

Predição de Classes de Solos de Paisagens Montanhosas da Serra do Mar, com o Uso de Redes Neurais Artificiais (RNAs)

Braz Calderano Filho¹
Helena Polivanov²
Cesar da Silva Chagas¹;
Antônio José Teixeira Guerra²
Waldir de Carvalho Júnior¹

¹Embrapa Solos - Rua Jardim Botânico, 1024 - 22460-000
Rio de Janeiro - RJ, Brasil
{braz,chagas, waldircj}@cnps.embrapa.br

²Universidade Federal do Rio de Janeiro - UFRJ - Instituto de Geociências
Av. Athos da Silveira Ramos, 274 –Cidade Universitária, Rio de Janeiro – RJ - 21949-900
polivanov@ig.ufrj.br; antoniotguerra@gmail.com

Abstract:The objective of this study was to apply artificial neural networks for the prediction of soil classes, using as source of data products of orbital remote sensors, information of local geology and attributes of the land derived from a digital elevation model, aiming to evaluate the use of this boarding for execution of the process of generation of soil map, in mountainous areas with varied lithology in Serra do Mar. For the prediction of soil classes were tried different combinations between the selected discriminant variables: elevation, slope angle, aspect, curvature, plan of curvature, profile of curvature, combined topographical index, solar radiation, factor LS, geology and indices derived from an image of sensor ETM+ of the LANDSAT 7, ndvi, clay mineral and iron oxid. The best results were obtained with all the discriminants variables, reaching global exactness between 93,2 and 95,6%, excluding the variable profile of curvature, the reached global exactness oscillated between 93,9 and 95,4%. The maps delineated for the classifier for artificial neural networks, have shown sufficient coherent and similar to the conventional soil map, presenting more space details.

Index terms: artificial neural networks, terrain attributes, classification of soils.

1. Introdução

As inovações tecnológicas das últimas décadas propiciaram o desenvolvimento de novas abordagens e perspectivas de análise no estudo dos elementos componentes da paisagem, possibilitando maior agilidade na aquisição de dados e rapidez na geração de resultados. Beneficiando-se destas inovações, os métodos de geração de informações de solos passaram por vários ajustes e aperfeiçoamentos, surgindo novas tendências para a obtenção dessa informação, envolvendo técnicas digitais para predição espacial de classes de solos. Uma dessas técnicas é a aplicação de redes neurais artificiais (RNAs).

RNAs são uma técnica de inteligência artificial baseada no paradigma biológico dos neurônios, com capacidade de adquirir, armazenar e utilizar conhecimento experimental e são da mesma família dos sistemas especialistas e abordagens baseadas em conhecimento para aprendizagem (Key et al.1989).

Especificamente para a predição e distribuição de classes de solos poucos são os relatos da utilização de RNAs disponíveis na literatura científica nacional, entre eles pode-se citar Carvalho Júnior et al. (2011), Chagas et al. (2010) e Calderano filho (2012). Zhu (2000), apresenta resultados que mostram o potencial da técnica, Brown et al. (1998) e Yang et al. (1998), relatam em seus trabalhos a aplicação de RNAs em estudos geológicos, todos encontraram resultados satisfatórios ou melhores que os obtidos com outras técnicas ou classificadores digitais.

O presente estudo teve como objetivo aplicar redes neurais artificiais para a predição de classes de solos, utilizando como fonte de dados produtos de sensores remotos orbitais, atributos do terreno derivados de um modelo digital de elevação e informação da geologia local, visando avaliar a possibilidade de utilização desta abordagem para a predição de classes

de solos de paisagens rurais montanhosas, com grau elevado de diversidade litológica na Serra do Mar.

2 - Material e Métodos

A área de estudo com aproximadamente 48.469km², localiza-se na região serrana do Estado do Rio de Janeiro, entre coordenadas W42°12'/W42°35' e S22°05'/S22°20'. Abrange partes territoriais dos municípios de Cordeiro, Trajano de Moraes, Duas Barras, Bom Jardim e Nova Friburgo. O clima é do tipo tropical mesotérmico úmido, com temperaturas elevadas bem distribuídas o ano todo e pouco ou nenhum déficit hídrico (Nimer, 1977). As amplitudes altimétricas locais variam entre 480 e 1620m (Calderano Filho, 2012).

Para a predição das classes de solos com o uso de RNAs foram utilizadas as variáveis ambientais, elevação, declividade, aspecto, curvatura, plano de curvatura, perfil de curvatura, índice topográfico de umidade (CTI), radiação solar e fator LS, derivadas de um modelo digital de elevação (MDE), com resolução espacial de 30 m, obtido com a opção “topo to raster” do programa ArcGIS 9.2 (ESRI, 2004), confeccionado a partir das curvas de nível equidistantes de 20 m, hidrografia e pontos cotados contidos nas cartas topográficas do IBGE, na escala de 1:50.000, folhas Quartéis, Cordeiro, Trajano de Moraes, Duas Barras e Casimiro de Abreu. Essas variáveis juntamente com o mapa geológico da área e os índices minerais de argila (“clay mineral index”), óxido de ferro (“iron oxide index”) e vegetação por diferença normalizada (“normalized difference vegetation index”, NDVI), derivados de uma imagem do sensor ETM+ do Landsat7, de agosto de 1999, compuseram as variáveis preditoras das classes de solos.

A escolha inicial das variáveis tiveram por base o conceito solo-paisagem desenvolvido por Jenny (1941), em que o solo é produto da influência dos seguintes fatores $S = f(CI, O, R, P, T...)$, e na literatura consultada. As variáveis foram obtidas com base nas equações de Moore et al. (1993), Fu & Rich (1999) e Bertoni & Lombardi Neto (2005), utilizando as ferramentas disponíveis no ArcGis 9.2. Os índices derivados do Landsat7 foram obtidos com o programa Erdas Imagine, versão 8.5, eles não apresentam relação direta com os fatores de formação do solo, eles são empregados no sensoriamento remoto geológico e podem ser utilizados para auxiliar na distinção de solos com características físicas e mineralógicas distintas, conforme Sabins Junior, (1997).

Confeccionou-se na escala 1:50.000, o mapa geológico da área, a partir das folhas Cordeiro e Quartéis do projeto faixa calcária Cordeiro-Cantagalo de Matos et al. (1980), e folhas Duas Barras e Trajano de Moraes, do projeto carta geológica do Estado do Rio de Janeiro (DRM1982), e um mapa de reconhecimento de média intensidade de solos, utilizando o método convencional de levantamentos de solos. O mapa de geologia serviu como uma das variáveis preditoras que alimentaram o modelo de predição, digital das classes de solos, além de fornecer informações acerca do material de origem dos solos. O mapa convencional de solos serviu para elencar as classes de solos dominantes que ocorrem na área, e que foram usadas como variáveis de saída na rede neural e para comparar os resultados finais obtidos com a predição digital das classes de solos, (Figura 1).

Utilizou-se 40 perfis completos de solos, 30 perfis extras (horizontes A e B) num total de 300 horizontes analisados, e 256 pontos de campo para a classificação digital com suporte de rede neural. O simulador de redes neurais utilizado foi o “Java Neural Network Simulator”, baseado no Stuttgart Neural Network Simulator 4.2 Kernel (Zell et al. 1996). O algoritmo de aprendizado utilizado foi o “backpropagation”.

Para facilitar o processo de treinamento e simplificar a estrutura da rede, os valores referentes às variáveis discriminantes utilizadas como dados de entrada na rede neural, foram re-escalados para o intervalo 0 e 1, utilizando o ArcGIS 9.2, no caso dos atributos do terreno e grid de geologia, e o ERDAS IMAGINE 8.5, no caso dos índices derivados da imagem do Landsat7. Isto foi feito para evitar a saturação da rede pelo elevado valor que os pesos

sinápticos poderiam ter (Vieira, 2000).

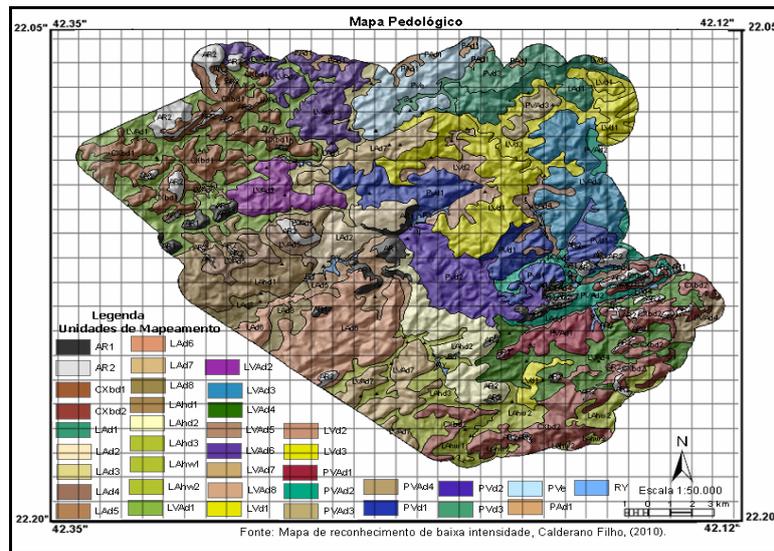


Figura 1 – Mapa de solos convencionais.

Montou-se 12 conjuntos de treinamento, combinando em distintas situações os atributos do terreno, os índices derivados da imagem do LANDSAT 7 e o grid de geologia, contendo o mínimo de 6 e o máximo de 13 variáveis discriminantes cada conjunto, fazendo assim, variar na camada de entrada as variáveis predictoras.

Padronizou-se para cada conjunto 10 classes de solos dominantes como variável de saída, 300 amostras para treinamento e 250 amostras para validação das RNAs por classe, totalizando (3000 e 2500) amostras respectivamente. As amostras obtidas de modo independente (amostras estratificadas) foram coletadas de uma imagem que continha as variáveis discriminantes, com o auxílio do ERDAS IMAGINE 8.5 e distribuídas na área de estudo, de modo a representar o melhor possível às características das populações em termos de condições ambientais e as características de cada classe a ser classificada. Os arquivos obtidos foram convertidos para o formato de trabalho do JavaNNS. Assim, para cada conjunto testado, foi criado um arquivo de treinamento e outro de validação.

Realizou-se vários ciclos de treinamento, simulações e testes, com diferentes arquiteturas de redes, fazendo variar o número de neurônios nas camadas de entrada, nas camadas internas e o número de camadas internas, padronizando 10 neurônios nas camadas de saída, com a finalidade de encontrar a arquitetura que melhor representasse as classes de saída pré-definidas. O treinamento das redes consistiu na alocação aleatória dos pesos interneurônios entre de -0,5 e 0,5, taxa de aprendizagem (η) de 0,2, para 10 mil ciclos de treinamento, de 0,1 para 10.000 a 20.000 ciclos e 0,075 para 20.000 a 30.000 ciclos de treinamento.

Para adicionar neurônios na camada interna, baseou-se no comportamento do erro durante a fase de treinamento, utilizando-se o método do incremento. Este processo é repetido até que a rede funcione com alta acurácia e baixo erro de treinamento (Zhu, 2000).

Ao final de todo o processo de treinamento, as redes foram submetidas à validação para escolha daquela(s) que seria(m) utilizada(s) na discriminação dos solos da área estudada. A avaliação dos resultados obtidos constou da determinação do nível de exatidão ou confiança da classificação (índice Kappa) e da exatidão global da classificação das redes neurais consideradas, através da análise da matriz de confusão (Congalton & Green, 1999). Uma matriz de significância de Kappa entre as redes consideradas foi gerada para verificar a existência de diferenças significativas ou não entre os resultados obtidos e para a escolha da melhor arquitetura de rede para a classificação final dos dados (Vieira, 2000).

Ao término do processo foi selecionada para a predição das classes de solos da área a

arquitetura de rede que obteve o melhor resultado para o índice Kappa, para cada um dos conjuntos de variáveis discriminantes considerados. Os resultados finais obtidos com as RNAs e as imagens das cenas classificadas, foram obtidas com o auxílio do aplicativo “Funcpow” e manipulados nos softwares ERDAS Imagine 8.5 e ArcGis 9.2. Os mapas de solos digitais produzidos por redes neurais para cada combinação de variáveis ambientais (Figuras 2 e 3), foram comparados com o mapa de solos convencional, avaliando a concordância de cada mapa digital com o mapa de solos convencional.

3. Resultados e Discussão

Durante todo o processo de treinamento os melhores resultados pela classificação por redes neurais, entre as várias combinações avaliadas e testadas, foram obtidos com todas as variáveis discriminantes, conjunto 13, (atributos do terreno e índices do sensor LANDSAT7, associadas as informações de geologia), alcançando exatidão global entre 93,2 a 95,6% e índice Kappa entre 0,924 e 0,951. Excluindo a variável perfil de curvatura, conjunto 12, a exatidão global alcançada oscilou entre 93,9 e 95,4% e o índice Kappa entre 0,932 e 0,948. Nesses dois conjuntos a maioria das redes treinadas mostram um desempenho do classificador de muito bom a excelente, com valores superiores a 0,75 de Kappa, conforme valores de referência sugeridos por Landis & Koch (1977).

A escolha e seleção final da melhor arquitetura de RNA para a predição das classes de solos foi baseada nos resultados do índice Kappa e da exatidão global, obtidos com a utilização das amostras de validação, através da matriz de confusão e pela análise da matriz de significância de Kappa entre as redes selecionadas, como mostra as Tabelas 1 e 2, onde observa-se que o índice Kappa variou em função do número de neurônios na camada interna.

O aumento da complexidade da rede com a adição de neurônios na camada interna melhorou substancialmente a exatidão da classificação, da mesma forma a inclusão da informação de geologia, aumento nos ciclos de treinamentos e uso de duas camadas internas contribuiu para elevar a exatidão da classificação. Segundo Foody & Arora (1997), redes maiores e mais complexas são mais eficientes para caracterizar corretamente um conjunto de treinamento.

Tabela 1 - Matriz de confusão obtida na classificação da rede [R4848_TP12] do conjunto 12.

1 – [R4848_TP12d]													
Classe	1	2	3	4	5	6	7	8	9	10	Total	Usuário	Z
1	245	0	0	7	0	0	0	0	0	0	252	97.2	84.505
2	0	247	0	19	0	3	0	0	0	0	269	91.8	49.430
3	5	0	234	0	0	0	0	18	0	0	252	92.9	51.463
4	0	0	0	222	0	0	0	0	0	0	227	97.8	90.318
5	0	0	0	2	249	17	0	0	1	0	269	92.6	52.059
6	0	3	0	0	0	226	0	0	0	0	229	98.7	118.185
7	0	0	12	0	0	4	245	0	13	0	274	89.4	43.262
8	0	0	0	0	1	0	0	232	0	0	233	99.6	209.238
9	0	0	4	0	0	0	5	0	234	0	243	96.3	71.503
10	0	0	0	0	0	0	0	0	2	250	252	99.2	159.727
U	0	0	0	0	0	0	0	0	0	0	0	0.0	
Total	250	250	250	250	250	250	250	250	250	250	2500		
Produ.	98,0	98,8	93,6	88,8	99,6	90,4	98,0	92,8	93,6	100,0			

Exatidão global = 95,4; Kappa = 0,948; Variância = 0,000022; Z calculado = 202,950; Z Tabelado = 1,96.

Na rede R4848_TP12d, o maior acerto de (100%) é referente a classe 10, domínio dos Argissolos Amarelos. As classes 1 e 7, domínio dos Afloramentos associados a Neossolos Litólicos e dos Argissolos Vermelho-Amarelos o acerto foi de 98,0% respectivamente, as classes 2 e 5, domínio dos Cambissolos háplicos e Latossolos Vermelho-Amarelos o acerto foi de 98,8% e 99,6% respectivamente, as classes 3 e 9 domínio dos Latossolos Amarelos distróficos e Neossolos Flúvicos, tiveram acertos de 93,6% respectivamente, na classe 8, domínio do Argissolo Vermelho o acerto foi de (92,8%) e na classe 6 domínio do Latossolo

Vermelho distrófico o acerto foi de (90,4%). O pior desempenho obtido na classificação ocorreu na classe 4, domínio dos Latossolos Amarelos húmicos, com uma exatidão de 88,8%, como mostra a Tabela 1.

A partir dos resultados das matrizes de confusão e outros valores estatísticos da validação das RNAs apresentados na Tabelas 1, e em função do seu desempenho, o conjunto 12, foi um dos escolhidos para auxiliar na discriminação dos solos da área. Assim, foi gerada uma matriz de significância de Kappa entre as redes consideradas, para verificar a existência de diferenças significativas ou não entre os resultados obtidos e para a escolha da melhor arquitetura de rede para a classificação final dos dados (Tabela 2).

TABELA 2. Matriz de significância de Kappa e respectivos índices para as diferentes arquiteturas de redes neurais selecionadas do conjunto 12_TP12d.

Redes	R4343T	R4444T	R4646T	R4848T	R5555T
Exatidão global	93,9	94,6	94,0	95,4	94,4
Kappa	0,932	0,940	0,933	0,948	0,938
Variância ^a	0,28	0,25	0,28	0,22	0,26
R4343T	176.131				
R4444T	1,099	188.000			
R4646T	0,134	0,962	176.320		
R4848T	2,263	1,167	2,121	202.114	
R5555T	0,816	0,280	0,680	1,443	183.957

^a valores multiplicados por 1000.

Na avaliação do treinamento no tempo dois, os maiores valores de exatidão global, índice Kappa e consequentemente os menores de variância, foram obtidos com as arquiteturas de redes com dupla camada interna, R4848_TP12d com 95,4% de exatidão global e 0,948 de Kappa, seguida das redes R4444_TP12d com 94,6% e 0,940 de Kappa e R5555_TP12d com 94,4% e 0,938 de Kappa, como mostra a matriz de significância entre as redes treinadas, Tabela 2. No entanto, a rede com 48 neurônios na camada interna é significativamente diferente das demais, portanto foi uma das escolhidas para a discriminação final das classes de solos da área.

A combinação de todos os atributos do terreno com o grid de geologia e os três índices derivados da imagem do sensor LANDSAT 7, conjunto 13, foi o que apresentou os melhores resultados finais em várias redes treinadas. A maioria destas redes apresentaram nas classes de saída resultados excelentes, como mostra a Tabela 3.

TABELA 3. Matriz de confusão obtida na classificação da rede [R4343_TP13d] do conjunto 13.

3 - [R4343_TP13d]													
Classe	1	2	3	4	5	6	7	8	9	10	Total	Usuário	Z
1	240	0	0	7	0	0	0	0	0	0	247	97.2	82.799
2	2	240	0	1	0	10	0	0	0	0	253	94.9	61.476
3	0	0	246	0	0	5	0	18	0	0	269	91.4	48.242
4	8	10	0	242	0	0	0	0	0	0	260	93.1	53.175
5	0	0	0	0	250	0	0	0	8	0	258	96.9	80.798
6	0	0	0	0	0	222	0	0	0	0	222	100.0	0.000
7	0	0	0	0	0	13	245	0	0	0	258	95.0	62.732
8	0	0	0	0	0	0	0	214	0	0	214	100.0	0.000
9	0	0	4	0	0	0	5	0	240	0	249	96.4	73.311
10	0	0	0	0	0	0	0	18	2	250	270	92.6	52.262
U	0	0	0	0	0	0	0	0	0	0	0	0.0	
Total	250	250	250	250	250	250	250	250	250	250	2500		
Produ.	96.0	96.0	98.4	96.8	100.0	88.8	98.0	85.6	96.0	100.0			

Exatidão global = 95,6; Kappa = 0,951; Variância = 0,000021; Z calculado = 207,761; Z Tabelado = 1,96.

Observando os resultados da classificação das amostras de validação da rede R4343_TP13d, Tabela 3, verifica-se que o maior acerto de (100%) é referente às classes 5 e 10, paisagens do

domínio dos Latossolos Vermelho Amarelos e dos Argissolos Amarelos.

Observando os resultados da classificação das amostras de validação da rede R4343_TP13d, verifica-se que o maior acerto de (100%) é referente às classes 5 e 10, paisagens do domínio dos Latossolos Vermelho Amarelos e dos Argissolos Amarelos. As classes 1, 2 e 9, domínio dos Afloramentos associados a Neossolos Litólicos, Cambissolos háplicos e Neossolos Flúvicos, tiveram acertos de 96% respectivamente, as classes 3 e 7 domínio dos Latossolos Amarelos distróficos e Argissolos Vermelho-Amarelos o acerto foi de 98,4% e 98% respectivamente. A classe 4, domínio dos Latossolos Amarelos húmicos o acerto foi de 96,8% e as classes 6 e 8, domínio dos Latossolos Vermelhos e Argissolos Vermelhos o acerto foi de 88,8% e 85,6% respectivamente, como mostra a Tabela 3.

As maiores confusões ocorreram na classe dos Argissolos Vermelhos (classe 8) com a alocação de 18 pixels nas classe 3 e 10. Esta confusão pode ser explicada pela diversidade litológica e pelo grau de complexidade pedológica da área de estudo, que apresenta padrões de paisagens muito semelhantes onde estas classes de solos ocorrem e na forma como se distribuem na paisagem, ou seja, ocupam indistintamente a mesma posição na paisagem, o que torna difícil a separação dos mesmos, com 100% de acerto.

A partir dos resultados da matriz de confusão e outros valores estatísticos da validação das RNAs apresentados na Tabelas 3, em função do melhor desempenho, o conjunto 13, foi também escolhido para auxiliar na discriminação dos solos da área. Assim, foi gerada uma matriz de significância de Kappa entre as redes consideradas, para verificar a existência de diferenças significativas ou não entre os resultados obtidos e para a escolha da melhor arquitetura de rede para a classificação final dos dados (Tabela 4).

TABELA 4. Matriz de significância de Kappa e respectivos índices para as diferentes arquiteturas de redes neurais selecionadas no conjunto 13_TP.

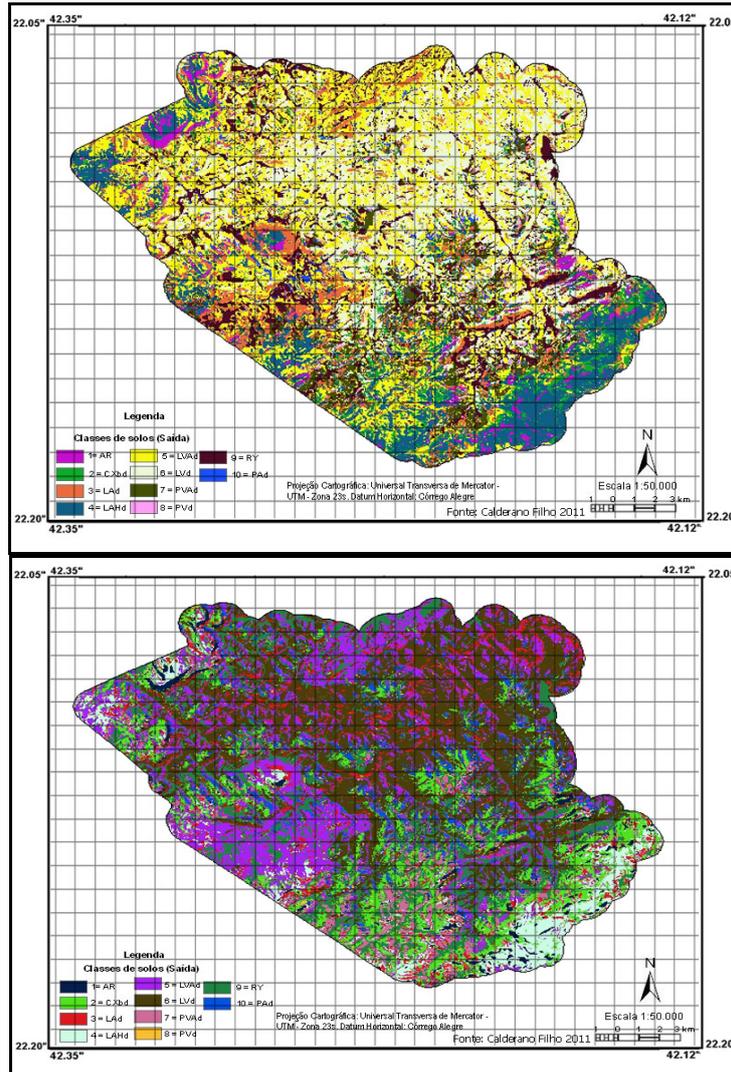
Redes	R4343TP	R4545TP	R4747TP	R5454TP	R5555TP
Exatidão global	95,6	94,0	93,2	93,7	93,4
Kappa	0,951	0,933	0,924	0,930	0,927
Variância ^a	0,21	0,28	0,31	0,29	0,30
R4343TP	207,525				
R4545TP	2,571	176,320			
R4747TP	3,744	1,172	165,955		
R5454TP	2,970	0,397	0,775	172,697	
R5555TP	3,361	0,788	0,384	0,391	169,246

existe diferença significativa ao nível de 95%;^a valores multiplicados por 1000.

A Tabela 4 mostra que os melhores desempenhos foram obtidos com as redes R4343_TP13d (207,525), R4545_TP13d (176,320) e R5454_TP13d (172,697). No entanto, a rede com 43 neurônios na camada interna é diferente de todas as demais e também foi uma das escolhidas para a discriminação das classes de solos da área.

Ao final de todo o processo de treinamento e validação para escolha das redes que seriam utilizadas na discriminação dos solos, definiu-se pelas redes R4343_TP13d e R4848_TP12d.

Durante o estudo não houve preocupação em comparar as metodologias aplicadas na geração do mapa de solos. A intenção foi a partir das experiências anteriores, utilizar como material básico produtos de baixo custo, de fácil aquisição e disponíveis no mercado, trabalhar uma área com grau mais elevado de complexidade litológica, e dessa forma testar e comprovar a eficiência das RNAs na discriminação e distribuição das classes de solos, mantendo a acurácia dos dados. A partir daí, áreas inóspitas ou de acesso difícil como a região amazônica, por exemplo, poderiam passar a contar com esse tipo de informação em escala média. As Figuras 2 e 3, mostram a classificação resultante da aplicação das RNAs do conjunto 12, rede [R4848TP_12d] e do conjunto 13, rede [R4343TP_13d], para a área de treinamento.



FIGURAS 2 e 3 – Classificação resultante da aplicação das arquiteturas de redes [R4848TP_12d] e [R4343TP_13d] para a área de treinamento.

Os mapas não se comparam entre si pois são metodologias diferentes que foram aplicadas (Figuras 1, 2 e 3). Mas, pelos resultados obtidos constata-se que a maioria das unidades de mapeamentos são compostas por associações de solos e o classificador por rede neural sempre alocou certo um dos membros componentes da unidade de mapeamento. Levando em conta o aspecto visual das classificações, observa-se um melhor delineamento, com uma classificação mais concisa em todas as classes de saída para as redes selecionadas, onde as classes dos Neossolos Litólicos associados a Afloramentos (AR), Cambissolos Háplicos (CXbds) e Latossolos Húmicos (LAHds), acompanham de forma consistente e bastante semelhante aos contornos do mapa convencional em todas as classificações, Figuras 1, 2 e 3. A discordância é maior e o desempenho do classificador neural é menor, quando se compara as áreas suavizadas com as áreas mais movimentadas da paisagem, como constatado por Zhu (2000) e Chagas et al. (2010). Neste tipo de avaliação visual, observa-se também uma boa separação de limites entre as classes de saída, em coerência com o mapa convencional, em praticamente todas as classes de saída e em todas as redes, com exceção dos Neossolos Flúvicos e Argissolos Vermelhos, que em algumas redes foram sub ou superdistribuídos.

4. Conclusões

A utilização conjunta dos atributos do terreno, informações da geologia e índices derivados do sensor Landsat, permitiram estabelecer com maior precisão às relações solo-paisagem que ocorrem na área de estudo, possibilitando a obtenção de mapas com mais detalhes espaciais,

principalmente entre os membros componentes das unidades de mapeamento.

Os resultados demonstram o potencial de utilização desta abordagem, os mapas inferidos por RNAs mostram muita coerência e semelhança ao mapa de solos convencional, produzido para área de estudo, apresentando porém, mais detalhes espaciais.

9 - Referências Bibliográficas

BERTONI, J. & LOMBARDI NETO, F. **Conservação do Solo**. 5 ed. Piracicaba, São Paulo; ícone Editora, 2005. 360p.

BROWN, D. G.; LUSCH, D. P. & DUDA, K. A. Supervised classification of types of glaciated landscapes using digital elevation data. **Geomorphology**, v.21, p.233-250, 1998.

CALDERANO FILHO, B. **Análise geoambiental de paisagens rurais montanhosas da Serra do utilizando redes neurais artificiais. Subsídios a sustentabilidade ambiental de ecossistemas frágeis e fragmentados sob interferência antrópica**. Rio de Janeiro 2012. 332f. Tese (Doutorado em Geologia) – Instituto de Geociências, Universidade Federal do Rio de Janeiro, Rio de Janeiro 2012.

CARVALHO JÚNIOR, W. CHAGAS, C. S. FERNANDES FILHO, E. I., VIEIRA, C. A. O., SCHAEFER, C. E. G., FRANCELINO, M. R. 'Digital soilscape mapping of tropical hillslope areas by neural networks. **Scientia agricola**, Piracicaba, v.68, n6, p679-686, 2011.

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

ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE. ArcGIS 9.2: getting started with ArcGIS. Redlands: ESRI, 2004. 272p.

FOODY, G. M.; ARORA, M. K. An evaluation of some factors affecting the accuracy of classification by an artificial neural network. **International Journal of Remote Sensing**, v.18, n.4, p.799 - 810, 1997.

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

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

KEY, J.; MASLANIK, J.A. & SCHWEIGER, A.J. Classification of merged AVHRR and SMMR artice data with neural networks. **Photogram. Eng. Remote Sens.**, 55:1331-1338, 1989.

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

LANDIS, J. R. & KOCH, G. G. The measurement of observer agreement for categorical data. **Biometrics**. v.33, p.159-174, 1977.

MATOS, G.; FERRARI, P.; CAVALCANTI, J. **Projeto Faixa Calcaria Cordeiro-Cantagalo**. Belo Horizonte: DNPM/CPRM, 1980, 620 p.

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

NIMER, E. Clima. In: IBGE/Departamento de Geografia, Rio de Janeiro. **Geografia do Brasil Região Sudeste**. Rio de Janeiro, IBGE, 1977. v.3., p.51- 89.

DRM, **Projeto Carta Geológica do Estado do Rio de Janeiro. Folhas: Duas Barras e Trajano de Morais**. 1982.

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

VIEIRA, C. A. O. **Accuracy of Remotely Sensing Classification of Agricultural Crops: A Comparative Study**. Tese de Doutorado. University of Nottingham. 2000. 352p.

YANG, G.; COLLINS, M. J. & GONG, P. Multisource data selection for lithologic classification with artificial neural networks. **International Journal of Remote Sensing**, v.19, p.3675-3680, 1998.

ZELL, A. Et al. **Stuttgart Neural Network Simulator v4.2**. University of Stuttgart: Institute for Parallel and Distributed High Performance Systems/University of Tübingen - Wilhelm-Schickard-Institute for Computer Science - Department of Computer Architecture. 1996.

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