,8	19,8	95	10					0,33
C12	B		760	20	220	4,7	4,0	0,9	3,0	0,2	12,0	4,0	7,0	40,0	16,2	56,2	29	30,2	3,0	3,7	2,4	1,83	0,09

ANEXO L - Matriz de significância de Kappa para o conjunto TV alterando o número de neurônios na camada interna (Estratégia 2)

Redes	R1 ^a	R3	R5	R7	R9	R11	R13	R15
Exatidão global	72,7	83,7	79,6	68,5	73,2	76,5	70,4	65,7
Kappa	0,68	0,81	0,76	0,63	0,69	0,72	0,65	0,59
Variância ^b	0,430	0,305	0,357	0,453	0,419	0,388	0,435	0,466
R1	32,88							
R3	4.68*	46,32						
R5	2.78*	1,90	40,22					
R7	1,85	6.61*	4.67*	29,45				
R9	0,17	4.53*	2.62*	2.03*	33,56			
R11	1,43	3.26*	1,35	3.31*	1,26	36,7		
R13	1,05	5.80*	3.87*	0,80	1,23	2.51*	31,21	
R15	2.94*	7.74*	5.78*	1,08	3.12*	4.41*	1,89	27,51

* existe diferença significativa ao nível de 95%; ^arede neural com 1 neurônio na camada interna. ^b valores multiplicados por 1000.

ANEXO M

