

ESTIMATIVA DA VARIABILIDADE ESPACIAL DE ATRIBUTOS DE SOLOS DO CERRADO POR REDES NEURAIAS

Me. Roberto Dib Bittar¹,
Dr^a. Sueli Martins Freitas Alves²,
Dr. Francisco Ramos de Melo³.

1 Mestre em Engenharia agrícola UEG(2016) e Docente da Universidade Estadual de Goiás,

2 Doutora em Agronomia UFG(2006), Pós doutorado UFV(2010) e Docente da Universidade Estadual de Goiás,

3 Doutor em Engenharia Elétrica UFU(2012), Pós doutorado UFU(2013) e Docente da Universidade Estadual de Goiás.

Resumo: A agricultura de precisão possibilita aquisição de dados em uma vasta gama, processamento e posterior utilização para realizar melhor gerenciamento com objetivo de minimizar custos e aumentar a produtividade. Um dos fatores que influenciam a produção é a variabilidade espacial dos atributos do solo. Ao conhecer essa variação, é possível usar técnicas para adequar o solo às necessidades específicas das culturas. As Redes Neurais Artificiais (RNAs) buscam imitar o raciocínio humano e se mostram capazes de realizar inferência de dados. Uma qualidade das RNAs é estabelecer relação das características multidimensionais consideradas no problema para identificar o padrão ou classe do objeto apresentado. Neste trabalho aplicou-se as RNAs com objetivo de realizar a inferência de determinados atributos físico-químicos do solo. Para tal foi realizada: coleta de dados, análise estatística descritiva, análise geoestatística, definição, treinamento e escolha das RNAs de menor erro médio, posteriormente calculou-se o erro médio relativo finalizando com comparação das estimativas realizadas por Krigagem ordinária dos atributos que apresentaram dependência espacial. Foi possível concluir que as RNAs apresentam potencial para realizar satisfatoriamente a inferência de atributos físico-químicos do solo.

Palavras-chave: Inteligência Artificial. Geoestatística. Agricultura Precisão.

Introdução

Almejou-se a possibilidade de realizar a inferência de determinados atributos do solo utilizando Redes Neurais Artificiais (RNA). Para isso, foi necessário definir o modelo para entrada dos dados para treinamento da RNA que considerasse tanto a auto correlação quanto a distância entre as amostras de solo. Gerar programas computacionais para manipulação desses dados, realizar o treinamento das respectivas RNAs testando diferentes topologias e proceder a validação, teste e comparação de resultados apresentados.

Assim, as RNAs foram aplicadas com objetivo de realizar a modelagem da variabilidade espacial de atributos do solo e verificar a validade desta modelagem comparando com os resultados conhecidos das amostras de solo e os com resultados apresentados pela análise geoestatística.

Referencial Teórico

A agricultura de precisão (AP) apresenta perspectivas para manejo e gerenciamento de culturas com vista na obtenção de melhora da produção, na diminuição do custo total e nos possíveis benefícios para o meio ambiente. Diferentes estratégias podem ser utilizadas no sentido de minimizar os gastos com os fatores de produção agrícola, por exemplo, com o preparo do solo, com o plantio, na utilização de fertilizantes e para gerenciar/controlar a colheita (MOLIN e CASTRO, 2008).

O conhecimento da variação espacial de atributos de solo pode contribuir para o planejamento de lavouras comerciais. O solo, por mais uniforme que seja, mesmo em áreas consideradas homogêneas, apresenta variações nos seus atributos físicos e químicos. Existe variação espacial de determinados atributos em grau suficiente para interferir na produtividade das culturas, mesmo a curtas distâncias. O conhecimento desta variabilidade deve ser incorporado aos procedimentos e técnicas aplicadas à agricultura de precisão (VIEIRA, 2000).

A análise geoestatística permite detectar a existência da variabilidade e distribuição espacial das medidas estudadas e constitui importante ferramenta na análise e descrição detalhada da variabilidade das propriedades do solo. Conhecendo coordenadas geográficas de pontos amostrados é possível representar a área com maior detalhamento. Os atributos do solo não estão distribuídos randomicamente dentro dos ecossistemas, seguem uma distribuição regionalizada. Algumas amostras possuem maior similaridade de valores dos seus atributos que outras e essa relação se dá pela distância que as separa (GREGO e VIEIRA, 2005; SANTOS et al., 2013).

Outras tecnologias podem ser utilizadas com o propósito de estimar a variabilidade espacial de atributos de solo. As Redes Neurais Artificiais (RNA) são programas computacionais que procuram imitar o raciocínio dos seres vivos, o neurônio artificial é seu componente básico. As RNAs compõem uma estrutura matemática flexível capaz de realizar mapeamentos não lineares entre informações de entrada e de saída. São modelos computacionais que possuem a capacidade de aquisição e manutenção do conhecimento e

podem ser treinadas para responder a determinada (NOROUZI et al., 2010; ANGELICO e SILVA, 2014).

As RNAs são sistemas de inteligência artificial baseados no sistema nervoso de seres vivos e seu elemento principal é o neurônio artificial, esses neurônios, buscam imitar o comportamento dos neurônios biológicos. Um sistema de inteligência artificial deve ser capaz de fazer três coisas: armazenar conhecimento, aplicar o conhecimento armazenado para resolver problemas e adquirir novo conhecimento através da experiência (HAYKIN, 2001; SILVA et al., 2010).

O processo de aprendizado da RNA, chamado de treinamento, pode ser visto como um problema de ajuste de curva onde generalização é a capacidade da rede em realizar o mapeamento de entrada-saída computada de maneira correta ou aproximadamente correta. A generalização é influenciada por três fatores: tamanho do conjunto de treinamento e o quanto esse conjunto representa o ambiente de interesse, a arquitetura da rede neural e a complexidade do problema em questão (HAYKIN, 2001).

Metodologia

Os dados utilizados para o desenvolvimento deste trabalho são os atributos físicos e químicos oriundos da dissertação de Reis (2011), foram obtidos em uma área localizada na Fazenda Palmital, numa extensão irrigada por pivô central, localizada no município de Morrinhos, GO, com altitude de 813 m, latitude 17°45'S e longitude 49°10'W. A área apresenta latossolo vermelho escuro, com textura franco argilo arenosa. Os dados foram coletados e georeferenciados em um talhão de 23 hectares em uma grade amostral de 50 x 50 m, totalizando 120 pontos amostrais. Cada ponto amostral foi georeferenciado com o um aparelho de GPS (Sistema de Posicionamento Global) Garmin modelo Etrex 36 Legend RoHs com o sistema de correção diferencial em tempo real via satélite e com o datum ajustado ao sistema SAD 69^a.

A Análise descritiva dos dados coletados foi realizada com o objetivo de conhecer e visualizar o comportamento das variáveis em estudo. A partir dos dados originais, utilizando o software livre R foi realizado o cálculo das medidas descritivas para cada variável: média, moda, quartil 1, mediana e quartil 3, variância, desvio-padrão, assimetria, curtose e coeficiente de variação. Assim como, a verificação de outlier usando interpretação gráfica *Boxplot* e o critério teste de Tukey (1977). Para verificar a normalidade dos dados foi realizado o teste ($p\text{-value} < 0,05$) proposto por Shapiro e Wilk (1965).

O treinamento da RNA foi realizado utilizando o software trial Matlab ® 2012 com pacote Neural Network ToolBox em topologia do tipo MLP alimentada para frente feedforward com algoritmo de aprendizado de retropropagação do erro Back-propagation. A metodologia utilizada para preparação, treinamento e aplicação da rede neural artificial foi a proposta pelos autores Braga et al., (2012) que corroboram com Russel e Norvig (2013).

Para cada um dos quinze atributos de solo considerados foram treinadas 168 redes neurais artificiais. A alternância na topologia das redes usadas no treinamento ocorreu em função de alterações em três fatores:

- a) Quantidade de amostras de solo relativas (1, 2, 3 ou 4) combinadas com o ponto amostral referencial;
- b) Quantidade de neurônios da camada intermediária (3, 5, 7, 9, 13, 17 e 21);
- c) Rodadas de treinamento (de 1 até 6).

As variáveis de entrada para treinamento das RNAs foram compostas de duas partes:

1ª Parte: Ponto amostral referencial – é a coordenada geográfica da amostra de solo que terá o valor de cada atributo de solo estimado pela RNA.

2ª Parte: Pontos amostrais relativos – são as amostras de solo conhecidas, consecutivas coordenadas e valores dos atributos de solo considerados.

Para treinamento das RNAs os valores dos atributos de solo foram normalizados utilizando (BITTAR, 2016). Os valores mínimos e máximos utilizados para cada atributo constam na Tabela 1.

A partir dos dados experimentais, foram separados quatro conjuntos de dados. Inicialmente foi escolhido de forma aleatória o conjunto nominado teste final (10 amostras), este conjunto não entrou no processo de treinamento da rede, foi utilizado somente na validação e teste final das redes neurais escolhidas. Posteriormente, os conjuntos utilizados para o treinamento da RNA nominados: Treinamento (82 amostras), validação (17 amostras) e teste (11 amostras) foram escolhidos de forma aleatória. A quantidade de amostras de cada um desses conjuntos foi feita mediante adaptação indicada por Braga et al. (2012) e Russel e Norvig (2013) devido a quantidade de amostras e a necessidade de se obter valores inteiros.

Utilizando os resultados do treinamento arquivados foi realizada a seleção de 4 RNAs para cada um dos 14 atributos de solo sob estudo, sendo uma RNA para cada quantidade de pontos amostrais relativos: um, dois, três e quatro. O critério de escolha utilizado foi a performance da RNA em acertar a estimativa dos valores do atributo no ponto amostral. O objetivo foi selecionar a hipótese que tornasse mínimo o erro do mapeamento entrada-saída.

O cálculo da performance foi feito pelo índice de acerto de previsão obtido pelo erro médio quadrático (EMQ) (Equação 1), quanto menor o valor do EMQ, melhor a performance da RNA (HAYKIN, 2010).

$$EMQ = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (1)$$

onde: n= número de elementos;
Y = valor observado;
 \hat{Y} = valor estimado.

Com objetivo de verificar o índice de acerto de cada uma das RNAs escolhidas foi feito a comparação dos resultados entre os valores estimados pelas redes e os valores observados nas amostras de solo. Os valores estimados foram desnormalizados (BITTAR, 2016) e conseqüentemente calculado o valor do erro médio relativo (P) (Equação 2).

$$P = \frac{100}{n} \sum \frac{|Y - \hat{Y}|}{Y} \quad (2)$$

onde: n = número de elementos;
Y = valor observado experimentalmente;
 \hat{Y} = valor estimado.

A identificação da estrutura de dependência espacial dos atributos físicos e químicos do solo foi feita por meio da análise geoestatística utilizando o programa GS+ versão demo 10.0 Gamma Design Software ® (Geostatistics for the Environmental Sciences).

Para cada atributo do solo considerado foi verificado, entre os modelos de semivariogramas o que apresentou melhor ajuste ao modelo experimental. Para a escolha do melhor modelo utilizou-se como critério a menor soma dos quadrados dos resíduos (SQR) e o maior coeficiente de determinação (R^2). Foram testados e ajustados os modelos de semivariogramas esférico, exponencial, linear e gaussiano. Para análise do semivariograma foi considerado o modelo teórico e o modelo experimental, foi feita a avaliação do efeito pepita (C_0), do alcance (A_0) e do patamar ($C_0 + C_1$).

Os resultados estimados utilizando as RNAs foram comparados aos estimados utilizando krigagem na análise geoestatística somente para os atributos que apresentaram dependência espacial

Resultados e Discussões

Os atributos Potencial Hidrogeniônico (pH), Potássio (K), Saturação por Bases (V%) e Areia apresentaram assimetria negativa com a média e a mediana menores que a moda, os demais atributos assimetria positiva. Exceto para o Fósforo (P), os demais atributos não

apresentaram variação substancial entre os valores da média, mediana e moda (tabela 1). Essa é uma característica favorável para indicar que os valores amostrados provavelmente pertencem a uma distribuição espacial com variação de valores em distribuições regionalizadas.

Tabela 1. Análise descritiva dos atributos de solo.

Atributo	Média	MD	Moda	Var	DP	Ass	Curtose	CV (%)	P-Value	MinN	MaxN
pH	5,65	5,70	5,80	0,0755	0,2747	-0,6042	0,3893	4,86%	0,0027	0	11
Ca	4,77	4,80	4,80	0,9567	0,9781	0,3499	0,9520	20,51%	0,1209	0	19
Mg	0,99	0,90	0,90	0,0854	0,2922	1,2450	1,6289	29,49%	0,0000	0	19
Ca+Mg	5,76	5,70	5,30	1,5177	1,2319	0,5645	0,8180	21,38%	0,0243	0	29
Al	0,01	0,00	0,00	0,0009	0,0295	4,2219	19,0642	392,74%	0,0000	0	19
H + Al	1,73	1,60	1,60	0,2191	0,4681	0,8086	1,9042	27,05%	0,0008	0	29
CTC	7,96	8,00	8,20	1,2287	1,1085	0,7643	1,2790	13,92%	0,0010	0	29
K	0,48	0,51	0,61	0,0140	0,1182	-0,0754	-1,4881	24,69%	0,0000	0	29
P	105,83	90,00	70,00	2385,8543	48,8452	1,7628	3,6258	46,15%	0,0000	0	499
m%	0,18	0,00	0,00	0,5489	0,7409	5,3802	34,5112	423,38%	0,0000	0	100
V%	77,79	77,50	81,00	49,7293	7,0519	-0,7984	2,2246	9,07%	0,0012	0	100
MO	23,88	23,00	23,00	17,5493	4,1892	0,9928	1,9251	17,54%	0,0000	0	1000
Argila	268,42	250,00	250,00	1608,3964	40,1048	1,1689	1,4904	14,94%	0,0000	0	1000
Silte	147,42	150,00	150,00	889,9090	29,8313	0,2897	0,2508	20,24%	0,0005	0	1000
Areia	584,17	600,00	600,00	4004,3417	63,2799	-0,9787	0,8679	10,83%	0,0000	0	1000

pH-Potencial Hidrogeniônico; Ca – Cálcio (cmolc dm^{-3}); Mg - Magnésio(cmolc dm^{-3}); Al – Alumínio (cmolc dm^{-3}); H+AL – Acidez Potencial (cmolc dm^{-3}); CTC – Capacidade de Troca Catiônica; P – Fósforo (mg dm^{-3}); K – Potássio (cmolc dm^{-3}); m % - Saturação por Alumínio (%); V% - Saturação por Bases (%); MO- Matéria Orgânica (g dm^{-3}); Argila (g Kg^{-1}); Silte (g Kg^{-1}); Areia (g Kg^{-1}); MD – Mediana; Var - Variância; DP – desvio padrão; Ass – Coeficiente de assimetria; CV(%) Coeficiente de Variação; P-Value : teste normalidade Shapiro Wilk a 5%; MinN – valor mínimo para normalização; MaxN – Valor máximo para normalização.

Conforme classificação adotada por Warrick e Nielsen (1980) para experimentos em campos, o Potencial Hidrogeniônico (pH), Saturação por Bases (V%) e Areia apresentaram CV baixo, Alumínio (Al) e Saturação por Alumínio (m%) CV alto e os demais atributos apresentaram CV médio (Tabela 1)

Os valores elevados do CV para determinados atributos de solo podem ser provenientes de efeitos residuais de adubações anteriores, visto que essa adubação geralmente ocorre na linha de plantio, e a de restos culturais e correção da acidez do solo que é realizada a lanço (CAVALCANTE et. al., 2007).

A normalidade da distribuição dos valores da amostra foi confirmada apenas para o Cálcio (Ca). Muitas variáveis do sistema solo-planta-atmosfera seguem distribuição normal, esta é uma característica importante para determinadas análises, porém, neste trabalho a característica de normalidade não é fundamental para aplicação em RNAs. O teste de

normalidade também não é considerado uma premissa para realizar a análise geoestatística, entretanto foi realizada verificação sobre a adequação dos dados à uma distribuição regionalizada utilizando a técnica da análise gráfica das janelas móveis de Isaaks e Srivastava (1989) dos atributos sob estudo.

A cada uma das redes selecionadas foram apresentadas dois conjuntos de valores para teste: conjunto C onde constam os 120 pontos amostrais e o conjunto C2 com os valores não mapeados no treinamento das RNAs. Com objetivo de analisar o índice de acerto das estimativas das RNAs selecionadas foi feito o cálculo de três indicadores: erro médio quadrático (EMQ) (Equação 1), erro médio relativo (P) (Equação 2) para o conjunto C e P do conjunto C2 (Tabela 2).

A Saturação por Alumínio (m%) atingiu o melhor índice de acerto com a RNA selecionada utilizando 4 pontos amostrais relativos. A Capacidade de Troca Catiônica (CTC), Saturação por Bases (V%) obtiveram o melhor índice de acerto de estimativa com as respectivas RNA selecionadas utilizando 3 pontos amostrais relativos. Os demais atributos de solo apresentaram os melhores resultados com 1 ponto amostral relativo (Tabela 2).

Cinco atributos de solo: Potencial Hidrogeniônico (pH), Alumínio (Al), Saturação por Alumínio (m%), Argila e Areia foram estimados pelas respectivas redes selecionadas apresentando P(C) menor que 8% e P(C2) menor que 9% (Tabela 2).

Seis atributos de solo: Cálcio (Ca), Cálcio+Magnésio (Ca+Mg), Capacidade de Troca Catiônica (CTC), Saturação por Bases (V%), Matéria Orgânica (MO) e Silte foram estimados pelas respectivas redes selecionadas apresentando P(C) entre 9% a 15% e P(C2) entre 10% a 20% (Tabela 2).

Três atributos de solo: Magnésio (Mg), Acidez Potencial (H+Al) e Potássio (K) foram estimados pelas respectivas redes selecionadas apresentando P(C) entre 15% a 18% e P(C2) entre 20% a 24% (Tabela 2).

Tabela 2. Resultados dos testes das RNAs selecionadas

Atributo	EMQ	P(C)	P(C2)	EMQ	P(C)	P(C2)	EMQ	P(C)	P(C2)	EMQ	P(C)	P(C2)
	1 amostra relativa			2 amostras relativas			3 amostras de relativas			4 amostras relativas		
pH	0,05	3,13	5,62	0,14	5,30	7,63	0,15	5,62	7,82	0,1488	5,34	7,88
Ca	0,61	14,15	18,49	0,94	17,37	22,12	1,10	19,00	22,96	1,02	17,73	22,74
Mg	0,04	16,25	20,58	0,09	24,63	25,73	0,10	26,56	25,47	0,09	25,60	26,67
Ca+Mg	1,04	14,69	18,53	1,51	17,63	21,54	1,72	19,22	22,38	1,66	18,69	22,33
Al	0,00	4,44	6,09	0,00	7,23	10,66	0,00	7,15	10,56	0,00	7,14	10,45
H+Al	0,11	15,65	21,48	0,41	31,22	37,93	0,35	29,95	36,58	0,35	29,19	35,50
CTC	1,05	9,89	13,89	1,26	10,91	14,87	1,04	9,94	13,73	1,17	10,51	14,07
K	0,01	17,78	23,91	0,02	29,48	40,42	0,02	28,43	39,03	0,02	28,44	40,00
P	1291,48	30,26	41,49	3016,79	48,54	69,19	2864,73	45,89	65,43	2684,17	46,03	66,20

m%	0,71	16,51	19,53	0,79	15,06	18,13	0,71	21,65	20,84	0,39	11,44	9,94
V%	123,79	15,80	12,10	131,99	15,86	13,88	76,05	12,71	9,85	125,90	15,49	12,78
MO	12,85	11,32	14,46	21,11	15,89	20,65	20,34	15,41	20,11	22,79	16,74	21,81
Argila	815,03	7,77	8,91	1830,74	11,56	11,70	1944,41	13,07	12,82	1816,98	11,58	10,85
Silte	502,55	12,88	13,24	1140,70	19,85	19,87	1170,40	19,21	19,78	1166,40	18,87	19,35
Areia	1783,10	5,44	7,25	4852,55	10,09	10,68	4829,61	9,36	9,02	5431,27	10,56	11,27

EMQ – Erro médio quadrático; P(C) – Erro médio relativo (%) 120 amostras; P(C2) – Erro médio relativo (%) Conjunto de Dados 2 : Não entraram no treinamento e/ou cálculo dos pesos; pH-Potencial Hidrogeniônico; Ca – Cálcio (cmolc dm-3); Mg - Magnésio; Al – Alumínio; H+AL – Acidez Potencial; CTC – Capacidade de Troca Catiônica; P – Fósforo; K – Potássio; m % - Saturação por Alumínio V% - Saturação por Bases MO- Matéria Orgânica.

O atributo Fósforo (P) foi estimado pela respectiva RNA selecionada com P(C) de 30,26% e P(C2) igual a 41,49%, sendo esta a pior performance de estimativa realizada para um atributo de solo utilizando RNA na área sob estudo (Tabela 2).

O resumo do erro médio relativo dos atributos que apresentaram dependência espacial entre os valores aferidos versus os estimados tanto pela krigagem ordinária quanto pelas RNAs selecionadas são apresentados na tabela 3.

A ocorrência de anomalia de valores na área sob estudo impacta diretamente na precisão das estimativas realizadas. Se for realizada em uma área onde a ocorrência dos valores é mais uniforme, a estimativa terá maior precisão. Por outro lado, se os valores considerados apresentarem maior variação ou *outliers* a precisão da estimativa será pior. Esse fato independe do método selecionado, qualquer estimativa terá melhores resultados com baixa variabilidade e piores resultados com alta variabilidade (ISAAKS e SRIVASTAVA, 1989).

Tabela 3. Resumo do erro médio relativo (%) entre valores aferidos e estimados pela Krigagem ordinária e redes neurais artificiais.

Atributo	P (KO)	P (RNA 1AR)	P (RNA 2AR)	P (RNA 3AR)	P (RNA 4AR)
Mg	24,47	16,25	24,63	26,56	25,60
CTC	9,29	9,89	10,91	9,94	10,51
m%	22,26	16,51	15,06	21,65	11,44
MO	17,35	11,32	15,89	15,41	16,74
Argila	13,22	7,77	11,56	13,07	11,58

Mg – Magnésio; CTC – Capacidade de Troca Catiônica; MO- Matéria Orgânica; m% - Saturação por Alumínio; P(KO) (%) - Erro médio relativo Krigagem Ordinária; P (RNA 1AR) (%) - Erro médio relativo Rede Neural Artificial Selecionada de um Ponto Amostral Relativo; P (RNA 2AR) (%) - Erro médio relativo Rede Neural Artificial Selecionada de dois Pontos Amostrais Relativos; P (RNA 3AR) (%) - Erro médio relativo Rede Neural Artificial Selecionada de três Pontos Amostrais Relativos; P (RNA 4AR) (%) - Erro médio relativo Rede Neural Artificial Selecionada de quatro Pontos Amostrais Relativos.

Conclusão

Todas as RNAs selecionadas adquiriram o conhecimento necessário para estimar os resultados dos atributos de solo analisados independente do atributo apresentar dependência espacial, requisito necessário para proceder krigagem na análise geoestatística.

As RNAs, após treinadas, realizaram a inferência dos valores dos atributos considerados utilizando no máximo 4 pontos amostrais, enquanto que Krigagem ordinária utilizou 120 pontos amostrais.

Considerando as comparações entre os valores estimados pelas RNAs selecionadas, cinco atributos de solo foram estimados com erro menor que 8%, seis atributos com erro entre 9% a 15%, três atributos com erro entre 15% a 18% e um atributo com erro igual à 30,26%.

Dentre os cinco atributos que apresentaram dependência espacial na análise geoestatística, quatro: Mg MO, m% e Argila foram melhores estimados com o uso das respectivas redes neurais selecionadas do que utilizando Krigagem ordinária. A estimativa da CTC apresentou resultado desfavorável à RNA de 0,5%.

Referências

- [1] MOLIM J.P.; CASTRO C.N.; Establishing management zones using soil electrical conductivity and other soil properties by the fuzzy clustering technique. **Revista Scientia Agricola**, Piracicaba, v.65, n.6., p.567-573. 2008. ISSN 1678-992X (on-line).
- [2] VIEIRA, S.R. **Geoestatística em estudos de variabilidade espacial de solo**. In: NOVAIS, R.F.; ALVAREZ, V.H.; SCHAEFER, C.R.G.R. (eds). Tópicos em ciência do solo Viçosa: Sociedade Brasileira de Ciência do Solo, 2000. v.1, p.1-53
- [3] GREGO, C. R.; VIEIRA, S. R. Variabilidade Espacial de Propriedades Físicas do Solo em uma Parcela Exeperimental. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 29, p. 169-177, 2005.
- [4] SANTOS, M.C.N.; MELLO, J.M.; MELLO C.R.; ÁVILLA L.F. Spatial Continuity of soil attributes in the Atlantic Forest remnant in the Mantiqueira Range, MG; **Ciência Agrotecnologia**, Lavras, v. 37, n.1, p.68-77, 2013.
- [5] NOROUZI, M.; YOUNI, S. A.; JALALIAN A., KHADEMI, H.; DEHGNANI & A.A. Predição da qualidade e quantidade do trigo de sequeiro utilizando rede neural artificial usando características de terreno e solo. **Acta Agriculturae Scandinavica. Section B. Soil and Plant Science**. v.60, n.4., p.341-353. 2010. ISSN1651-1913 (on-line).
- [6] ANGELICO, J. C.; SILVA, I.N. Redes neurais artificiais aplicadas na estimativa da variabilidade de atributos do solo, SP. **Revista Científica FACOL/ISEOL**, São Paulo, v. 1, p. 9-20, 2014. ISSN 2359-0645 (on line).
- [7] HAYKIN, S. S. **Redes Neurais – Princípios e Práticas**. 2ª. ed. Porto Alegre: Bookman, 2001. 900 p.
- [8] SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. 1ª. ed. São Paulo: Artliber, 2010. 399 p.
- [9] REIS, J. D. S. **Determinação de zonas de manejo para adubação nitrogenada em lavoura de tomate industrial**. 2011. 67 p. Dissertação Mestrado em Engenharia Agrícola - Universidade Estadual de Goiás. Anápolis, 2011

- [10] TUKEY, J. **Exploratory Data Analysis**, Addison-Wesley, 1977, p. 43-44.
- [11] SHAPIRO, S.S.; WILK, M.B. Na analysis of variance test for normality (complete sample). **Biometrika**, London, v.52, n. 3/4, p. 591-611, 1965.
- [12] BRAGA, A. D. P.; CARVALHO, A. P. D. L. F. D.; LUDERMIR, T. B. **Redes Neurais Artificiais - Teoria e Aplicações**. 2ª. ed. Rio de Janeiro: LTC, 2012. 226p.
- [13] RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 3ª. ed. Rio de Janeiro: Campus, 2013.1016 p.
- [14] BITTAR, R. D. **Redes neurais artificiais aplicadas à modelagem da variabilidade espacial de atributos físico-químicos de solos do cerrado**. 2016. 112 p. Dissertação Mestrado em Engenharia Agrícola - Universidade Estadual de Goiás. Anápolis, 2016.
- [15] CAVALCANTE, E. G. S.; ALVES, M. C.; SOUZA, Z. M.; PEREIRA, G. T. Variabilidade espacial de atributos químicos do solo sob diferentes usos e manejos. **Revista Brasileira de Ciência do Solo**. v.31, p.1329-1339, 2007.
- [16] WARRICK, A.W.; NIELSEN, D.R. Spatial variability of soil physical in the field. In: HILLEL, D. (ed). **Applications of soil physics**. New York: Academic, 1980. P. 319-344.
- [17] ISAACS, E.H.; SRIVASTAVA, R.M. **An introduction to applied geostatistic**. New York, Oxford University Press, 1989. 561p.