

UNIVERSIDADE ESTADUAL DE GOIÁS
CAMPUS ANÁPOLIS DE CIÊNCIAS EXATAS E TECNOLÓGICAS - HENRIQUE
SANTILLO
MESTRADO *STRICTO SENSU* EM ENGENHARIA AGRÍCOLA

**REDE NEURAL ARTIFICIAL NA PREDIÇÃO DE ATRIBUTOS FÍSICOS E
QUÍMICOS DO SOLO**

Elaine de Fatima Miranda Freitas

ANÁPOLIS - GO
FEVEREIRO / 2018

REDE NEURAL ARTIFICIAL NA PREDIÇÃO DE ATRIBUTOS FÍSICOS E QUÍMICOS DO SOLO

Elaine de Fatima Miranda Freitas

Orientadora: Prof^ª. Dr^ª. Sueli Martins de Freitas Alves

Dissertação apresentada à Universidade Estadual de Goiás - UEG, Campus Anápolis de Ciências Exatas e Tecnológicas - Henrique Santillo, como parte das exigências do Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola - Sistemas Agroindustriais, para obtenção do título de MESTRE.

ANÁPOLIS - GO
FEVEREIRO / 2018

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da UEG
com os dados fornecidos pelo(a) autor(a).

FF866r Freitas, Elaine de Fatima Miranda
Rede neural artificial na predição de atributos físicos e químicos do solo / Elaine de Fatima Miranda Freitas; orientador Sueli Martins de Freitas Alves. -- Anápolis, 2018.
102 p.

Dissertação (Mestrado - Programa de Pós-Graduação Mestrado Acadêmico em Engenharia Agrícola) -- Câmpus-Anápolis CET, Universidade Estadual de Goiás, 2018.

1. Ciências Agrárias. 2. Inteligência artificial. 3. Agricultura de precisão. 4. Geoestatística. 5. Lógica Fuzzy. I. Alves, Sueli Martins de Freitas, orient. II. Título.


**REDE NEURAL ARTIFICIAL NA PREDIÇÃO DE ATRIBUTOS FÍSICOS E
QUÍMICOS DO SOLO**

Por

Elaine de Fátima Miranda Freitas

Dissertação apresentada como parte das exigências para obtenção do título de
MESTRA EM ENGENHARIA AGRÍCOLA

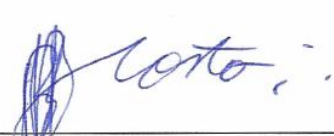
Aprovado em 27/02/2018



Profa. Dra. Sueli Martins de Freitas Alves
Orientadora
UEG/CCET



Prof. Dr. Francisco Ramos de Melo
Membro
UEG/CCET



Prof. Dr. Rommel Bernardes da Costa
Membro
UFG/EA

A meus pais, Joaquim Cardoso de Freitas e Deuseli de Fatima Miranda de Freitas, pelo apoio e amor incondicional. A vocês todo o meu amor e gratidão.

AGRADECIMENTOS

A Deus, de infinita misericórdia, por me conceder saúde e força para correr atrás de meus objetivos e por sempre iluminar meus caminhos.

A minha professora e orientadora Dra. Sueli Freitas, por ter me recebido e sempre me mostrado o caminho correto a ser seguido, de forma única, admirável e exemplar. Desejo poder contribuir a ciência com a mesma ética e entusiasmo que me transmitiu. Espero também que nossas agradáveis conversas tenham vida longa.

Ao meu noivo Hiago Farias, por todo amor, companheirismo, compreensão e colaboração, meu muito obrigada por estar ao meu lado sempre.

Aos meus familiares, especialmente meus pais por compreenderem minha ausência em muitos momentos e principalmente pelo estímulo constante.

Aos amigos (a): Luana Lopes, Verônica Soares, Jéssica Caetano, Caroline Xavier, Cláudio Magela, Fernando Camargo, Isneider Silva, Ivandro Rocha, pelas palavras amigas e colaboração na pesquisa.

Aos professores e colaboradores da UEG: Anamaria Achtschin, Roberta Passini, Francisco Ramos, André Campos, Itamar Teixeira, Ivano Devilla, Elton Fialho, Eliete Feitosa, Waldeir Costa, pelos ensinamentos.

A Universidade Estadual de Goiás - UEG, Campus de Ciências Exatas e Tecnológicas - CCET, ao departamento de Engenharia Agrícola e ao Programa de Pós-Graduação em Engenharia Agrícola.

A Coordenação de Aperfeiçoamento de Pessoas de Nível Superior (CAPES), pela concessão da bolsa de estudos.

Enfim, a todos que de alguma forma contribuíram para que este trabalho fosse realizado: fico-lhes muito agradecida!

BIOGRAFIA

Elaine de Fatima Miranda Freitas, nascida em Leopoldo de Bulhões, Goiás, concluiu o curso de Engenharia Agrícola na Universidade Estadual de Goiás (UEG-CCET) em 2015. Durante a graduação foi membro da empresa júnior Sênior Agrícola e desenvolveu projetos de iniciação científica. No ano de 2016 iniciou o curso de Mestrado em Engenharia Agrícola no programa da Universidade Estadual de Goiás – UEG, Campus Anápolis de Ciências Exatas e Tecnológicas - Henrique Santillo.

SUMÁRIO

| | |
|---|------------|
| RESUMO..... | XV |
| ABSTRACT | XVI |
| 1. INTRODUÇÃO GERAL | 1 |
| 2. REVISÃO DE LITERATURA | 4 |
| 2.1. ATRIBUTOS DE SOLO | 4 |
| 2.2. AGRICULTURA DE PRECISÃO | 4 |
| 2.3. GEOESTATÍSTICA | 5 |
| 2.4. REDES NEURAS ARTIFICIAIS | 8 |
| 2.5. CULTURA DO TOMATE INDUSTRIAL..... | 10 |
| 2.6. TRABALHOS CORRELATOS | 11 |
| 3. REFERÊNCIAS BIBLIOGRÁFICAS..... | 12 |
| CAPÍTULO 1 | |
| PREDIÇÃO DE ATRIBUTOS FÍSICOS E QUÍMICOS DO SOLO POR MEIO DE UMA REDE NEURAL ARTIFICIAL | 18 |
| 1. INTRODUÇÃO | 18 |
| 2. MATERIAL E MÉTODOS..... | 20 |
| 2.1. Caracterização e localização da área experimental | 20 |
| 2.2. Mapeamento da área e georreferenciamento dos pontos amostrais | 20 |
| 2.3. Determinação dos atributos físicos e químicos do solo | 20 |
| 2.4. Rede neural artificial na predição dos atributos de solo..... | 21 |
| 2.4.1. Seleção dos pontos amostrais e variáveis de entrada na RNA..... | 21 |
| 2.4.2. Normalização dos dados para entrada na RNA..... | 21 |
| 2.4.3. Geração das matrizes de dados para aplicar na RNA..... | 22 |
| 2.4.4. Estimativa dos atributos de solo utilizando a RNA..... | 23 |
| 2.5. Estatística descritiva..... | 23 |
| 2.6. Análise geoestatística para os dados originais da análise de solo e para os dados estimados pela RNA..... | 24 |
| 2.7. Teste para comparação de médias | 25 |
| 2.8. Indicadores estatísticos para avaliar a eficiência das estimativas obtidas pela RNA..... | 25 |
| 3. RESULTADOS E DISCUSSÃO | 27 |
| 3.1. Rede neural artificial na predição dos atributos de solo..... | 27 |
| 3.1.1. Estimativas dos atributos físicos e químicos do solo utilizando RNA..... | 27 |
| 3.2. Análise Estatística | 30 |
| 3.2.1. Análise Exploratória..... | 30 |
| 3.2.2. Análise Geoestatística | 33 |
| 3.2.3. Qualidade do ajuste do semivariograma | 35 |
| 3.3. Comparação dos resultados da análise de solo, resultados da rede neural e da análise geoestatística (krigagem ordinária) | 43 |
| 3.4. Erro médio relativo dos valores estimados a partir da krigagem | 44 |

| | |
|--|-----------|
| 3.5. Eficiência da RNA na estimativa dos atributos..... | 44 |
| 4. CONCLUSÕES..... | 48 |
| 5. REFERÊNCIAS BIBLIOGRÁFICAS | 49 |
| CAPÍTULO 2 | |
| ÍNDICE DE ACURÁCIA DE MAPAS DE VARIABILIDADE ESPACIAL DE FERTILIDADE DO SOLO ORIUNDOS DE DADOS ESTIMADOS POR UMA REDE NEURAL ARTIFICIAL | 53 |
| 1. INTRODUÇÃO | 53 |
| 2. MATERIAL E MÉTODOS | 55 |
| 2.1. Caracterização e localização da área experimental | 55 |
| 2.2. Mapeamento da área e georreferenciamento dos pontos amostrais | 55 |
| 2.3. Atributos físicos e químicos do solo | 55 |
| 2.3.1. Determinação dos atributos pela análise de solo..... | 55 |
| 2.3.2. Estimativas dos atributos do solo por meio da Rede Neural Artificial (RNA) | 56 |
| 2.4. Fertilidade do solo utilizando lógica fuzzy | 56 |
| 2.5. Recomendação de corretivos e fertilizantes | 57 |
| 2.6. Estatística descritiva para os dados de fertilidade do solo, recomendação de corretivos e fertilizantes | 58 |
| 2.7. Análise geoestatística para os dados de fertilidade do solo, recomendação de corretivos e fertilizantes | 58 |
| 2.8. Acurácia temática dos mapas | 59 |
| 2.8.1. Matriz de confusão (ou matriz de erro)..... | 59 |
| 2.8.1.1. Definição das classes da matriz de confusão | 59 |
| 2.8.2. Exatidão Global..... | 60 |
| 2.8.3. Índice Kappa | 60 |
| 3. RESULTADOS E DISCUSSÃO | 62 |
| 3.1. Rede neural artificial na predição dos atributos de solo..... | 62 |
| 3.2. Estatística descritiva para os dados de fertilidade do solo, recomendação de corretivos e fertilizantes | 62 |
| 3.3. Análise geoestatística para os dados de fertilidade do solo, recomendação de corretivos e fertilizantes | 63 |
| 3.4. Mapas de fertilidade do solo, recomendação de corretivo e fertilizante..... | 64 |
| 3.5. Acurácia temática dos mapas | 66 |
| 4. CONCLUSÕES..... | 68 |
| 5. REFERÊNCIAS BIBLIOGRÁFICAS..... | 69 |
| 6. CONCLUSÕES GERAIS | 72 |
| ANEXOS | |
| ANEXO A - GRÁFICOS BOXPLOT PARA IDENTIFICAÇÃO DE OUTLIERS E CRITÉRIO DE REJEIÇÃO DE TUKEY (1960) | 73 |

| | |
|--|-----------|
| ANEXO B - ANÁLISE DESCRITIVA DOS ATRIBUTOS COM E SEM A PRESENÇA DE OUTLIERS..... | 74 |
| ANEXO C - GRÁFICOS DE REGRESSÃO PARA OS DADOS DETERMINADOS PELA ANÁLISE DE SOLO E OS DADOS ESTIMADOS PELA RNA..... | 75 |
| ANEXO D - MATRIZ DE ERRO E CÁLCULO DOS ÍNDICES KAPPA E EXATIDÃO GLOBAL DOS DADOS DETERMINADOS PELA ANÁLISE DE SOLO EM RELAÇÃO AOS DADOS ESTIMADOS PELA RNA..... | 77 |
| ANEXO E - MAPAS DE ISOLINHAS PARA OS ATRIBUTOS QUÍMICOS E FÍSICOS DO SOLO DADOS DETERMINADOS PELA ANÁLISE DE SOLO E OS DADOS ESTIMADOS PELA RNA..... | 85 |

LISTA DE TABELAS

CAPÍTULO 1

| | |
|---|----|
| TABELA 1 - Limites para normalização das variáveis de entrada da RNA. | 22 |
| TABELA 2 - Estatística descritiva dos atributos de solo na profundidade de (0 - 20 m). | 31 |
| TABELA 3 - Modelos teóricos de semivariograma ajustados para os atributos de solo determinados pela análise de solo e os estimados pela RNA. | 34 |
| TABELA 4 - Teste-t de Student para comparação de média dos resultados da análise de solo, resultados da rede neural e da análise geoestatística (krigagem ordinária). | 43 |
| TABELA 5 - Erro médio relativo P (%) entre os valores obtidos pela análise de solo e obtidos pela RNA estimados pela Krigagem ordinária. | 44 |
| TABELA 6 - Erro médio relativo (P%), coeficiente linear (a), coeficiente angular (b), coeficiente de determinação (R^2), coeficiente de correlação (r), índice de concordância (c) e índice de desempenho (id), obtidos na comparação entre os dados dos atributos determinados na análise de solo e estimados pela RNA. | 45 |

CAPÍTULO 2

| | |
|--|----|
| TABELA 1 - Critério para definição de fertilidade do solo para hortaliças. | 57 |
| TABELA 2 - Recomendação de adubação para o tomate industrial no cerrado. | 57 |
| TABELA 3 - Modelo da matriz de confusão utilizada para o cálculo da acurácia temática..... | 59 |
| TABELA 4 - Critério para definição das classes para compor a matriz de confusão. | 60 |
| TABELA 5 - Estatística descritiva da fertilidade, recomendação de corretivos e fertilizantes do solo. | 63 |
| TABELA 6 - Modelos teóricos de semivariograma ajustados para os atributos de fertilidade, recomendação de corretivos e fertilizantes do solo. | 64 |
| TABELA 7 - Resultados dos índices de acurácia Kappa e Exatidão Global. | 67 |

ANEXOS

ANEXO B

| | |
|--|----|
| TABELA 1 - Análise descritiva dos atributos com e sem a presença de outliers. | 74 |
|--|----|

ANEXO D

| | |
|--|----|
| TABELA 1 - Matriz de erro para a análise da acurácia das estimativas do atributo potencial hidrogeniônico (pH). | 77 |
| TABELA 2 - Matriz de erro para a análise da acurácia das estimativas do atributo cálcio (Ca)..... | 77 |
| TABELA 3 - Matriz de erro para a análise da acurácia das estimativas do atributo Magnésio (Mg)..... | 78 |
| TABELA 4 - Matriz de erro para a análise da acurácia das estimativas do atributo Cálcio + Magnésio (Ca+Mg). | 78 |
| TABELA 5 - Matriz de erro para a análise da acurácia das estimativas do atributo acidez potencial (H+Al). | 79 |

| | |
|---|----|
| TABELA 6 - Matriz de erro para a análise da acurácia das estimativas do atributo Capacidade de troca catiônica (CTC). | 79 |
| TABELA 7 - Matriz de erro para a análise da acurácia das estimativas do atributo fósforo (P)..... | 80 |
| TABELA 8 - Matriz de erro para a análise da acurácia das estimativas do atributo saturação por bases (V%)..... | 80 |
| TABELA 9 - Matriz de erro para a análise da acurácia das estimativas do atributo Matéria orgânica (MO). | 81 |
| TABELA 10 - Matriz de erro para a análise da acurácia das estimativas do atributo Argila..... | 81 |
| TABELA 11 - Matriz de erro para a análise da acurácia das estimativas do atributo Silte..... | 82 |
| TABELA 12 - Matriz de erro para a análise da acurácia das estimativas do atributo Areia. | 82 |
| TABELA 13 - Matriz de erro para a análise da acurácia das estimativas da Fertilidade do solo. | 83 |
| TABELA 14 - Matriz de erro para a análise da acurácia das estimativas da necessidade de calagem (NC). | 83 |
| TABELA 15 - Matriz de erro para a análise da acurácia das estimativas da necessidade de fósforo (NP). | 84 |

LISTA DE FIGURAS

REVISÃO DE LITERATURA

| | |
|--|---|
| FIGURA 1 - Variograma experimental, modelo teórico e seus parâmetros. | 6 |
| FIGURA 2 - Neurônio McCulloch e Pitts (MCP). | 9 |

CAPÍTULO 1

| | |
|---|----|
| FIGURA 1 - (a) Pivô central; (b) Área experimental. | 20 |
| FIGURA 2 - (a) 4 pontos amostrais conhecidos selecionados; (b) 120 estimativas obtidas a partir de 4 pontos amostrais conhecidos. | 27 |
| FIGURA 3 - Gráfico comparativo dos valores determinados na análise de solo <i>versus</i> valores estimados pela RNA. (a) pH - potencial hidrogeniônico, (b) Ca - cálcio, (c) Mg - magnésio, (d) Ca+Mg - cálcio + magnésio, (e) Al - alumínio, (f) H+Al - acidez potencial, (g) K - potássio, (h) P - fósforo, (i) m% - saturação por alumínio e (j) MO - matéria orgânica. | 28 |
| FIGURA 4 - Gráfico comparativo dos valores determinados na análise de solo <i>versus</i> valores estimados pela RNA. (a) CTC - capacidade de troca catiônica e (b) V% - saturação por bases..... | 29 |
| FIGURA 5 - Gráfico comparativo dos valores determinados na análise de solo <i>versus</i> valores estimados pela RNA. (a) Argila, (b) Silte e (c) Areia. | 29 |
| FIGURA 6 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo pH, dos dados determinados pela análise de solo e os estimados pela RNA..... | 36 |
| FIGURA 7 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Ca, dos dados determinados pela análise de solo e os estimados pela RNA..... | 37 |
| FIGURA 8 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Mg, dos dados determinados pela análise de solo e os estimados pela RNA..... | 37 |
| FIGURA 9 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Ca+Mg, dos dados determinados pela análise de solo e os estimados pela RNA..... | 38 |
| FIGURA 10 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo H+Al, dos dados determinados pela análise de solo e os estimados pela RNA. | 38 |
| FIGURA 11 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo P, dos dados determinados pela análise de solo e os estimados pela RNA..... | 39 |
| FIGURA 12 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo MO, dos dados determinados pela análise de solo e os estimados pela RNA..... | 39 |
| FIGURA 13 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada do atributo CTC, dos dados determinados pela análise de solo e os estimados pela RNA..... | 40 |

| | |
|--|----|
| FIGURA 14 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo V%, dos dados determinados pela análise de solo e os estimados pela RNA..... | 40 |
| FIGURA 15 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Argila, dos dados determinados pela análise de solo e os estimados pela RNA. | 41 |
| FIGURA 16 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Silte, dos dados determinados pela análise de solo e os estimados pela RNA. | 42 |
| FIGURA 17 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Areia, dos dados determinados pela análise de solo e os estimados pela RNA. | 42 |

CAPÍTULO 2

| | |
|--|----|
| FIGURA 1 - (a) Pivô central; (b) Área experimental. | 55 |
| FIGURA 2 - (a) 4 pontos amostrais conhecidos selecionados; (b) 120 estimativas obtidas a partir de 4 pontos amostrais conhecidos. | 62 |
| FIGURA 3 - Mapas de isolinhas da (a) fertilidade do solo, (b) fertilidade do solo RNA, (c) necessidade de calcário, (d) necessidade de calcário RNA, (e) necessidade de fósforo e (f) necessidade de fósforo RNA. | 65 |

ANEXOS

ANEXO A

| | |
|--|----|
| FIGURA 1 - Gráficos boxplot de atributos pH, Ca+Mg, H+Al, P e V% que tiveram a presença de outliers à esquerda. Gráficos boxplot dos atributos do solo após eliminação de outliers pelo teste de Tukey à direita. | 73 |
|--|----|

ANEXO C

| | |
|---|----|
| FIGURA 1 - Gráficos de regressão para os dados determinados pela análise de solo e os dados estimados pela RNA. (a) pH - potencial hidrogeniônico; (b) Ca - cálcio; (c) Mg - magnésio; (d) Ca+Mg - cálcio + magnésio; (e) Al - alumínio; (f) H+Al - acidez potencial; (g) CTC - capacidade de troca catiônica; (h) K - potássio; (i) P - fósforo; (j) m% - saturação por alumínio; (k) V% - saturação por bases; (l) MO - matéria orgânica; (m) Argila; (n) Silte; (o) Areia..... | 76 |
|---|----|

ANEXO E

| | |
|--|----|
| FIGURA 1 - Mapas de isolinhas para os atributos pH, Ca, Mg, Ca+Mg, H+Al, P, MO, CTC, V%, argila, silte e areia dos dados determinados na análise de solo e os dados estimados por meio da RNA utilizando 4 pontos amostrais conhecidos. | 87 |
|--|----|

Rede neural artificial na predição de atributos físicos e químicos do solo

RESUMO

O tomateiro é considerado uma das hortaliças mais exigentes em nutrientes presentes no solo e o estudo das propriedades físicas e químicas do solo é um procedimento de custo e tempo relativamente elevado. Na busca de alternativas para prever esses atributos a partir de um número menor de amostras do solo, o uso de Redes Neurais Artificiais (RNA) tem sido apontada como uma técnica computacional com grande capacidade de resolver problemas por meio da experiência, pois possuem a capacidade de aquisição e manutenção do conhecimento. Esse trabalho teve por objetivo avaliar a eficiência das estimativas de atributos físicos e químicos do solo obtidas por meio de uma rede neural artificial. Os dados foram coletados em uma área de 23 ha em uma lavoura de tomate industrial irrigada por pivô central no município de Morrinhos (GO). As amostras deformadas de solo foram coletadas na profundidade de 0,0 a 0,2 m utilizando uma grade amostral de 50x50 m, totalizando 120 pontos amostrais para determinação dos atributos físicos e químicos do solo. Foram selecionados aleatoriamente 4 pontos amostrais conhecidos dos 120 pontos obtidos na análise de solo, para compor as variáveis de entrada de aplicação na RNA, após obtenção das estimativas dos atributos físicos e químicos utilizando a RNA juntamente com os dados determinados pela análise de solo, esses foram submetidos à análise descritiva, análise geoestatística (krigagem ordinária), Teste-t de Student, análise de fertilidade do solo por lógica Fuzzy, necessidade de fertilizantes e corretivo e análise de acurácia dos mapas de variabilidade espacial pelo índice Kappa e Exatidão global. O uso da técnica de RNA apresentou-se promissora para obter estimativas de atributos de solo empregando um número menor de amostras de solo. A RNA adquiriu o conhecimento necessário para estimar valores médios dos atributos de solo com eficiência, mas o mesmo não ocorreu para estimar os atributos pontualmente. A fertilidade do solo foi classificada como boa para o cultivo de tomate industrial tanto pelos dados determinados na análise de solo como os estimados pela RNA. A área experimental, por ter apresentado áreas com maior e menor exigência de fertilizante fosfatado pode ser dividida em zonas de manejo facilitando a aplicação de forma variável.

Palavras-chave: inteligência artificial, agricultura de precisão, geoestatística, krigagem ordinária, lógica Fuzzy.

Artificial neural network in the prediction of physical and chemical soil attributes

ABSTRACT

The tomato is considered to be one of the most demanding nutrients in the soil and the study of the physical and chemical soil properties is a relatively high cost and time procedure. In the search for alternatives to predict these attributes from a smaller number of soil samples, the use of Artificial Neural Networks (RNA) has been pointed as a computational technique with great capacity to solve problems through experience, since they have the capacity of knowledge acquisition and maintenance. The objective of this work was to evaluate the efficiency of soil physical and chemical attributes estimates obtained through an artificial neural network. The data were collected in an area of 23 ha in an industrial tomato crop irrigated by central pivot in the municipality of Morrinhos (GO). The deformed soil samples were collected at a depth of 0.0 to 0.2 m using a sampling grid of 50x50 m, totaling 120 sampling points to determine the physical and chemical attributes of the soil. We randomly selected 4 known sample points from the 120 points obtained in the soil analysis, to compose the input variables of the RNA, after obtaining the estimates of the physical and chemical attributes using the RNA together with the data determined by the soil analysis, these were submitted to descriptive analysis, geostatistical analysis (ordinary kriging), Student's t-test, soil fertility analysis by Fuzzy logic, fertilizer need and corrective and accuracy analysis of spatial variability maps by Kappa index and Global accuracy. The use of RNA technique was promising to obtain estimates of soil attributes using a smaller number of soil samples. RNA acquired the knowledge necessary to estimate mean values of soil attributes efficiently, but this was not done to estimate attributes on time. Soil fertility was classified as good for the cultivation of industrial tomato both by the data determined in soil analysis and those estimated by RNA. The experimental area, for presenting areas with higher and lower requirements of phosphate fertilizer can be divided into areas of management facilitating the application of variable form.

Key words: artificial intelligence, precision agriculture, geostatistics, ordinary kriging, Fuzzy logic.

1. INTRODUÇÃO GERAL

A produção do tomate (*Solanum lycopersicum* L.) vem se destacando no cenário agroindustrial brasileiro. O estado de Goiás atualmente, apresenta 86% desta produção, o estado de São Paulo 12,7% e o estado de Minas Gerais com 1,3% da produção, o cerrado brasileiro consolida liderança em termos de área plantada e produtividade (ASSUNÇÃO et al., 2013; VILELA et al., 2012).

Independentemente do Estado de Goiás ser o maior produtor de tomate industrial, ainda se busca o equilíbrio entre a produtividade e a redução no custo de produção, sem o aumento da área cultivada. Por isso, as intervenções tecnológicas nos sistemas produtivos como, utilização de novos materiais genéticos, manejo eficiente do solo e da aplicação de insumos devem ser estudados (OLIVER et al., 2010).

Além da variabilidade natural existente em uma área de produção, existem também as fontes adicionais de heterogeneidade no solo, por causa do manejo exercido pelo homem como preparo do solo, efeitos residuais de adubos e corretivos, sistemas de manejo adotados, forma de aplicação de insumos (BURAK et al., 2016). Portanto, o conhecimento da distribuição espacial dos atributos do solo em determinada área é de extrema importância para o aperfeiçoamento das práticas de manejo e avaliação dos efeitos da agricultura sobre a qualidade ambiental (CAVALCANTE et al., 2011).

A agricultura de precisão apresenta a ideia que os campos de produção agrícola não são homogêneos, devido a isso, a variabilidade espacial da produtividade das culturas e os fatores que controlam esta variabilidade devem ser estudados. Deste modo, ferramentas que permitam o entendimento da variabilidade da produtividade das culturas e suas relações no tempo e no espaço, assim como os fatores que a controlam devem ser observados, desenvolvidos e testados (RODRIGUES, 2013).

O emprego de técnicas de agricultura de precisão, como sua utilização no manejo localizado da fertilidade do solo, vem sendo frequentemente utilizado. As dosagens de insumos são aplicadas de forma variável, visando atender às necessidades específicas de cada local e cultura, aumentando a produtividade, otimizando o processo de produção e reduzindo os impactos ambientais causados pelas práticas agrícolas (BOTTEGA et al., 2013).

É na agricultura de precisão que são aplicados os princípios da geoestatística para caracterizar a variabilidade espacial dos atributos que fazem parte dos fatores de produção agrícola. Identificando zonas com restrições químicas que possam estar limitando o rendimento

e posteriormente, realizar a correção de maneira adequada (AMADO et al., 2009; SANCHEZ et al., 2009).

A geoestatística é uma ferramenta eficaz para o estudo da variabilidade espacial dos atributos físicos e químicos do solo. Para isto, é conveniente que seja feita uma amostragem representativa da área, para que se possam obter dados com valores que, realmente correspondam à realidade da parcela (CAVALCANTE et al., 2011). Os atributos químicos e físicos do solo tornam-se, então, importantes para definir as práticas agrônômicas a serem adotadas nas culturas (CERRI e MAGALHÃES, 2012).

A Krigagem é o método de interpolação da geoestatística, que usa a dependência espacial expressa no semivariograma entre amostras vizinhas para estimar valores em qualquer posição dentro do campo, sem tendência e com variância mínima, essas duas características fazem da Krigagem um interpolador ótimo (SILVA et al., 2011a). Um tipo característico de interpolação por Krigagem é a chamada Krigagem ordinária, a qual trabalha com variáveis regionalizadas que tenham um comportamento estacionário. Assim, os valores estimados, bem como sua covariância espacial, não possuem uma variação sistemática, mas são caracterizados por apresentar uma mesma probabilidade de ocorrência para toda a área analisada (LANDIM et al., 2002).

A seleção do método de interpolação apropriado é essencial para obter mapas de espacialização confiáveis (PASINI et al., 2015). Os mapas estão dentre as principais ferramentas utilizadas para identificação dos fatores que afetam o desenvolvimento das culturas, são utilizados na agricultura de precisão como alternativa moderna visando gerenciar a variabilidade espacial das lavouras orientando práticas de manejo (SANA et al., 2014).

Aos poucos vem sendo estudada uma nova tecnologia para estimar os atributos físicos e químicos do solo, as redes neurais artificiais (RNAs). As RNAs são modelos computacionais que procuram imitar o raciocínio do cérebro humano. O neurônio artificial é seu componente básico e possui a capacidade de aquisição e manutenção do conhecimento. As RNAs compõem uma estrutura matemática flexível capaz de realizar mapeamentos não lineares entre informações de entrada e de saída (ANGELICO e SILVA, 2014; NOROUZI et al., 2010).

A capacidade das RNAs em resolver problemas é demonstrada cada vez mais em trabalhos na área de ciências agrárias. Binoti et al. (2013) propôs construir e validar um modelo de estimação da altura de árvores em povoamentos de eucalipto com a utilização de RNAs. O modelo proposto foi eficiente para estimação da altura de árvores, garantindo alta precisão dessas estimativas obtidas através das RNAs.

Leal et al. (2015) utilizando as RNAs mostraram resultados satisfatórios na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do

solo. Utilizando a RNA conseguiram predizer de forma aceitável a produtividade de milho, utilizando os atributos do solo matéria orgânica (MO), capacidade de troca catiônica (CTC), saturação por bases (V%) e argila.

A partir do uso de redes neurais artificiais, Soares et al. (2014) apresentaram uma proposta de metodologia para estimativa da curva de retenção de água, para solos do Estado do Rio Grande do Sul. Ao implementar o algoritmo, pôde-se inferir que o uso de redes neurais para estimativa da curva de retenção de água no solo é uma ferramenta com alta capacidade preditiva e que trará grande contribuição ao setor agrícola.

Bittar (2016) desenvolveu uma RNA com objetivo de estimar os atributos do solo. Foi realizado o treinamento, a validação e testes de diferentes RNAs e consecutiva escolha da rede que apresentou o melhor resultado. O autor concluiu que as RNAs apresentam potencial para realizar satisfatoriamente as estimativas dos atributos físicos e químicos do solo.

Este trabalho objetivou avaliar a eficiência das estimativas de atributos físicos e químicos do solo obtidas por meio de uma rede neural artificial. Sendo dividido em 2 capítulos: o Capítulo 1, “Predição de atributos físicos e químicos do solo por meio de uma rede neural artificial” e o Capítulo 2, “Índice de acurácia de mapas de variabilidade espacial de fertilidade do solo oriundos de dados estimados por uma rede neural artificial”, relacionado as estimativas obtidas pela RNA no Capítulo 1.

2. REVISÃO DE LITERATURA

2.1. Atributos de solo

A qualidade do solo está relacionada com seus componentes físicos, químicos e biológicos e entender a distribuição espacial dos atributos dos solos é de extrema importância, o que pode ser demonstrado por resultados dos levantamentos e análises dos solos, bem como pelas diferenças encontradas nas produções das plantas (ROSA et al., 2015; SILVA et al., 2015; BOTTEGA et al., 2013).

Melhorar a distribuição dos atributos químicos do solo, provenientes de manejos inadequados, associados à monocultura e ao preparo excessivo do solo é essencial para um manejo consciente do solo (BARETTA et al., 2011). Pois, a maioria dos solos do cerrado tem sido diagnosticados como de baixa fertilidade natural, apresentando interferência direta na disponibilidade de nutrientes para as plantas se desenvolverem e atingirem altas produtividades (BOTTEGA et al., 2013; KLINK e MACHADO, 2005).

2.2. Agricultura de precisão

A Agricultura de Precisão (AP) é um sistema de gestão da produção agrícola composta por tecnologias e procedimentos utilizados para a melhoria dos campos e sistemas de produção. Visando minimizar os efeitos indesejáveis ao ambiente e aumentar a produtividade, tendo como elemento chave o gerenciamento da variabilidade espacial (MONDO et al., 2012).

Mesmo em áreas consideradas homogêneas e pertencentes a mesma classe, o solo normalmente apresenta variações nos seus atributos a curtas distâncias e em grau suficiente para interferir na produtividade das culturas (AMARO FILHO et al., 2007). Isso ocorre, pois, o material de origem dos solos não é uniforme devido às diferenças com relação à dureza, composição química, cristalização, condições de relevo, clima e organismos que atuam na gênese dos mesmos (MATIAS et al., 2015; SILVA et al., 2010a). A variabilidade espacial dessas características em campos agrícolas é importante para a adoção de técnicas de agricultura de precisão (ZONTA et al., 2014; SERRANO et al., 2010).

Aliada à evolução da tecnologia na agricultura, pesquisas têm demonstrado a importância da modelagem da variação espacial de atributos do solo que afetam a produtividade das culturas (DALCHIAVON et al., 2017; SOUZA et al., 2014). Visto que tais informações possibilitam definir zonas homogêneas de manejo específico, com o objetivo de efetuar a aplicação de calcário e fertilizantes a taxas variáveis, proporcionando um manejo mais eficiente e econômico da

cultura, atendendo às condições necessárias à agricultura de precisão (DALCHIAVON et al., 2012).

A variabilidade espacial dos atributos dos solos pode ser demonstrada por resultados dos levantamentos das análises dos solos, bem como a produção das cultivares (MATIAS et al., 2015; SILVA et al., 2010a). A análise detalhada da variabilidade dos atributos do solo pode indicar tomadas de decisões, orientando práticas de manejo com base nos mapas de aplicação de insumos à taxa variável (MOLIN e RABELO, 2011).

2.3. Geoestatística

O engenheiro de minas Daniel G. Krige e o professor H. J. Wijs, no início dos anos 50 na África do Sul, desenvolveram empiricamente uma técnica própria de estimativa para o cálculo de reservas minerais, a qual posteriormente recebeu tratamento formal por Georges Matheron, na França o nome Geoestatística, para o estudo das variáveis regionalizadas (YAMAMOTO e LANDIM, 2013).

O mapeamento da variabilidade espacial de atributos do solo é uma preocupação antiga, e seu conhecimento é importante para todos aqueles que visam uma agricultura sustentável (GUIMARÃES et al., 2016; WEIRICH NETO et al., 2006), pois permite a separação de zonas de manejo, por meio do estudo da variabilidade espacial dos atributos do solo a partir da geoestatística (BURAK et al., 2016).

O objetivo da geoestatística é caracterizar a variabilidade espacial dos atributos do solo e das plantas e fazer uma estimativa, utilizando o princípio da variabilidade espacial, com a finalidade de identificar inter-relações desses atributos no espaço e no tempo, além de permitir estudar padrões de amostragem adequados (NOETZOLD et al., 2014).

O semivariograma é a principal ferramenta utilizada na geoestatística por meio da Krigagem, que mostra a natureza estrutural de uma variável regionalizada definida pela comparação entre dois ou mais pontos obtidos simultaneamente, em razão das suas distâncias (SANTOS et al., 2013). Uma aplicação imediata do semivariograma é a utilização das informações geradas por ele na interpolação, ou seja, na estimativa de dados e posterior mapeamento da variável (VIEIRA et al., 2011).

O semivariograma permite verificar e modelar o grau de dependência entre amostras ao longo de um suporte específico para as chamadas variáveis regionalizadas, representadas por $Z(x)$ em que x indica a localização da amostra, coletadas em diversos pontos que podem estar regularmente distribuídos ou não. Caso haja a dependência espacial, o valor de cada ponto deverá apresentar um relacionamento, de algum modo, com valores obtidos no entorno deste ponto e a

influência dos mesmos será tanto maior quanto menor forem as distâncias que os separam. Assim, os semivariogramas foram construídos com base no cálculo da semivariância $y(h)$, para valores encontrados ao longo da distância h , separados por Δh , por meio da Equação 1 (SANTOS et al., 2011):

$$y(h) = \frac{1}{2N} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (1)$$

Em que:

$y(h)$ - Semivariância estimada a partir de dados experimentais;

N - Número de pares de dados para a distância de separação (h);

$Z(x_i)$ - Valor da variável medida na posição x_i ;

$Z(x_i+h)$ - Valor da variável medida na posição (x_i+h);

i - Posição da amostra;

h - Distância entre duas amostras, m.

A Figura 1 representa o ajuste do variograma experimental a um teórico, bem como os parâmetros do modelo. Na teoria temos que a variância $y(h)$ cresce com o incremento de h , até atingir um valor constante para $y(h)$ que corresponde às variações aleatórias, ou seja, variações que não são justificadas pela semelhança de um ponto com outro. Para o ajuste de um modelo matemático aos valores estimados de $y(h)$ são definidos os coeficientes do modelo teórico para o semivariograma (o efeito pepita C_0 , patamar $C_0 + C_1$, e o alcance a) (SILVA et al., 2013).

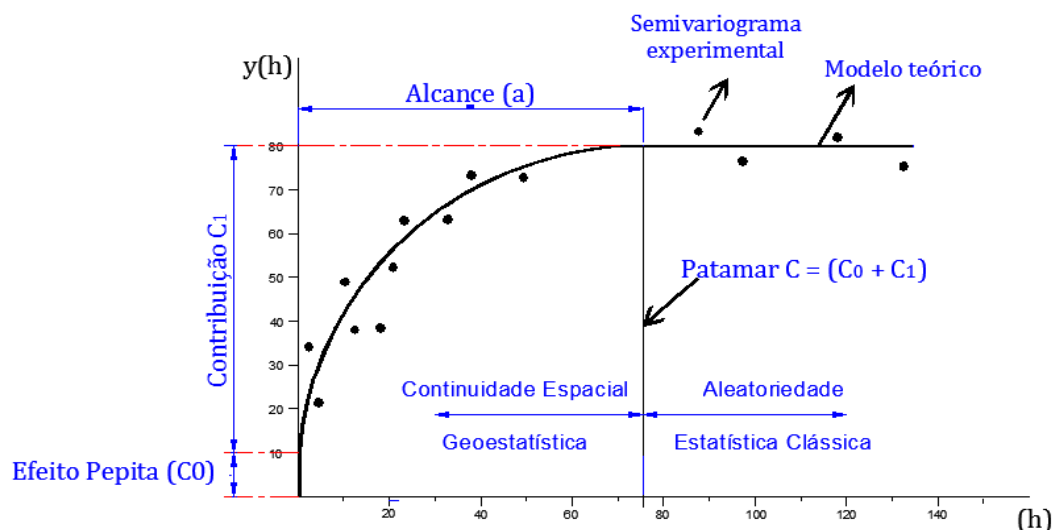


FIGURA 1 - Variograma experimental, modelo teórico e seus parâmetros.

Fonte: Adaptado de Landim e Sturaro (2002).

O semivariograma é formado por algumas grandezas: alcance (a), indica a distância a partir da qual as amostras passam a não possuir correlação espacial e a relação entre elas torna-

se aleatória; efeito pepita (C_0), pode ser resultado tanto da variabilidade do fenômeno espacial em estudo como da escala de amostragem; patamar (C), o qual refere-se ao valor em que ocorre a estabilidade no campo aleatório e a contribuição (C_1), que reflete as diferenças espaciais entre os valores de uma variável analisada em dois pontos com distâncias sucessivamente maiores (YAMAMOTO e LANDIM, 2013; LANDIM e STURARO, 2002).

As estimativas geoestatística, fazem uso da função semivariograma, que não é simplesmente uma função da distância entre pontos, mas depende da existência ou não do efeito pepita, da amplitude e da presença de anisotropia. A estimativa geoestatística tem por objetivo a modelagem do fenômeno espacial em estudo, ou seja, determinar a distribuição e variabilidade espaciais da variável de interesse (YAMAMOTO e LANDIM, 2013).

A variabilidade de qualquer variável espacial avaliada em um fenômeno pode ser dividida em dois tipos básicos, chamada de tendência e outra denominada de dependência espacial. A Geoestatística considera os dois tipos de variabilidade para explicar a continuidade observada em dados espaciais, reservando a média para modelar a estrutura da tendência e a semivariância, para modelar a estrutura de dependência espacial. A avaliação da significância da dependência espacial, quando feita, é realizada por meio da interpretação de algum indicador de dependência espacial, como, por exemplo, a medida do grau de dependência espacial (SEIDEL e OLIVEIRA, 2014).

As relações entre o efeito pepita e o patamar demonstram predominância do grau da dependência espacial. Quanto maior a dependência espacial da variável melhor estrutura espacial e maior precisão podem ser obtidas na estimativa em locais não amostrados por intermédio de técnicas geoestatística como a Krigagem (LIMA et al., 2010; KRAVCHENKO et al., 2006).

O que diferencia a Krigagem de outros métodos de interpolação é a estimação de uma matriz de covariância espacial que determina os pesos atribuídos às diferentes amostras, o tratamento da redundância dos dados, a vizinhança a ser considerada no procedimento inferencial e o erro associado ao valor estimado (SANTOS et al., 2016). Além disso, a Krigagem estima valores para locais não estimados sem tendência e com variância mínima, proporcionando uma estimativa mais precisa do atributo de interesse (SOUZA et al., 2014).

Para a estratificação da variabilidade espacial, a agricultura de precisão tem utilizado a geoestatística como ferramenta, por meio do método da técnica de Krigagem (SILVA et al., 2011a), sendo as formas mais usuais a Krigagem simples, a ordinária e a indicativa. A Krigagem simples é utilizada quando a média é assumida estatisticamente como constante para toda a área. A Krigagem ordinária é um método de interpolação de dados que usa a dependência espacial entre amostras vizinhas, expressa por meio de um semivariograma ajustado, para estimar valores

em qualquer posição dentro do espaço analisado, sem tendência e com variância mínima. Enquanto que, a krigagem indicativa é uma ramificação da krigagem ordinária onde os dados são transformados e categorizados tomando como referência pontos de corte, antes da estimativa, denominado de codificação por indicação (SILVA et al., 2011b; YAMAMOTO e LANDIM, 2013).

2.4. Redes Neurais Artificiais

A inteligência computacional é a área da ciência da computação que visa simular, em máquinas, a capacidade de solucionar problemas e realizar tarefas, que são habilidades da inteligência natural do homem (RUSSEL e NORVIG, 2013). Dentre as diversas técnicas de aprendizado de máquinas, as Redes Neurais Artificiais (RNAs) se destacam como uma ferramenta com potencial reconhecido na área da ciência da computação (CARNEIRO, 2015).

HAYKIN (2001) definiu uma rede neural artificial como um processador paralelamente distribuído, maciçamente, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro humano em dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente por meio de um processo de aprendizagem e as forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

As redes neurais artificiais (RNAs) apresentam estrutura e funcionamento semelhante à rede de neurônios biológicos do sistema nervoso humano e seu principal componente de processamento é o neurônio. O neurônio artificial é uma modelagem simplificada do funcionamento do neurônio biológico, sendo que esta unidade de processamento se torna fundamental para o funcionamento das redes neurais artificiais (HAYKIN, 2008). Cada neurônio biológico apresenta componentes próprios com importantes funções para o funcionamento do cérebro humano como um todo. Os principais componentes dos neurônios são os dendritos, o corpo do neurônio e o axônio. Os dendritos recebem os estímulos transmitidos pelos outros neurônios, enquanto que o corpo do neurônio é responsável por coletar e combinar informações vindas de outros neurônios. Por fim, o axônio é responsável por transmitir os estímulos para outras células (GAZZANIGA et al., 2013).

Em termos de estrutura os neurônios artificiais apresentam também três importantes componentes (Figura 2). O primeiro é o conjunto de pesos sinápticos (w_1, w_2, \dots, w_n) capaz de ponderar cada variável entrada (x_1, x_2, \dots, x_n). O segundo é o combinador linear (Σ) capaz de agregar as entradas ponderadas pelos seus respectivos pesos em uma única medida, a fim de

produzir um valor potencial de ativação, sendo θ o patamar dessa ativação. O terceiro são as funções de ativação capazes de regular o funcionamento dos neurônios de acordo com o potencial de ativação (u), que é então calculado pela função de ativação (g), sendo o resultado desta função y disparado como resposta pelo axônio (SILVA et al., 2010b).




FIGURA 2 - Neurônio McCulloch e Pitts (MCP).

x_n - entradas; w_n - pesos; Σ - combinador linear; θ - limiar de ativação; u - potencial de ativação; $g(\cdot)$ - função de ativação; y - sinal de saída.

Fonte: SILVA et al. (2010b).

Por meio das funções de ativação é possível obter um valor de saída y produzido pelo neurônio em relação a um determinado conjunto de sinais de entrada x (x_1, x_2, \dots, x_n) (BRAGA et al., 2011). Existem diferentes funções de ativação e cada uma delas com suas respectivas particularidades, uma característica que as diferencia é quanto ao valor de saída dos neurônios, que podem ser dos tipos, binários $[0,1]$ ou bipolares $[-1,1]$ (BEALE et al., 2015).

Os principais destaques das RNAs é que elas são capazes de processar rapidamente uma grande quantidade de dados e de reconhecer padrões, possui a capacidade de aprender por meio de exemplos e de generalizar a informação aprendida, gerando um modelo não-linear, o que torna a sua aplicação bastante eficiente na análise espacial (SOARES et al., 2015). O processo de aprendizagem consiste na etapa por meio da qual os parâmetros livres de uma rede são adaptados por meio dos estímulos fornecidos pelo ambiente de treinamento e se torna capaz de fornecer uma solução generalizada para uma classe de problemas (HAYKIN, 2008).

A fim de permitir que as RNAs tenham elevada capacidade de aprendizado e de generalização, essa técnica é baseada em algoritmos de aprendizagem, que são um conjunto de regras bem definidas para a solução de um problema de aprendizado. Esses algoritmos são divididos conforme as etapas de treinamento e de validação. A etapa de treinamento é responsável pelo processo de aprendizado, enquanto que a validação é uma forma de verificação da capacidade de generalização das RNAs geradas (CARNEIRO, 2015).

2.5. Cultura do tomate industrial

O tomate (*Solanum lycopersicum*), originário da parte ocidental das Américas Central e do Sul é a segunda espécie vegetal mais importante do mundo, cultivado praticamente em todo o Brasil (ALMEIDA, 2011). Em 2016, a soma da produção brasileira de tomate industrial e de mesa foi da ordem de 3,66 milhões de toneladas, um terço dos quais foram destinados ao processamento industrial. O Brasil ocupou em 2016 a oitava posição entre os países produtores de tomate (IBGE, 2016).

As principais regiões brasileiras produtoras são Sudeste e Centro-Oeste, concentrada nos estados de São Paulo, Minas Gerais, Bahia e Goiás responsáveis por 70% da produção anual de tomate. Dentre esses Estados, Goiás se destaca com maior produtividade, em 2016 produziu cerca de 978 mil toneladas. Toda a produtividade do estado está relacionada com os aspectos climáticos e tipos de solo que são favoráveis para a cultura. Solos profundos, bem drenados e a topografia plana facilita a mecanização e permite o uso de grandes sistemas de irrigação o que favorece o crescimento do setor (IBGE, 2016; RIBEIRO, 2015; GAMEIRO et al., 2008).

A cultura ocupa lugar de destaque na economia brasileira, não somente pelo seu valor econômico, mas também por ser uma atividade geradora de um grande número de empregos e renda em todos os setores componentes dos respectivos elos (MANSO, 2016; SOUZA et al., 2010). A produção brasileira de tomate é processada por 23 indústrias e 12 estão sediadas em Goiás nas regiões centro-sul e leste de estado, concentrando 55% da produção nacional (RIBEIRO, 2015).

Um dos principais fatores para a expansão da cultura é o crescimento do consumo, impulsionados por fatores como o aumento da renda per capita, mudança de hábitos alimentares, crescimento das redes “fast foods”, o aumento da demanda de alimentos preparados e entrada de novas empresas no mercado de processamento de tomate (GERALDINI et al., 2011; BRITO e CASTRO, 2010; GAMEIRO et al., 2008).

No Brasil, a produção de tomate tem se destacado nos últimos anos em função do elevado nível de tecnologia adotado pelos produtores (HOTT et al., 2014). Isso inclui a execução de práticas agrícolas adequadas, utilização de diferentes formas de manejo fitossanitário e principalmente, a realização de adubações seguindo a recomendação de análise de solo, de modo que as plantas se desenvolvam em um ambiente equilibrado quanto à disponibilidade de nutrientes (ABBOUD et al., 2013).

2.6. Trabalhos correlatos

Aitkenhead et al. (2012) estudando a previsão da composição química do solo e outros parâmetros de observação do solo usando uma rede neural verificaram que, o uso da rede neural poderia ser uma ferramenta adicional importante para prever as características do solo, além disso, o trabalho fornece informações sobre relações de parâmetros e processos dentro do sistema do solo em função das variáveis de entrada e saída da rede.

Andrade et al. (2013) definiram um procedimento de classificação automática utilizando Redes Neurais Artificiais para identificação de áreas cafeeiras em imagens de satélite da região de Machado-MG. O resultado da classificação foi validado pelos cruzamentos entre o mapa classificado visualmente com os classificados automaticamente pela melhor rede neural treinada, pelo cruzamento entre os mapas obteve-se a matriz de confusão para o cálculo dos índices de Exatidão Global e Kappa. O trabalho demonstrou potencial das redes neurais artificiais na classificação automática de imagens de satélite para identificação de áreas cafeeiras, obtendo acurácia da classificação e índices superiores aos encontrados na literatura.

Binoti et al. (2014) tiveram o objetivo de avaliar diferentes configurações do treinamento de Redes Neurais Artificiais (RNAs) para a estimação do volume de árvores de eucalipto. As variáveis utilizadas para treinamento das RNAs foram: variáveis numéricas (quantitativas): idade em meses, diâmetro com casca a 1,30 m de altura em cm, altura total em m e volume da árvore em m³ e as variáveis (qualitativas): projeto, espaçamento e clone. As redes neurais simples com apenas um neurônio na camada oculta, podem ser utilizadas com eficiência para estimação do volume de árvores.

Bonini Neto et al. (2017) avaliaram uma Rede Neural Artificial para estabelecer uma classificação e análise de solos degradados e sua recuperação em resposta à aplicação de limo e gesso. Os atributos físicos considerados do solo degradado foram: densidade, porosidade e resistência à penetração. A rede foi composta por quatro variáveis de entrada, que são os atributos físicos do solo, dez neurônios na camada intermediária e um neurônio na camada de saída, que tem a função de informar se o solo foi recuperado (R), parcialmente recuperado (PR) ou não recuperado (NR). Considerando o desempenho da RNA, verificou-se que a rede obteve um treinamento adequado para classificar os solos degradados, apresentando baixo erro médio quadrático de dados analisados. Portanto, a RNA é considerada uma alternativa interessante e uma poderosa ferramenta automática para classificar os solos degradados durante o processo de recuperação.

3. REFERÊNCIAS BIBLIOGRÁFICAS

- ABBOUD, A.C.S. **Introdução à Agronomia**. 1. ed. Rio de Janeiro: Ed. Interciência, 2013. 646p.
- AITKENHEAD, M.J.; COULL, M.C.; TOWERS, W.; HUDSON, G.; BLACK, H.I.J. Predicting soil chemical composition and other soil parameters from field observations using a neural network. **Computers and Electronics in Agriculture**, Oxford, v.82, s/n, p.108–116, 2012.
- ALMEIDA, R.F. Adubação nitrogenada de tomateiros. **Revista Verde**, Mossoró, v.6, n.5, p.25-30, 2011.
- AMADO, T.J.C.; PES, L.Z.; LEMAINSKI, C.L.; SCHENATO, R.B. Atributos químicos e físicos de Latossolos e sua relação com os rendimentos de milho e feijão irrigados. **Revista Brasileira de Ciência do Solo**, Viçosa, v.33, n.4, p.831-843, 2009.
- AMARO FILHO, J.; NEGREIROS, R.F.D.; ASSIS JUNIOR, R.N.; MOTA, J.C.A. Amostragem e variabilidade espacial de atributos físicos de um Latossolo Vermelho em Mossoró, RN. **Revista Brasileira de Ciência do Solo**, Viçosa, v.31, n.3, p.415-422, 2007.
- ANDRADE, L.N.; VIEIRA, T.G.C.; LACERDA, W.S.; VOLPATO, M.M.L.; DAVIS JUNIOR, C.A. Aplicação de redes neurais artificiais na classificação de áreas cafeeiras em Machado-MG. **Coffee Science**, Lavras, v.8, n.1, p.78-90, 2013.
- ANGELICO, J.C.; SILVA, I.N. Redes neurais artificiais aplicadas na estimativa da variabilidade de atributos do solo. **Revista Científica da FACOL/ISEOL**, São Paulo, v.1, n.1, p.9-20, 2014.
- ASSUNÇÃO, P.E.V.; SPINELLI, E.M.A.; CARDOSO, J.S. Caracterização da produção de tomate industrial no município de Morrinhos/GO: da utilização de defensivos à vantagem dos contratos. **Revista Teoria e Evidência Econômica**, Passo Fundo, v.19, n.40, p.153-168, 2013.
- BARETTA, D.; SANTOS, J.C.P.; SEGAT, J.C.; GEREMIA, E.V.; OLIVEIRA FILHO L.C.I.; ALVES M.V. Fauna edáfica e qualidade do solo. In: FILHO, O.K.; MAFRA, Á.L.; GATIBONI, L.C. **Tópicos em Ciência do Solo**. Viçosa, MG: Sociedade Brasileira de Ciência do Solo, 2011. cap.7, p.119-170.
- BEALE, M.H.; HAGAN, M.T.; DEMUTH, H.B. **Neural Network Toolbox: User's Guide**. ed. MathWorks: Massachusetts, 2015. 406p.
- BINOTI, M.L.M.S.; BINOTI, D.H.B.; LEITE, H.G. Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto. **Revista Árvore**, Viçosa, v.37, n.4, p.639-645, 2013.
- BINOTI, D.H.B.; BINOTI, M.L.M.S.; LEITE, H.G. Configuração de redes neurais artificiais para estimação do volume de árvores. **Ciência da Madeira**, Pelotas, v.5, n.1, p.58-67, 2014.
- BITTAR, R.D. **Redes neurais artificiais aplicadas à modelagem da variabilidade espacial de atributos físico-químicos de solos do cerrado**. 2016. 112p. (Mestrado em Engenharia Agrícola) - Universidade Estadual de Goiás, Anápolis.

BONINI NETO, A.; BONINI, C.S.B.; BISI, B.S.; COLETTA, L.F.S.; REIS, A.R. Artificial Neural Network for Classification and Analysis of Degraded Soils. **Ieee Latin America Transactions**, v.15, n.3, p.503-509, 2017.

BOTTEGA, E.L.; QUEIROZ, D.M.; PINTO, F.A.C.; SOUZA, C.M.A. Variabilidade espacial de atributos do solo em sistema de semeadura direta com rotação de culturas no cerrado brasileiro. **Revista Ciência Agronômica**, Fortaleza, v.44, n.1, p.1-9, 2013.

BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2. ed. Rio de Janeiro: Ed. LTC, 2011. 226p.

BRITO, L.; CASTRO, S.D. **Expansão na produção de tomate industrial no Brasil e em Goiás**. Conjuntura Econômica Goiana, Boletim Trimestral. Goiânia: Secretaria do Planejamento e Desenvolvimento do Estado de Goiás, p.43-52, 2010.

BURAK, D.L.; SANTOS, D.A.; PASSOS, R.R. Variabilidade espacial de atributos físicos: relação com relevo matéria orgânica e produtividade em café conilon. **Coffee Science**, Lavras, v.11, n.4, p.455-466, 2016.

CARNEIRO, V.Q. **Rede neural e lógica fuzzy aplicadas no melhoramento do feijoeiro**. 2015. 118p. Dissertação (Mestrado em Genética e Melhoramento) - Universidade Federal de Viçosa, Viçosa.

CAVALCANTE, E.G.S.; ALVES, M.C.; SOUZA, M. Z.; PEREIRA, G.T. Variabilidade espacial de atributos físicos do solo sob diferentes usos e manejos. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.15, n.3, p.237-243, 2011.

CERRI, D.G.P.; MAGALHÃES, P.S.G. Correlation of physical and chemical attributes of soil with sugarcane yield. **Pesquisa Agropecuária Brasileira**, Brasília, v.47, n.3, p.613-620, 2012.

DALCHIAVON, F.C.; RODRIGUES, A.R.; LIMA, E.S.; LOVERA, L.H.; MONTANARI, R. Variabilidade espacial de atributos químicos do solo cultivado com soja sob plantio direto. **Revista de Ciências Agroveterinárias**, Lages, v.16, n.2, p.144-154, 2017.

DALCHIAVON, F.C.; CARVALHO, M.P.; ANDREOTTI, M.; MONTANARI, R. Variabilidade espacial de atributos da fertilidade de um Latossolo Vermelho Distroférico sob Sistema Plantio Direto. **Revista Ciência Agronômica**, Fortaleza, v.43, n.3, p.453-461, 2012.

GAMEIRO, A.H.; CAIXETA FILHO, J.V.; ROCCO, C.D.; RANGEL, R. Modelagem e gestão das perdas no suprimento de tomates para processamento industrial. **Gestão e Produção**, São Carlos, v.15, n.1, p.101-115, 2008.

GAZZANIGA, M.; IVRY, R.; MANGUN, G. **Cognitive Neuroscience: The Biology of the Mind**. 4. ed. New York: Ed. W.W. Norton & Company, 2013. 1377p.

GERALDINI, F.; JULIÃO, L.; BORGATO, E. Procuram-se agroindústrias. **Hortifruti Brasil**, Piracicaba, n.104, v.10, p.8-23, 2011.

GUIMARÃES, W.D.; GRIPP JUNIOR, J.; MARQUES, E.A.G.; SANTOS, N.T.; FERNANDES, R.B.A. Variabilidade espacial de atributos físicos de solos ocupados por pastagens. **Revista Ciência Agronômica**, Fortaleza, v.47, n.2, p.247-255, 2016.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. Hamilton: Ed. Pearson - Prentice Hall, 2008. 937p.

HAYKIN, S. **Redes neurais: princípios e práticas**. 2. ed. Porto Alegre: Ed. Bookman, 2001. 900p.

HOTT, M.O.; LIMA, V.L.S.; PEREIRA, L.R.; SOUZA, J.M.; REIS, E.F. Produção de biomassa na fase vegetativa do tomateiro em função da tensão de água no solo. **Enciclopédia Biosfera**, Goiânia, v.10, n.18, p.2389-2398, 2014.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Levantamento Sistemático da Produção Agrícola**, Rio de Janeiro, v.29, n.12, p.1-82, 2016.

KLINK, C.A.; MACHADO, R.B. A conservação do cerrado brasileiro. **Revista Megadiversidade**, Belo Horizonte, v.1, n.1, p.147-155, 2005.

KRAVCHENKO, A.N.; ROBERTSON, G.P.; SNAP, S.S.; SMUCKER, A.J.M. Using information about spatial variability to improve estimates of total soil carbon. **Agronomy Journal**, Madison, v.98, n.3, p.823-829, 2006.

LANDIM, P.M.B.; STURARO, J.R. **Krigagem Indicativa aplicada à elaboração de mapas de probabilidades de riscos**. DGA, IGCE, UNESP, Rio Claro, Laboratório de Geomatemia, Texto Didático 06, 19p. 2002.

LANDIM, P.M.B.; STURARO, J.R.; MONTEIRO, R.C. **Krigagem ordinária para situações com tendência regionalizada**. DGA, IGCE, UNESP, Rio Claro, 12p. 2002.

LEAL, A.J.F.; MIGUEL, E.P.; BAILO, F.H.R.; NEVES, D.C.; LEAL, U.A.S. Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo. **Bragantia**, Campinas, v.74, n.4, p.436-444, 2015.

LIMA, J.S.S.; SOUZA, G.S.; SILVA, S.A. Amostragem e variabilidade espacial de atributos químicos do solo em área de vegetação natural em regeneração. **Revista Árvore**, Viçosa, v.34, n.1, p.127-136, 2010.

MANSO, R.T.; ALVES, D.K.M.; SOARES, F.A.L.; CUNHA, N.F.; TEIXEIRA, M.B.; MORAIS, W.A. Produtividade de tomateiros irrigados com água residuária de suinocultura. **Revista Brasileira de Agricultura Irrigada**, Fortaleza, v.10, n.6, p.1075-1085, 2016.

MATIAS, S.S.R.; NÓBREGA, J.C.A.; NÓBREGA, R.S.A.; ANDRADE, F.R.; BAPTISTEL, A.C. Variabilidade espacial de atributos químicos em Latossolo cultivado de modo convencional com soja no cerrado piauiense. **Revista Agro@mbiente On-line**, v.9, n.1, p.17-26, 2015.

MOLIN, J.P.; RABELLO, L.M. Estudos sobre a mensuração da condutividade elétrica do solo. **Engenharia Agrícola**, Jaboticabal, v.31, n.1, p.90-101, 2011.

MONDO, V.H.V.; GOMES JUNIOR, F.G.; PINTO, T.L.F.; MARCHI, J.L. MOTOMIYA, A.V.A.; MOLIN, J.P.; CICERO, S.M. Spatial variability of soil fertility and its relationship with seed physiological potential in a soybean production area. **Revista Brasileira de Sementes**, Brasília, v.34, n.2, p.193-201, 2012.

NOETZOLD, R.; ALVES, M.C.; CASSETARI NETO, D.; MACHADO, A.Q. Variabilidade espacial de *Colletotrichum truncatum* em campo de soja sob três níveis de sanidade de sementes. **Summa Phytopathol**, Botucatu, v.40, n.1, p.16-23, 2014.

NOROUZI, M.; YOUNI, S.A.; JALALIAN, A., KHADEMI, H.; DEGHANI, A.A. Predicting rainfed wheat quality and quantity by artificial neural network using terrain and soil characteristics. **Acta Agriculturae Scandinavica, Section B - Soil and Plant Science**, Oslo, v.60, n.4, p.341-353, 2010.

OLIVER, Y.M.; ROBERTSON, M.J.; WONG, M.T.F. Integrating farmer knowledge, precision agriculture tools, and crop simulation modelling to evaluate management options for poor performing patches in cropping fields. **European Journal of Agronomy**, Amsterdam, v.32, n.1, p.40-50, 2010.

PASINI, M.P.B.; LÚCIO, A.D.; FRONZA, D.; WEBER, L.S. Krigagem ordinária e inverso da distância ponderada aplicados na espacialização da população da mosca-do-figo. **Agrária**, Recife, v.10, n.3, p.452-459, 2015.

ROSA, M.G.; KLAUBERG FILHO, O.; BARTZ, M.L.C.; MAFRA, A.L.; SOUSA, J.P.F.A.; BARETTA, D. Macrofauna edáfica e atributos físicos e químicos em sistemas de uso do solo no planalto catarinense. **Revista Brasileira de Ciência do Solo**, Viçosa, v.39, n.6, p.1544-1553, 2015.

RIBEIRO, K. In natura ou processado? Líder em tomate industrial e significativo em tomate de mesa, Goiás esbarra em altos custos de produção. In: **Federação da Agricultura e Pecuária de Goiás (FAEG)**. Revista Campo, Goiânia, Ano XVI, n. 239, 2015.

RODRIGUES, M.S. **Análise espacial e temporal de atributos do solo e da produtividade das culturas visando manejo específico em áreas agrícolas**. 2013. 90p. (Doutorado em Agronomia) - Universidade Estadual Paulista, Jaboticabal.

RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 3. ed. Rio de Janeiro: Ed. Campus, 2013. 1016p.

SANA, R.S.; ANGHINONI, I.; BRANDÃO, Z.N.; HOLZSCHUH, M.J. Variabilidade espacial de atributos físicos-químicos do solo e seus efeitos na produtividade do algodoeiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.18, n.10, p.994-1002, 2014.

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

SANTOS, H.S.; CUNHA, G.N.; CASTRO, J.R. Avaliação qualitativa das técnicas de interpolação de mínima curvatura, Krigagem e bidirecional na formação de imagens. **Revista de Engenharias da Faculdade Salesiana**, Macaé, v.1, n.4, p.2-16, 2016.

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.

SANTOS, P.C.; SANTANA, A.C.; BARROS, P.L.C.; QUEIROZ, J.C.B.; VIEIRA, T.O. O emprego da geoestatística na determinação do tamanho “ótimo” de amostras aleatórias com vistas à obtenção de estimativas dos volumes dos fustes de espécies florestais em Paragominas, estado do Pará. **Acta Amazonica**, Manaus, v.41, n.2, p.213-222, 2011.

SEIDEL, E.J.; OLIVEIRA M.S. Proposta de um teste de hipótese para existência de dependência espacial em dados geoestatísticos. **Boletim de Ciências Geodésicas**, Curitiba, v.20, n.4, p.750-764, 2014.

SERRANO, J.M.; PEÇA, J.O.; SILVA, J.R.; SHAHIDIAN, S. Medição e mapeamento da condutividade elétrica aparente do solo em pastagens. **Revista de Ciências Agrárias**, Lisboa, v.33, n.2, p.5-14, 2010.

SILVA, A.F.; PEREIRA, M.J.; ZIMBACK, C.R.L.; LANDIM, P.M.B.; SOARES, A. Simulação sequencial de atributos diagnósticos do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.19, n.5, p.418-425, 2015.

SILVA, A.F.; ZIMBACK, C.R.; LANDIM, P.M.B. **Aplicação da Geoestatística em Ciências Agrárias**: parte II. Botucatu, v.1, 2013.

SILVA, A.F.; QUARTEZANI, W.Z.; ZIMBACK, C.R.L.; LANDIM, P.M.B. Aplicação da Geoestatística em Ciências Agrárias. In: SIMPÓSIO DE GEOESTATÍSTICA APLICADA A CIÊNCIAS AGRÁRIAS, 2. **Anais...**, Botucatu: FEPAF, 2011a. 136p.

SILVA, S.A.; LIMA, J.S.S.; ZUCOLOTO, M. Distribuição espacial das frações granulométricas em um Latossolo Vermelho utilizando krigagem indicativa. **Engenharia na Agricultura**, Viçosa, v.19, n.3, p.195-202, 2011b.

SILVA, S.A.; LIMA, J.S.S.; SOUZA, G.S.; OLIVEIRA, R.B.; SILVA, A.F. Variabilidade espacial do fósforo e das frações granulométricas de um Latossolo Vermelho Amarelo. **Revista Ciência Agronômica**, Fortaleza, v.41, n.1, p.1-8, 2010a.

SILVA, I.N.; SPATTI, D.H.; FLAUZINO, R.A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. 1. ed. São Paulo: Ed. Artliber, 2010b, 399p.

SOARES, F.C.; ROBAINA, A.D.; PEITER, M.X.; RUSSI, J.L. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, Santa Maria, v.45, n.11, p.1987-1993, 2015.

SOARES, F.C.; ROBAINA, A.D.; PEITER, M.X.; RUSSI, J.L.; VIVAN, G.A. Redes neurais artificiais na estimativa da retenção de água do solo. **Ciência Rural**, Santa Maria, v.44, n.2, p.293-300, 2014.

SOUZA, Z.M.; SOUZA, G.S.; MARQUES JÚNIOR, J.; PEREIRA, G.T. Número de amostras na análise geoestatística e na krigagem de mapas de atributos do solo. **Ciência Rural**, Santa Maria, v.44, n.2, p.261-268, 2014.

SOUZA, J.A.R.; MOREIRA, D.A.; FERREIRA, P.A.; MATOS, A.T. Avaliação de frutos de tomate de mesa produzidos com efluente do tratamento primário da água residuária da suinocultura. **Engenharia na Agricultura**, Viçosa, v.18, n.3, p.198-207, 2010.

VIEIRA, S. R.; DECHEN, S. C. F.; SIQUEIRA, G. M.; DUFRANC, G. Variabilidade espacial de atributos físicos e químicos relacionados com o estado de agregação de dois Latossolos cultivados no sistema de semeadura direta. **Bragantia**, Campinas, v.70, n.1, p.185-195, 2011.

VILELA, N.J.; MELO, P.C.T.; BOITEUX, L.S.; CLEMENTE, F.M.V.T. Perfil socioeconômico da cadeia agroindustrial no Brasil. In: CLEMENTE, F.M.V.T.; BOITEU, L.S. (eds). **Produção de tomate para processamento industrial**. Brasília: Embrapa, 2012. p.17-22.

WEIRICH NETO, P.H.; BUZOLINI JUNIOR, O.; ROCHA, J.V.; BORGHI, E.; SVERZUT, C.B. Um estudo da variabilidade espacial do conteúdo de areia do solo, utilizando diferentes métodos de interpolação. **Ciências Agrárias e Engenharias**, Ponta Grossa, v.12, n.1, p.41-49, 2006.

YAMAMOTO, J.K.; LANDIM, P.M.B. **Geoestatística: conceitos e aplicações**. 1. ed. São Paulo: Ed. Oficina de Textos, 2013. 215p.

ZONTA, J.H.; BRANDÃO, Z.N.; MEDEIROS, J.C.; SANA, R.S.; SOFIATTI, V. Variabilidade espacial do solo em área cultivada com algodoeiro no Cerrado do Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.18, n.6, p.595-602, 2014.

CAPÍTULO 1

PREDIÇÃO DE ATRIBUTOS FÍSICOS E QUÍMICOS DO SOLO POR MEIO DE UMA REDE NEURAL ARTIFICIAL

1. INTRODUÇÃO

O solo é um sistema, resultante da interação de fatores geológicos, topográficos e climáticos, entre outros, que juntos conferem suas características e propriedades físicas e químicas (SILVA et al., 2015). A qualidade do solo agrícola está relacionada com seus componentes físicos, químicos e biológicos, pois esses atributos atuam diretamente no processo de desenvolvimento das plantas (ROSA et al., 2015).

Um dos principais indicadores físicos, que tem estreita relação com a retenção e o transporte de água, estrutura do solo, teor de nutrientes e de matéria orgânica, além de influenciar fortemente os processos erosivos do solo é a textura do solo, que é uma de suas propriedades mais estáveis. A estrutura do solo se refere ao tamanho e ao padrão de arranjo das partículas primárias (areia, silte e argila) e poros do solo e como estão organizados. Já as medidas que expressam a disponibilidade dos nutrientes químicos, como cálcio e magnésio trocáveis, fósforo, potássio, micronutrientes, assim como suas relações são importantes para avaliar qualidade do solo entre diferentes sistemas de manejos (ARAÚJO et al., 2012).

A análise química do solo é uma ferramenta básica para a transferência de informações, sobre calagem e adubação. Por meio da coleta e análise de solo realizada de forma correta é possível determinar o grau de deficiência dos nutrientes e quantificar as quantidades de corretivos e fertilizantes a serem aplicados. Recomenda-se que uma área amostrada deve ser dividida em glebas de no máximo 10 hectares e cada gleba deve ser mais homogênea possível (EMBRAPA, 2014).

As áreas de cultivo nem sempre são uniformes quanto a formação do solo e podem apresentar variabilidade no espaço e no tempo dos fatores que afetam a produtividade das culturas, sendo necessário manejo diferenciado nos locais que apresentam variabilidade do atributo em estudo para otimização dos recursos de produção (PELLISSARI et al., 2014). Segundo Pinheiro (2016), a agricultura de precisão (AP) é um conjunto de técnicas que permite o gerenciamento localizado dos cultivos que promovem uma melhor gestão da produção agrícola,

na utilização de uma técnica que trata a cultura em busca do seu melhor rendimento, levando em conta os aspectos de localização, fertilidade do solo, produtividade potencial dos solos agrícolas, entre outros fatores que podem variar consideravelmente.

Entre os diversos desafios da agricultura de precisão, a amostragem de solo é um deles. Uma caracterização precisa da variabilidade dos nutrientes do solo é necessária para o uso correto e adequado de fertilizantes, garantindo rendimentos mais elevados e consequentemente, uma produção mais rentável e sustentável. No entanto, um dos fatores limitantes para um mapeamento preciso dos solos é a quantidade de amostras necessárias. Para se obter um adequado mapeamento dos atributos físicos e químicos do solo é necessário realizar uma amostragem densa na área, fazendo muitas vezes com que a atividade se torne impraticável tanto física quanto economicamente (PEETS et al., 2012).

A simples redução dos pontos de amostragem, como tem sido praticada pela maioria dos consultores da área, não é a solução adequada, pois distorce os resultados e compromete a vantagem da agricultura de precisão (SANCHES et al., 2017).

Dessa forma, pesquisadores têm buscado uma nova tecnologia que pode ser utilizada para vencer esse gargalo tecnológico, surgindo então a utilização das Redes Neurais Artificiais (RNAs) na predição dos atributos de solo, com base em poucas observações de campo (AITKENHEAD et al., 2012). Bittar (2016) desenvolveu e aplicou as RNAs com objetivo de estimar os atributos do solo. Foi realizado o treinamento, a validação e testes de diferentes RNAs e consecutiva escolha da rede que apresentou o melhor resultado. O referido estudo propôs que utilizando 4 pontos amostrais conhecidos (atributos químicos e físicos), seria possível estimar os atributos de solo em 120 pontos amostrais numa área correspondente a 23 ha.

Objetivou-se com este trabalho obter as estimativas dos atributos físicos e químicos do solo por meio de RNA, comparar as estimativas obtidas com os valores obtidos por meio de análise de solo e com os valores estimados por meio da krigagem ordinária na análise geoestatística, bem como avaliar a eficiência da RNA.

2. MATERIAL E MÉTODOS

2.1. Caracterização e localização da área experimental

Os dados utilizados para o desenvolvimento deste trabalho foram oriundos de um estudo realizado na Fazenda Palmital localizada no município de Morrinhos, GO (17°45'20" S de latitude e 49°10'34" W de longitude), altitude de 813 m (REIS, 2011), em uma área irrigada por pivô central (Figura 1a). Os dados foram coletados em um talhão de 23 ha (Figura 1b). O solo da região é classificado como de textura franco argilo arenosa (EMBRAPA, 2013).




FIGURA 1 - (a) Pivô central; (b) Área experimental.

2.2. Mapeamento da área e georreferenciamento dos pontos amostrais

Os dados foram coletados em uma área de 23 hectares em uma grade amostral de 50x50 m, totalizando 120 pontos amostrais. Cada ponto foi georreferenciado utilizando aparelho de Sistema de Posicionamento Global - GPS, marca Garmin modelo Etrex Legend RoHs (erro ± 3 m), com sistema de correção diferencial em tempo real via satélite e com coordenadas em sistema UTM (Universal Transversa de Mercator).

2.3. Determinação dos atributos físicos e químicos do solo

Em cada ponto da grade amostral georreferenciada, foram coletadas amostras deformadas de solo (composta por 5 subamostras) na camada de 0,0 a 0,2 m, com um trado de rosca, coletadas em um raio de um metro, em torno de cada ponto da grade amostral.

Em seguida as amostras foram embaladas, identificadas, e encaminhadas para laboratório de Análise de Solos Certificado, com aproximadamente 300 g de amostra de solo de cada ponto amostral, para a determinação dos atributos de solo:

- Químicos: pH (CaCl_2), cálcio (Ca), magnésio (Mg), cálcio + magnésio (Ca+Mg), alumínio trocável (Al), acidez potencial (H+Al), potássio (K), fósforo (P), saturação por alumínio (m%) e matéria orgânica (MO);

- De fertilidade: capacidade de troca catiônica (CTC) e saturação por bases (V%);
- Físicos (composição granulométrica do solo): areia, silte e argila.

2.4. Rede neural artificial na predição dos atributos de solo

Para o uso da RNA na predição dos atributos físicos e químicos do solo, foi utilizada uma rede desenvolvida no estudo de Bittar (2016).

A rede utilizada apresenta as seguintes características: a preparação e o treinamento da RNA foram realizados utilizando o pacote *Neural Network ToolBox* do Matlab® em topologia do tipo MLP (*Multi Layer Perceptron*) alimentada para frente *feedforward* com algoritmo de aprendizado de retropropagação do erro *Back-propagation* (RUSSEL e NORVIG, 2013). Bittar (2016) avaliou 168 redes no processo de treinamento utilizando, alternando a quantidade de neurônios da camada intermediária (3, 5, 7, 9, 13, 17 e 21) e rodadas de treinamento (de 1 até 6). E o critério utilizado para a escolha da melhor rede que foi utilizada neste estudo foi a performance da RNA em acertar a estimativa dos valores dos atributos de solo nos 120 pontos amostrais.

2.4.1. Seleção dos pontos amostrais e variáveis de entrada na RNA

As variáveis de entrada na RNA foram compostas pelas combinações não repetitivas de 4 pontos amostrais conhecidos selecionados aleatoriamente entre os 120 pontos obtidos na análise de solo, pelas coordenadas geográficas, pela altitude em metros de cada ponto amostral e pelos 15 atributos do solo. Essas variáveis de entrada, após realizado o processo de verificação da aplicabilidade da rede gera a resposta para a coordenada informada.

2.4.2. Normalização dos dados para entrada na RNA

Para iniciar o processo de verificação da aplicabilidade do uso da RNA, para estimar os atributos físicos e químicos do solo, foi realizada a normalização dos dados das variáveis com a intenção de equalizar as variáveis de entrada na RNA (LEAL et al., 2015). Os dados foram normalizados para uma faixa de valor entre -1 e 1 (SILVA et al., 2010), conforme Equação 1.

$$y = \frac{(x - x_{\min})(d_2 - d_1)}{x_{\max} - x_{\min}} + d_1 \quad (1)$$

Em que:

y = resultado normalizado;

x = valor a ser normalizado;

x_{\min} = valor mínimo de x;

$x_{m\acute{a}x}$ = valor maximo de x ;

d_1 = limite inferior do resultado da normalizaao (-1);

d_2 = limite superior do resultado da normalizaao (1).

Para os valores ($x_{m\acute{i}n}$ e $x_{m\acute{a}x}$) para os atributos de solo, foram atribuidos zero (0) para os valores mınimos e para os valores maximos foram atribuidos valores maximos possıveis ou numeros primos que ultrapassem os limites de toxicidade do atributo do solo (RIBEIRO et al., 1999). O uso de numeros primos nos valores maximos foi utilizado para evitar resultados da normalizaao iguais a zero (Tabela 1). O aumento na faixa de valores da normalizaao para o treinamento da rede visa possibilitar que a RNA apos treinada possa ser usada em situaoes onde os valores das variaveis venham a extrapolar a faixa de valores do treinamento (HAYKIN, 2001).

TABELA 1 - Limites para normalizaao das variaveis de entrada da RNA.

| Atributo | Unidade | Mınimo da amostra | Maximo da amostra | Limite inferior normalizaao | Limite superior normalizaao |
|-------------------------|------------------------------------|--------------------|--------------------|------------------------------|------------------------------|
| X | UTM | 702352,20 | 703316,35 | Mınimo - 10% | Maximo + 10% |
| Y | UTM | 8047686,17 | 8047974,14 | Mınimo - 10% | Maximo + 10% |
| Altitude | m | 789,36 | 830,46 | Mınimo - 10% | Maximo + 10% |
| pH (CaCl ₂) | - | 4,90 | 6,10 | 0,00 | 11,00 |
| Ca | cmol _c dm ⁻³ | 2,20 | 8,10 | 0,00 | 19,00 |
| Mg | cmol _c dm ⁻³ | 0,60 | 2,10 | 0,00 | 19,00 |
| Ca+Mg | cmol _c dm ⁻³ | 3,00 | 8,80 | 0,00 | 29,00 |
| Al | cmol _c dm ⁻³ | 0,00 | 0,20 | 0,00 | 19,00 |
| H+Al | cmol _c dm ⁻³ | 0,80 | 2,30 | 0,00 | 29,00 |
| CTC | cmol _c dm ⁻³ | 5,70 | 10,10 | 0,00 | 29,00 |
| K | cmol _c dm ⁻³ | 0,26 | 0,72 | 0,00 | 29,00 |
| P | mg dm ⁻³ | 6,00 | 24,00 | 0,00 | 49,00 |
| m% | % | 0,00 | 6,00 | 0,00 | 100,00 |
| V% | % | 62,00 | 86,00 | 0,00 | 100,00 |
| MO | g kg ⁻¹ | 16,00 | 39,00 | 0,00 | 1000,00 |
| Argila | g kg ⁻¹ | 200,00 | 420,00 | 0,00 | 1000,00 |
| Silte | g kg ⁻¹ | 80,00 | 230,00 | 0,00 | 1000,00 |
| Areia | g kg ⁻¹ | 400,00 | 690,00 | 0,00 | 1000,00 |

X - coordenada geografica; Y - coordenada geografica; pH - potencial hidrogenionico; Ca - calcio; Mg - magnesio; Ca+Mg - calcio + magnesio; Al - alumınio; H+Al - acidez potencial; CTC - capacidade de troca cationica; K - potassio; P - fosforo; m% - saturaao por alumınio; V% - saturaao por bases; MO - materia organica; UTM - Universal Transversa de Mercator (UTM).

2.4.3. Geraao das matrizes de dados para aplicar na RNA

A verificaao da aplicabilidade da RNA foi realizada no software trial Matlab  2012, utilizando dois tipos de matrizes de dados, a matriz que possui os dados de entrada (*input*) e a

matriz de respostas (*target*). Foram geradas quatro matrizes de entrada e 15 matrizes de resposta com os valores de cada atributo de solo considerado.

O arquivo resposta, foi salvo no formato CSV, para deixar o arquivo compatível com planilhas eletrônicas, foram substituídos os (pontos) por (vírgulas), concluído esses ajustes o arquivo foi salvo no formato XLS.

2.4.4. Estimativa dos atributos de solo utilizando a RNA

Obtidos os resultados estimados pela RNA, os mesmos foram desnormalizados retornando a sua grandeza original, para efetuar a comparação com os resultados obtidos nas amostras de solo, conforme Equação 2.

$$x = \frac{(x_{\text{máx}} - x_{\text{mín}}) * (y - d_1)}{d_2 - d_1} + x_{\text{mín}} \quad (2)$$

Em que:

x = resultado desnormalizado;

y = valor normalizado;

$x_{\text{mín}}$ = valor mínimo de x;

$x_{\text{máx}}$ = valor máximo de x;

d_1 = limite inferior do resultado da normalização (-1);

d_2 = limite superior do resultado da normalização (1).

2.5. Estatística descritiva

Os dados coletados da análise de solo e os estimados pela RNA, que compõem os atributos químicos do solo: potencial hidrogeniônico (pH), cálcio (Ca), magnésio (Mg), cálcio + magnésio (Ca+Mg), alumínio trocável (Al), acidez potencial (H+Al), potássio (K), fósforo (P), saturação por alumínio (m%) e matéria orgânica (MO); de fertilidade: capacidade de troca catiônica (CTC) e saturação por bases (V%); e os atributos físicos do solo: areia, silte e argila foram submetidos à estatística descritiva por meio da análise exploratória dos dados, permitindo conhecer e visualizar a tendência, medidas de dispersão e distribuição dos mesmos.

Foi realizado a partir dos dois conjuntos de dados, o cálculo das medidas descritivas: média, mediana, variância, desvio-padrão, assimetria, curtose e coeficiente de variação, para cada variável em estudo. Para verificação da normalidade dos dados com ($p\text{-value} < 0,05$) foi realizado o teste proposto por Shapiro e Wilk (1965). Já a identificação de “*Outliers*”, foi por meio de

interpretação gráfica (*Box plot*) e o critério de Tukey (1960). Foram utilizados para a realização das análises estatísticas, planilhas eletrônicas e o software R.

2.6. Análise geoestatística para os dados determinados na análise de solo e para os dados estimados pela RNA

Para a análise geoestatística foi utilizado o software GS⁺® versão 7.0, (*Geostatistics for the Environmental Sciences*). Para verificar a existência e quantificar o grau de dependência espacial dos dados (análise de solo e os dados estimados pela RNA) foi utilizado o ajuste de funções teóricas aos modelos com patamar de semivariogramas experimentais: Linear, Esférico, Exponencial e Gaussiano.

Para análise do grau de dependência espacial, foi calculado o avaliador de dependência espacial (ADE), o qual foi classificado de acordo com a proposta de Dalchiavon et al. (2012): a dependência espacial fraca para valores $\leq 25\%$; entre 25% e 75% moderada e $\geq 75\%$ dependência forte, como apresentado na Equação 3:

$$\text{ADE} = \frac{C}{C + C_0} \times 100 \quad (3)$$

Em que:

ADE = Avaliador de dependência espacial;

C = Variância estrutural;

C₀ = Efeito pepita;

(C + C₀) = Patamar.

Para a escolha do melhor modelo foram utilizados os seguintes critérios: maior coeficiente de determinação (R²), menor soma dos quadrados dos resíduos (SQR) e o maior grau de dependência espacial. Para validação do modelo foi utilizada a validação cruzada. Na análise de validação cruzada, depois de obtido o modelo semivariográfico, cada valor original é removido do domínio espacial e usando-se os demais, um novo valor é estimado para esse ponto. Desse modo, um gráfico de dispersão foi construído mostrando a relação entre valores reais e estimados.

Após definição dos modelos e parâmetros dos semivariogramas indicados pela validação cruzada e comprovada a dependência espacial foi utilizado o método de interpolação por meio da técnica denominada krigagem ordinária, visando gerar estimativas de valores em pontos não amostrados a partir de pontos amostrados.

2.7. Teste para comparação de médias

Para cada atributo do solo visando comparar as médias dos valores estimados pela RNA e as médias dos valores estimados pela krigagem ordinária com as médias dos valores obtidos por meio da análise de solo foi realizado o Teste-t.

2.8. Indicadores estatísticos para avaliar a eficiência das estimativas obtidas pela RNA

Para verificação da eficiência das estimativas obtidas por meio da RNA, os valores dos atributos estimados pela RNA para os 120 pontos da área em estudo foram utilizados os seguintes indicadores:

- a) Erro médio relativo (P), conforme Equação 4, que permite calcular o erro médio entre os dados observados experimentalmente (análise de solo) e dados estimados pela RNA.

$$P = \frac{100}{n} \sum \frac{|Y - \hat{Y}|}{Y} \quad (4)$$

Em que:

P = Erro médio relativo (%);

n = número de elementos;

Y = valor observado experimentalmente;

\hat{Y} = valor estimado.

- b) Coeficiente de correlação (r), Equação 5, que permite quantificar o grau de associação, para cada atributo, entre as duas variáveis envolvidas na análise, valores observados e valores estimados pela RNA. O coeficiente de correlação pode variar de -1 a 1 e, quanto maior o seu valor absoluto, maior o grau de associação entre os valores observados e os valores estimados (SCHNEIDER, 1998).

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{[\sum_{i=1}^n (x_i - \bar{x})^2][\sum_{i=1}^n (y_i - \bar{y})^2]}} \quad (5)$$

Em que:

r = coeficiente de correlação de Pearson;

x_i = valores estimados;

y_i = valores observados;

\bar{x} = média dos valores estimados;

\bar{y} = média dos valores observados;

n = quantidade de padrões de teste.

- c) Coeficiente de determinação (R^2), Equação 6, indica quanto da variação total é comum aos elementos que constituem os pares analisados, valores observados e valores estimados pela RNA. Quanto mais próximo da unidade for o coeficiente de determinação, tanto maior será a validade do modelo.

$$R^2 = r^2 \quad (6)$$

Em que:

R^2 = coeficiente de determinação;

r = coeficiente de correlação de Pearson.

- d) Índice de concordância (c), Equação 7, fornece o grau de exatidão entre as variáveis envolvidas na análise, valores originais e valores estimados pela RNA, uma vez que relaciona a diferença entre os valores estimados em relação aos valores observados. Esse índice varia entre 0 (zero) nenhuma concordância até 1 concordância perfeita (WILLMONT, 1981).

$$c = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (|x_i - \bar{y}| + |y_i - \bar{y}|)^2} \quad (7)$$

Em que:

c = índice de concordância de Willmont;

x_i = valores estimados;

y_i = valores observados;

\bar{x} = média dos valores estimados;

\bar{y} = média dos valores observados;

n = quantidade de padrões de teste.

- e) Índice de desempenho (Id), Equação 8. Foi calculado pelos indicadores conhecidos, coeficiente de correlação de Pearson e índice de concordância de Willmont, o índice de desempenho da RNA foi classificado, conforme CAMARGO e SENTELHAS (1997).

$$Id = r \cdot c \quad (8)$$

Em que:

Id = índice de desempenho;

r = coeficiente de correlação de Pearson;

c = índice de concordância de Willmont.

3. RESULTADOS E DISCUSSÃO

3.1. Rede neural artificial na predição dos atributos de solo

Dos 120 pontos amostrais coletados na área em estudo, foram selecionados aleatoriamente 4 pontos amostrais para aplicação na RNA para obtenção das estimativas dos atributos físicos e químicos do solo. Para a seleção dos pontos amostrais a área foi dividida em 4 glebas de 5,75 ha cada uma (Figura 2a) e foi selecionado aleatoriamente um ponto amostral correspondente para cada gleba, estimando a partir de 4 pontos amostrais 120 estimativas para cada atributo de solo em toda a área (Figura 2b).




FIGURA 2 - (a) 4 pontos amostrais conhecidos selecionados; (b) 120 estimativas obtidas a partir de 4 pontos amostrais conhecidos.

3.1.1. Estimativas dos atributos físicos e químicos do solo utilizando RNA

Utilizando a RNA desenvolvida por Bittar (2016), a partir de 4 amostras de solo foram estimados valores para 120 pontos amostrais para 15 atributos: pH, potássio, fósforo, cálcio, magnésio, cálcio + magnésio, alumínio trocável, acidez potencial, matéria orgânica, saturação por alumínio, capacidade de troca catiônica, saturação por bases, areia, silte e argila. Nas Figuras 3, 4 e 5 estão apresentados gráficos de linhas em função dos valores determinados na análise de solo e os valores estimados pela RNA.

Os atributos pH (Figura 3a) e Al (3e) apresentaram um erro médio de 4,21% e 6,86%, respectivamente (Tabela 6), para os valores estimados pela RNA em relação aos dados determinados na análise de solo. Resultados bem próximos foram observados por Gomes et al. (2014) que na validação de um modelo de simulação de inteligência artificial, para a cultura da soja, observaram uma variação na produção de grãos de 7,2%, entre os valores observados a campo e os estimados pelo modelo. A alta capacidade preditiva foi observada também, por outros pesquisadores que utilizam a técnica de inteligência artificial em modelos de simulação (JANA et al., 2012; JANA e MOHANTY, 2012).

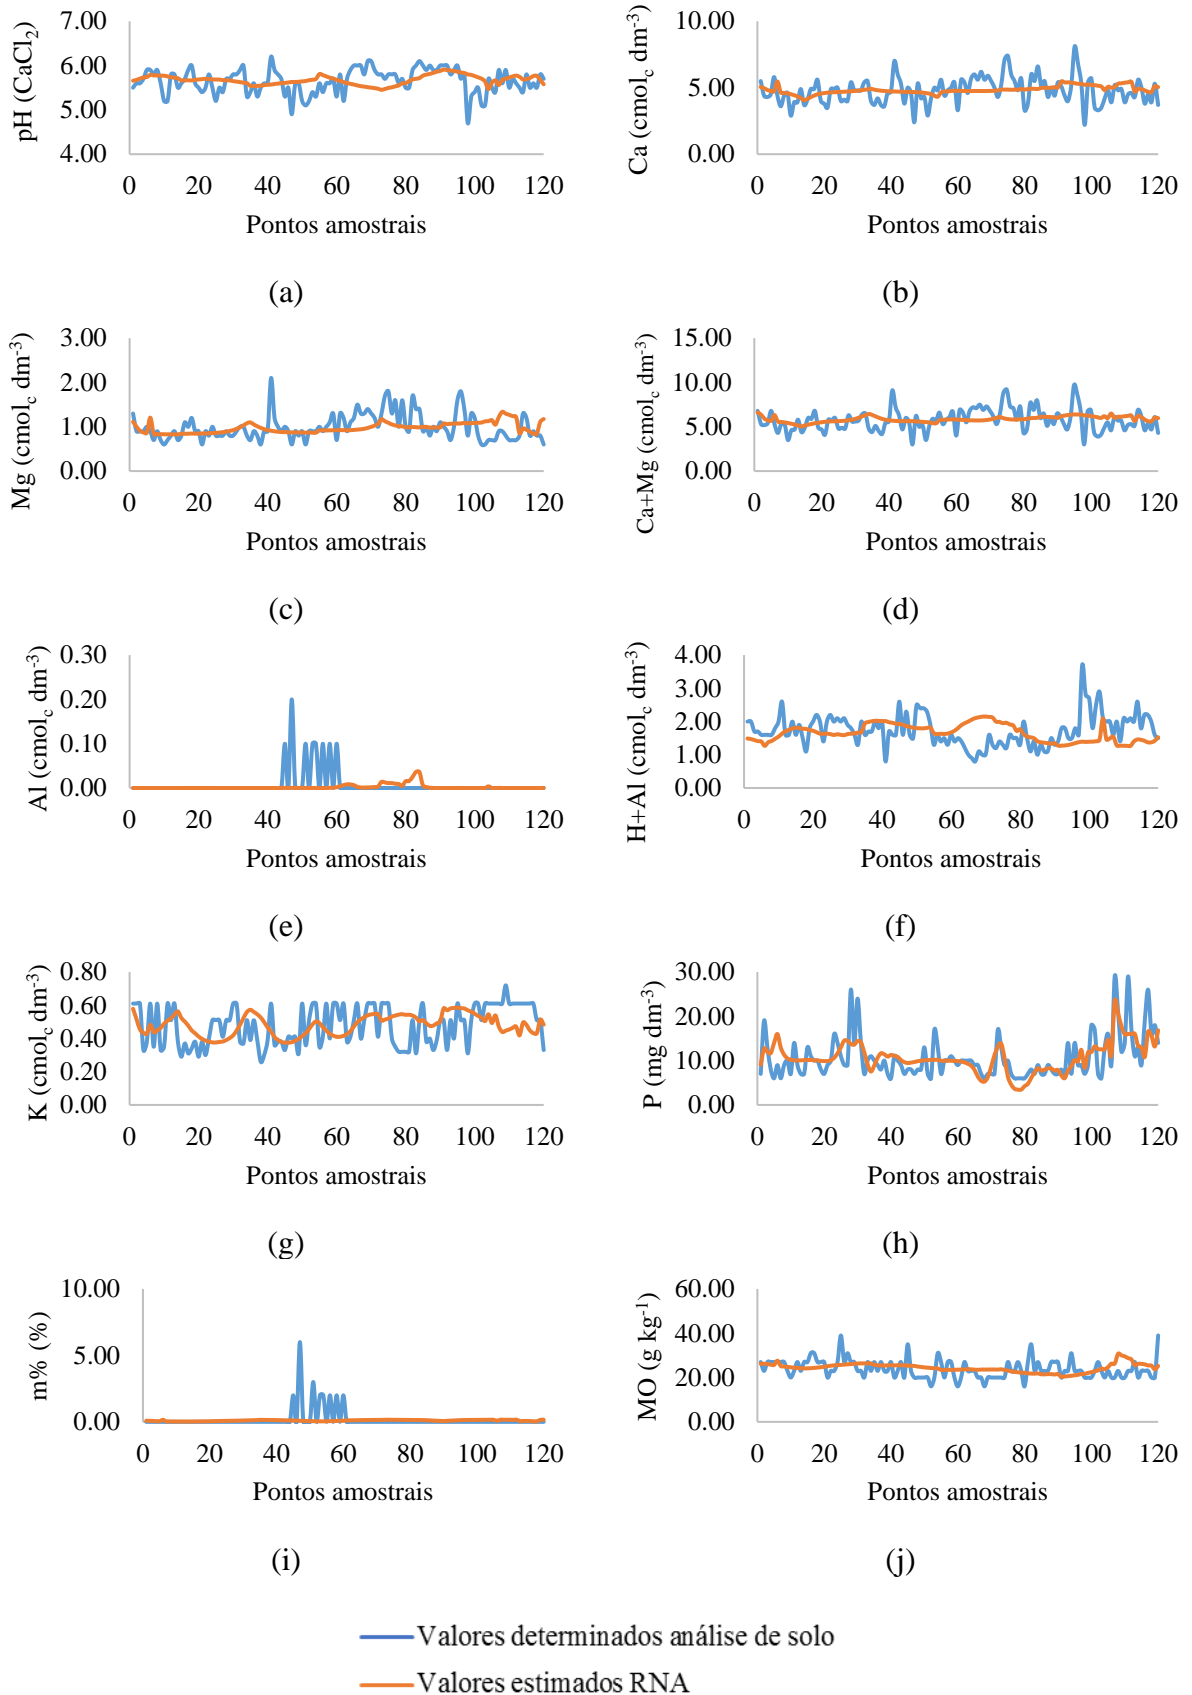


FIGURA 3 - Gráfico comparativo dos valores determinados na análise de solo *versus* valores estimados pela RNA. (a) pH - potencial hidrogeniônico, (b) Ca - cálcio, (c) Mg - magnésio, (d) Ca+Mg - cálcio + magnésio, (e) Al - alumínio, (f) H+Al - acidez potencial, (g) K - potássio, (h) P - fósforo, (i) m% - saturação por alumínio e (j) MO - matéria orgânica.

A Figura 4 apresenta os gráficos comparativos, para cada ponto amostral, entre os valores de CTC e V% estimados pela RNA e os valores determinados pela análise de solo. Os valores de CTC e V% estimados pela RNA apresentaram um erro médio em relação aos dados determinados pela análise de solo de 10,76% e 13,64%, respectivamente (Tabela 6). Os atributos argila, silte e areia (Figura 5), apresentaram um erro médio de 11,36%, 16,31% e 8,62%, respectivamente (Tabela 6).

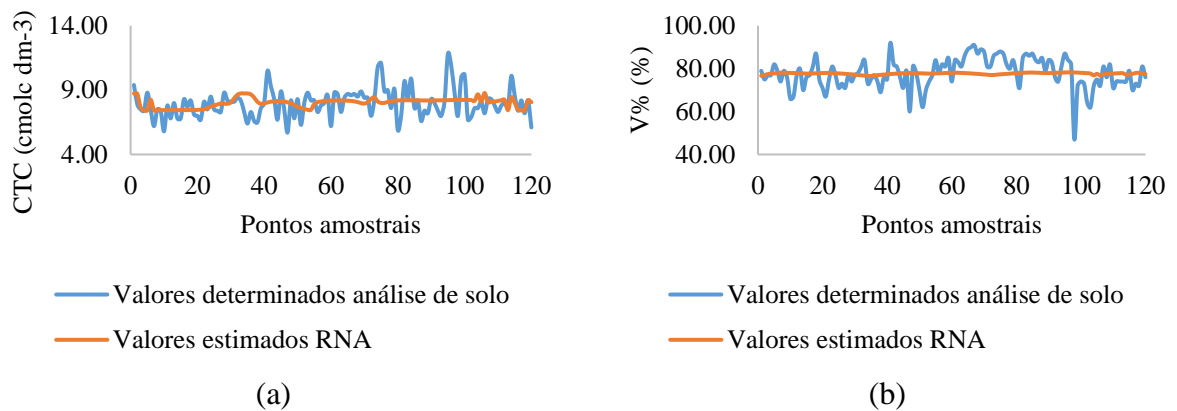


FIGURA 4 - Gráfico comparativo dos valores determinados na análise de solo *versus* valores estimados pela RNA. (a) CTC - capacidade de troca catiônica e (b) V% - saturação por bases.

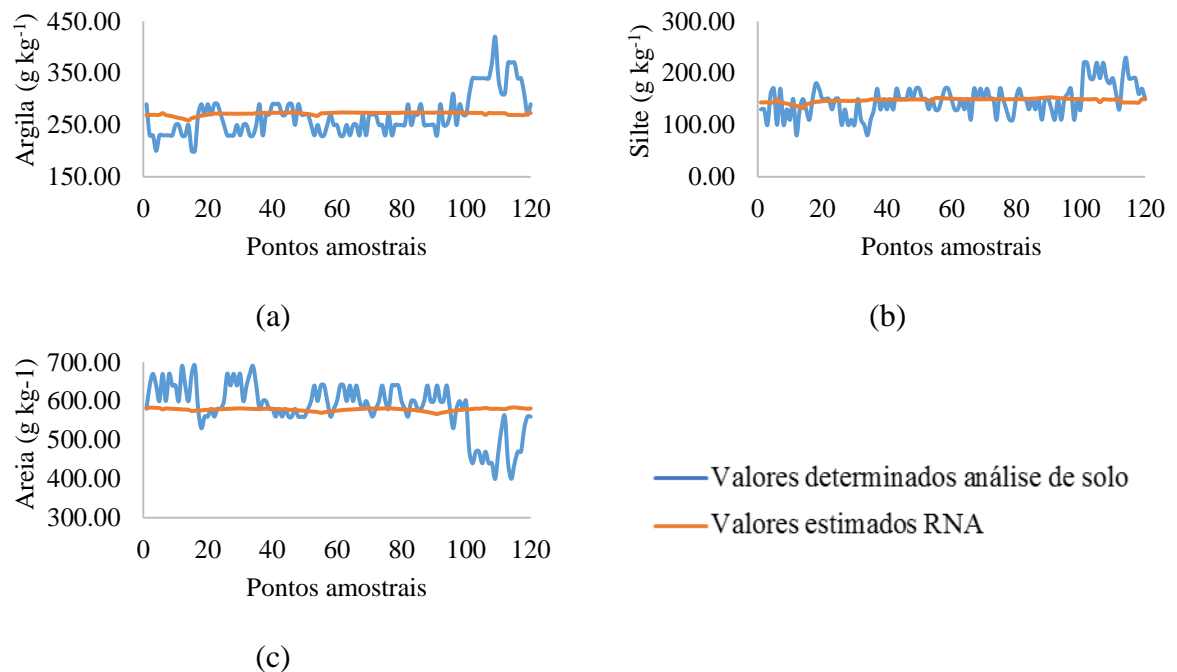


FIGURA 5 - Gráfico comparativo dos valores determinados na análise de solo *versus* valores estimados pela RNA. (a) Argila, (b) Silte e (c) Areia.

3.2. Análise Estatística

3.2.1. Análise Exploratória

A análise exploratória, por meio de gráfico de box-plot (Anexo A, Figura 1) foi realizada para cada um dos atributos de solo estudados, tanto para os dados determinados na análise de solo quanto para os dados estimados pela RNA. Para os atributos determinados pela análise de solo pH, Ca+Mg, H+Al, P e V% foram detectados a presença de *outliers* e para a eliminação desses valores discrepantes (*outliers*) (Anexo B, Tabela 1) foi utilizado critério de rejeição de Tukey (1960). Os dados discrepantes podem afetar a variância aleatória existente no processo, implicando na presença ou ausência de correlação espacial (RIBEIRO JÚNIOR e DIGGLE, 2001). Portanto, estes pontos foram removidos para posterior análise espacial.

Mesmo excluindo os valores considerados *outliers*, a maioria dos atributos de solo continuaram apresentando coeficientes de variação (CV) entre médio e alto (Tabela 2), segundo a classificação proposta por Warrick e Nielsen (1980).

O valor de coeficiente de variação (CV) para pH, V% e Areia (Tabela 2) foram classificados como baixo ($CV < 12\%$), para ambos conjuntos de dados. Sanches et al. (2009), também encontraram CV baixo para o atributo areia, isso pode estar relacionado pelo fato que a areia é um dos atributos do solo com maior estabilidade, ou seja, modifica-se pouco ao longo do tempo por ação do intemperismo.

Para os atributos determinados na análise de solo Ca, Mg, Ca+Mg, H+Al, CTC, K, P, MO, Argila e Silte foram classificados como médio ($12\% < CV < 60\%$) e alto para Al e m% ($CV > 60\%$). Em estudos realizados por Cherubin et al. 2014, Santi et al. 2012 e Cherubin et al. 2011 o coeficiente de variação também variaram nessa faixa.

Valores elevados de CV podem ser considerados como os primeiros indicadores da existência de heterogeneidade nos dados, os valores encontrados de Al e m% para os dados determinados na análise de solo e os dados estimados pela RNA, nos 120 pontos analisados, apenas em oito pontos foram detectados a presença desses atributos, justificando alto coeficiente de variação, resultados semelhantes foram encontrados por Dias et al. (2015) estudando a distribuição espacial das características físicas e químicas do solo de cerrado.

TABELA 2 - Estatística descritiva dos atributos de solo na profundidade de (0 - 20 m).

| Atributos | Origem dos dados | Média | MD | Var | DP | Ass | Cur | CV (%) | P-Value |
|-----------|------------------|--------|--------|---------|-------|-------|-------|--------|---------|
| pH | An. solo | 5,65 | 5,70 | 0,07 | 0,26 | -0,44 | -0,34 | 4,56 | 0,0026 |
| | RNA | 5,67 | 5,68 | 0,01 | 0,10 | 0,05 | -0,40 | 1,82 | 0,4762 |
| Ca | An. solo | 4,77 | 4,80 | 0,96 | 0,98 | 0,35 | 0,95 | 20,51 | 0,1209 |
| | RNA | 4,83 | 4,76 | 0,08 | 0,28 | 0,27 | 0,43 | 5,79 | 0,0007 |
| Mg | An. solo | 0,99 | 0,90 | 0,09 | 0,29 | 1,25 | 1,63 | 29,49 | 0,0000 |
| | RNA | 0,97 | 0,95 | 0,01 | 0,12 | 0,86 | 0,22 | 11,99 | 0,0000 |
| Ca+Mg | An. solo | 5,70 | 5,65 | 1,34 | 1,16 | 0,41 | 0,73 | 20,33 | 0,0203 |
| | RNA | 5,86 | 5,82 | 0,10 | 0,32 | -0,04 | -0,33 | 5,43 | 0,0084 |
| Al | An. solo | 0,01 | 0,00 | 0,00 | 0,03 | 4,22 | 19,06 | 392,74 | 0,0000 |
| | RNA | 0,00 | 0,01 | 0,00 | 0,01 | 3,98 | 17,99 | 267,35 | 0,0000 |
| H+Al | An. solo | 1,63 | 1,60 | 0,12 | 0,35 | -0,24 | -0,56 | 21,54 | 0,0106 |
| | RNA | 1,65 | 1,63 | 0,07 | 0,26 | 0,22 | -1,09 | 15,41 | 0,0002 |
| CTC | An. solo | 7,90 | 8,00 | 1,04 | 1,02 | 0,46 | 0,62 | 12,88 | 0,0010 |
| | RNA | 8,02 | 8,12 | 0,13 | 0,36 | -0,21 | -0,44 | 4,48 | 0,0000 |
| K | An. solo | 0,48 | 0,51 | 0,01 | 0,12 | -0,08 | -1,49 | 24,69 | 0,0000 |
| | RNA | 0,48 | 0,48 | 0,00 | 0,06 | -0,11 | -1,07 | 12,61 | 0,0012 |
| P | An. solo | 10,08 | 9,00 | 13,60 | 3,69 | 1,32 | 1,52 | 36,60 | 0,0000 |
| | RNA | 10,64 | 10,12 | 10,95 | 3,31 | 0,59 | 1,73 | 31,10 | 0,0013 |
| m% | An. solo | 0,18 | 0,00 | 0,55 | 0,74 | 5,38 | 34,51 | 423,38 | 0,0000 |
| | RNA | 0,10 | 0,11 | 0,00 | 0,04 | -0,24 | -1,40 | 44,21 | 0,0000 |
| V% | An. solo | 76,85 | 77,00 | 28,95 | 5,38 | -0,43 | -0,07 | 7,00 | 0,0201 |
| | RNA | 77,70 | 77,81 | 0,16 | 0,40 | -1,01 | 0,35 | 0,51 | 0,0000 |
| MO | An. solo | 23,88 | 23,00 | 17,55 | 4,19 | 0,99 | 1,93 | 17,54 | 0,0000 |
| | RNA | 24,37 | 24,41 | 3,80 | 1,95 | 0,32 | 0,74 | 8,00 | 0,0034 |
| Argila | An. solo | 268,42 | 250,00 | 1608,40 | 40,10 | 1,17 | 1,49 | 14,94 | 0,0000 |
| | RNA | 271,71 | 273,10 | 8,81 | 2,97 | -2,12 | 4,78 | 1,09 | 0,0000 |
| Silte | An. solo | 147,42 | 150,00 | 889,91 | 29,83 | 0,29 | 0,25 | 20,24 | 0,0005 |
| | RNA | 147,75 | 149,08 | 13,82 | 3,72 | -1,61 | 3,08 | 2,52 | 0,0000 |
| Areia | An. solo | 584,17 | 600,00 | 4004,34 | 63,28 | -0,98 | 0,87 | 10,83 | 0,0000 |
| | RNA | 578,12 | 579,16 | 11,98 | 3,46 | -1,09 | 0,84 | 0,60 | 0,0000 |

pH - potencial hidrogeniônico; Ca - cálcio ($\text{cmol}_c \text{dm}^{-3}$); Mg - magnésio ($\text{cmol}_c \text{dm}^{-3}$); Ca+Mg - ($\text{cmol}_c \text{dm}^{-3}$); Al - alumínio ($\text{cmol}_c \text{dm}^{-3}$); H+Al - acidez potencial ($\text{cmol}_c \text{dm}^{-3}$); CTC - capacidade de troca catiônica ($\text{cmol}_c \text{dm}^{-3}$); K - potássio ($\text{cmol}_c \text{dm}^{-3}$); P - fósforo (mg dm^{-3}); m% - saturação por alumínio (%); V% - saturação por bases (%); MO - matéria orgânica (g kg^{-1}); Argila - (g kg^{-1}); Silte - (g kg^{-1}); Areia - (g kg^{-1}); MD - mediana; Var - variância; DP - desvio padrão; Ass - coeficiente de assimetria; Cur - curtose; CV (%) - coeficiente de variação; P-Value - teste de normalidade de Shapiro Wilk a 5%; RNA - Rede neural artificial; An. solo - Análise de solo.

Observa-se que os valores das medidas de tendência central (média e mediana) foram bem próximos, indicando distribuição simétrica e assimétrica a esquerda, confirmada pelos valores de assimetria próximos de zero e assimetria negativa, o que ocorreu para todos os

atributos estimados por meio da RNA em exceção do atributo Al e os atributos determinados pela análise de solo pH, Ca, H+Al, K, V%, Silte e Areia. De acordo com Isaaks e Srivastava (1989), o coeficiente de assimetria é mais sensível a valores extremos do que a média, mediana e o desvio padrão, uma vez que um único valor pode influenciar fortemente o coeficiente de assimetria, pois os desvios entre cada valor e a média são elevados à terceira potência. Igualmente ao coeficiente de assimetria, os coeficientes de curtose foram próximos de zero para esses mesmos atributos. Os atributos da análise de solo Mg, Ca+Mg, Al, CTC, P, m%, MO e Argila, apresentaram assimetria positiva com uma cauda mais alongada à direita e valores de média superiores à moda, Tabela 2.

Pelo teste de Shapiro-Wilk a 5% de significância, observou-se que, com exceção do atributo Ca para os dados obtidos pela análise de solo e com exceção do atributo pH estimado pela RNA, não há distribuição normal para os demais atributos dos dois conjuntos de dados estudados. Segundo Webster e Oliver (2007), a normalidade dos dados não é uma exigência da geoestatística, sendo conveniente apenas que a distribuição não apresente caudas muito alongadas, o que poderia comprometer as análises. Já, Gonçalves et al. (2001) evidenciaram que a distribuição normal dos dados é muito interessante na avaliação da dependência espacial, porém, mais importante que a normalidade é a verificação de que os dados não apresentem tendência.

Entre os fatores de natureza física do solo, a estrutura e a textura do solo são relevantes no desenvolvimento das plantas. De acordo com o tamanho das partículas a fração mineral do solo divide-se em três subfrações sendo a maior a areia, a intermediária o silte e a menor a argila. A argila é uma das mais importantes em termos de manutenção da produção vegetal pois, devido ao seu tamanho minúsculo, possui propriedades específicas, como a exposição de cargas elétricas e essas cargas são responsáveis pela retenção dos nutrientes no solo, porém, as partículas mais grossas como a areia e o silte são importantes para que haja infiltração da água no solo, por aumentarem sua porosidade (SILVA et al., 2012). Com base nos valores médios em g kg^{-1} de proporção de: argila $268,42 \text{ g kg}^{-1}$ ($\cong 27\%$), silte $147,42 \text{ g kg}^{-1}$ ($\cong 15\%$) e areia $584,17 \text{ g kg}^{-1}$ ($\cong 58\%$) e baseado no modelo de identificação de classes texturais de amostras de solo (triângulo textural) apresentado pela Embrapa (2013), é possível classificar o perfil do solo como textura franco argilo arenosa.

Ambos conjuntos de dados (Análise de solo e RNA) apresentaram a mesma classificação para o solo em estudo sendo, potencial hidrogeniônico (pH) fracamente ácido, Ca médio, Mg médio, H+Al baixo, CTC alto, P médio, K alto, m% baixo, V% muito alto e MO médio, de acordo com a classificação da Comissão de Fertilidade de Solos de Goiás (1988). A saturação por bases

é um indicador de fertilidade do solo e com o percentual alto encontrando de 76,85% (Análise de solo) e 77,70% (RNA), esse solo pode ser classificado como fértil apresentando boas condições ao desenvolvimento da cultivar em estudo. O valor médio da Capacidade de Troca Catiônica (CTC) foi 7,9 cmolc dm^{-3} (Análise de solo) e 8,02 cmolc dm^{-3} (RNA) sendo assim, o solo foi classificado como de fertilidade alta, Tabela 2. Alves et al. (2014), considera a CTC sendo uma característica fundamental ao manejo adequado do solo, representando a graduação da capacidade de liberação de vários nutrientes, ou seja, quando maior a sua presença maior será a capacidade de cátions que esse solo pode reter.

3.2.2. Análise Geoestatística

Por meio do teste de normalidade de Shapiro-Wilk (Tabela 2) verificou-se que os dois conjuntos de dados não seguem distribuição normal ($p \leq 0,05$). Os atributos da análise de solo Mg, Ca+Mg, Al, CTC, P, m%, MO e Argila, além de não apresentarem distribuição normal, também apresentaram assimetria positiva, sendo então necessária à transformação dos dados antes de realizar a análise geoestatística. A transformação faz-se necessária para evitar a influência dos altos valores na estimativa de pontos da vizinhança (YAMAMOTO e LANDIM, 2013).

A Tabela 3 apresenta o resultado da análise geoestatística com os modelos ajustados aos semivariogramas para os atributos de solo, dos dados determinados pela análise de solo e dados estimados pela RNA. Em exceção dos atributos alumínio (Al), potássio (K) e saturação por alumínio (m%) para os dados da análise de solo e RNA, todos os demais atributos de solo apresentaram dependência espacial, sendo os modelos exponencial e esférico os que melhores se ajustaram aos dados da análise de solo e estimados pela RNA, esses modelos foram utilizados para representar os semivariogramas e estimar os valores para elaborar os mapas de isolinhas.

O ajuste dos semivariogramas permitiu identificar dados de Al, K e m% com descontinuidade espacial, chamado efeito pepita puro. Esta análise demonstra que os dados podem ser amostrados em distâncias menores do que 50 m e que podem assumir uma distribuição ao acaso, pois há independência entre as amostras. Assim, os dados podem ser tratados pela estatística clássica, sendo a média aritmética um valor que representa o conjunto de dados.

O valor do alcance para os dados obtidos por meio da análise de solo variou de 70,20 a 171,30 m, enquanto o alcance para os dados obtidos por meio da RNA variou de 138,60 a 940,80, Tabela 3. O alcance representa a distância limite na qual uma variável regionalizada apresenta continuidade espacial (dependência espacial). Assim, variáveis amostradas a distâncias maiores que os valores de alcance apresentam distribuição aleatória, sendo independentes entre si (WEBSTER e OLIVER, 2007).

TABELA 3 - Modelos teóricos de semivariograma ajustados para os atributos de solo determinados pela análise de solo e os estimados pela RNA.

| Atributo | Origem dos dados | Semivariograma | A | C ₀ | C ₀ +C | SQR | R ² | ADE | GD |
|----------|------------------|----------------|--------|----------------|-------------------|--------|----------------|--------|-------|
| pH | An. solo | Esférico | 75,10 | 0,0035 | 0,0681 | 0,0001 | 0,7280 | 94,90 | Forte |
| | RNA | Esférico | 213,90 | 0,0000 | 0,0086 | 0,0000 | 0,9320 | 99,90 | Forte |
| Ca | An. solo | Exponencial | 91,50 | 0,1530 | 1,0230 | 0,0073 | 0,7940 | 85,00 | Forte |
| | RNA | Exponencial | 459,60 | 0,0001 | 0,0875 | 0,0006 | 0,9160 | 99,90 | Forte |
| Mg | An. solo | Exponencial | 96,00 | 0,0103 | 0,0767 | 0,0002 | 0,6160 | 86,60 | Forte |
| | RNA | Exponencial | 940,80 | 0,0000 | 0,0210 | 0,0000 | 0,9590 | 100,00 | Forte |
| Ca+Mg | An. solo | Exponencial | 75,00 | 0,1910 | 1,2780 | 0,0172 | 0,5940 | 85,10 | Forte |
| | RNA | Exponencial | 584,70 | 0,0001 | 0,1182 | 0,0009 | 0,9460 | 99,90 | Forte |
| Al | An. solo | EPP | - | - | - | - | - | - | - |
| | RNA | EPP | - | - | - | - | - | - | - |
| H+Al | An. solo | Esférico | 114,80 | 0,0108 | 0,1326 | 0,0006 | 0,7590 | 91,90 | Forte |
| | RNA | Esférico | 171,40 | 0,0001 | 0,0669 | 0,0006 | 0,8490 | 99,90 | Forte |
| CTC | An. solo | Exponencial | 100,20 | 0,1280 | 0,8520 | 0,0086 | 0,7740 | 85,00 | Forte |
| | RNA | Exponencial | 606,00 | 0,0001 | 0,1552 | 0,0015 | 0,9460 | 99,90 | Forte |
| K | An. solo | EPP | - | - | - | - | - | - | - |
| | RNA | EPP | - | - | - | - | - | - | - |
| P | An. solo | Esférico | 109,60 | 0,0019 | 0,0717 | 0,0000 | 0,9420 | 97,40 | Forte |
| | RNA | Esférico | 138,60 | 0,0083 | 0,1226 | 0,0008 | 0,8130 | 93,20 | Forte |
| m% | An. solo | EPP | - | - | - | - | - | - | - |
| | RNA | EPP | - | - | - | - | - | - | - |
| V% | An. solo | Exponencial | 74,10 | 0,0007 | 0,0053 | 0,0000 | 0,6530 | 87,70 | Forte |
| | RNA | Exponencial | 303,70 | 0,0010 | 0,5470 | 0,0067 | 0,9730 | 99,80 | Forte |
| MO | An. solo | Esférico | 70,20 | 0,3000 | 9,6600 | 0,1100 | 0,6670 | 96,90 | Forte |
| | RNA | Esférico | 258,60 | 0,0000 | 0,0064 | 0,0000 | 0,9640 | 99,80 | Forte |
| Argila | An. solo | Exponencial | 171,30 | 0,0015 | 0,0196 | 0,0000 | 0,8580 | 92,50 | Forte |
| | RNA | Exponencial | 613,80 | 0,0000 | 0,0001 | 0,0000 | 0,9580 | 99,90 | Forte |
| Silte | An. solo | Exponencial | 98,10 | 0,0031 | 0,0419 | 0,0000 | 0,6510 | 92,60 | Forte |
| | RNA | Exponencial | 188,10 | 0,0000 | 0,0172 | 0,0000 | 0,9200 | 99,90 | Forte |
| Areia | An. solo | Exponencial | 171,00 | 0,0008 | 0,0132 | 0,0000 | 0,8520 | 93,90 | Forte |
| | RNA | Exponencial | 332,70 | 0,0000 | 0,0001 | 0,0000 | 0,9800 | 99,90 | Forte |

A - alcance; C₀ - Efeito Pepita; C₀+C - Patamar; SQR - soma de quadrado do resíduo; R² - coeficiente de determinação; ADE - Avaliador de Dependência Espacial (%); GD - grau de dependência; pH - potencial hidrogeniônico; Ca - cálcio (cmol_c dm⁻³); Mg - magnésio (cmol_c dm⁻³); Ca+Mg - (cmol_c dm⁻³); Al - alumínio (cmol_c dm⁻³); H+Al - acidez potencial (cmol_c dm⁻³); CTC - capacidade de troca catiônica (cmol_c dm⁻³); K - potássio (cmol_c dm⁻³); P - fósforo (mg dm⁻³); m% - saturação por alumínio (%); V% - saturação por bases (%); MO - matéria orgânica (g kg⁻¹); Argila - (g kg⁻¹); Silte - (g kg⁻¹); Areia - (g kg⁻¹); EPP - efeito pepita puro; An. solo - análise de solo; RNA - Rede neural artificial.

Foi possível verificar dependência espacial para 12 dos 15 atributos (Tabela 3), o que indica ser possível estudar a variabilidade espacial destes atributos com a malha amostral

utilizada de 50x50 m. Souza et al. (2014) sugerem que a redução da dimensão da malha amostral, ou seja, o aumento da densidade amostral e a aproximação dos pontos amostrais promove maior detalhamento da distribuição espacial dos atributos na área e portanto, melhora a acurácia das informações geradas por meio dos mapas temáticos.

O grau de dependência espacial em ambos os métodos de determinação dos atributos de solo foi classificado como forte (Tabela 3). Variogramas com estrutura de dependência espacial de moderada a forte geram mapas de krigagem mais precisos, que aqueles gerados com dependência espacial fraca, devido à menor contribuição do componente aleatório na variabilidade dos dados (SOUZA et al., 2014; KRAVCHENKO, 2003).

O coeficiente de determinação é um dos parâmetros utilizados para definição do melhor modelo de semivariograma, quanto mais próximo de 1 indica que o modelo de semivariograma escolhido explica adequadamente a dependência espacial das variáveis analisadas. Os modelos dos semivariogramas variaram de 0,59 a 0,86 para os dados determinados pela análise de solo e 0,81 a 0,98 para os dados estimados pela RNA, mostrando que os dados provenientes da RNA conseguiram explicar a dependência espacial dos 12 atributos analisados, conforme observado na Tabela 3.

3.2.3. Qualidade do ajuste do semivariograma

A fim de verificar a qualidade do ajuste do semivariograma aos dados experimentais e assim constatar o modelo que melhor se adequou, foram utilizadas as técnicas da geoestatística: a Validação Cruzada (Figuras 6 a 17), o grau de dependência espacial, o coeficiente de determinação e a soma dos quadrados dos resíduos (Tabela 3). A Validação Cruzada consiste em estimar, com base no modelo de semivariograma ajustado, os pontos que foram realmente amostrados podendo assim, comparar o valor estimado ao real, pelo erro de estimação. O procedimento consiste em eliminar cada um dos pontos amostrados e estimar o valor retirado, utilizando as amostras remanescentes.

O coeficiente de regressão apresenta o ajuste da equação de regressão linear entre os valores determinados pela análise de solo e os valores estimados pela RNA e os valores estimados por interpolação. Observou-se nas Figuras 6 a 17 que quanto mais afastada a reta está da linha pontilhada, maior é o desvio entre o valor observado e o estimado pelo modelo. Quando a reta estiver acima da linha pontilhada ela estará superestimando e quando abaixo subestimando os valores das observações.

Observou-se que para todos os atributos de solo estimados pela RNA, a reta está praticamente sobrepondo a linha pontilhada, evidenciando uma estimativa bem melhor das

observações de cada atributo de solo, Figuras 6 a 17. Num estudo geoestatístico, a parte fundamental refere-se à determinação do semivariograma, todo o cuidado deve ser tomado na análise semivariográfica para que possa obter uma criteriosa análise geoestatística (LANDIM, 2006).

Baseando-se nos valores do coeficiente de regressão e do intercepto, que são constituintes da equação de regressão, em que coeficientes de regressão próximo de 1 e intercepto próximo de 0 são adequados, demonstram que os atributos Mg e H+Al (determinados pela análise de solo) Figuras 8 e 10 e os atributos pH, Ca, Mg, Ca+Mg, H+Al, P e MO (estimados pela RNA) foram estimados sem tendência e com variância mínima, Figuras 6, 7, 9, 11 e 12.

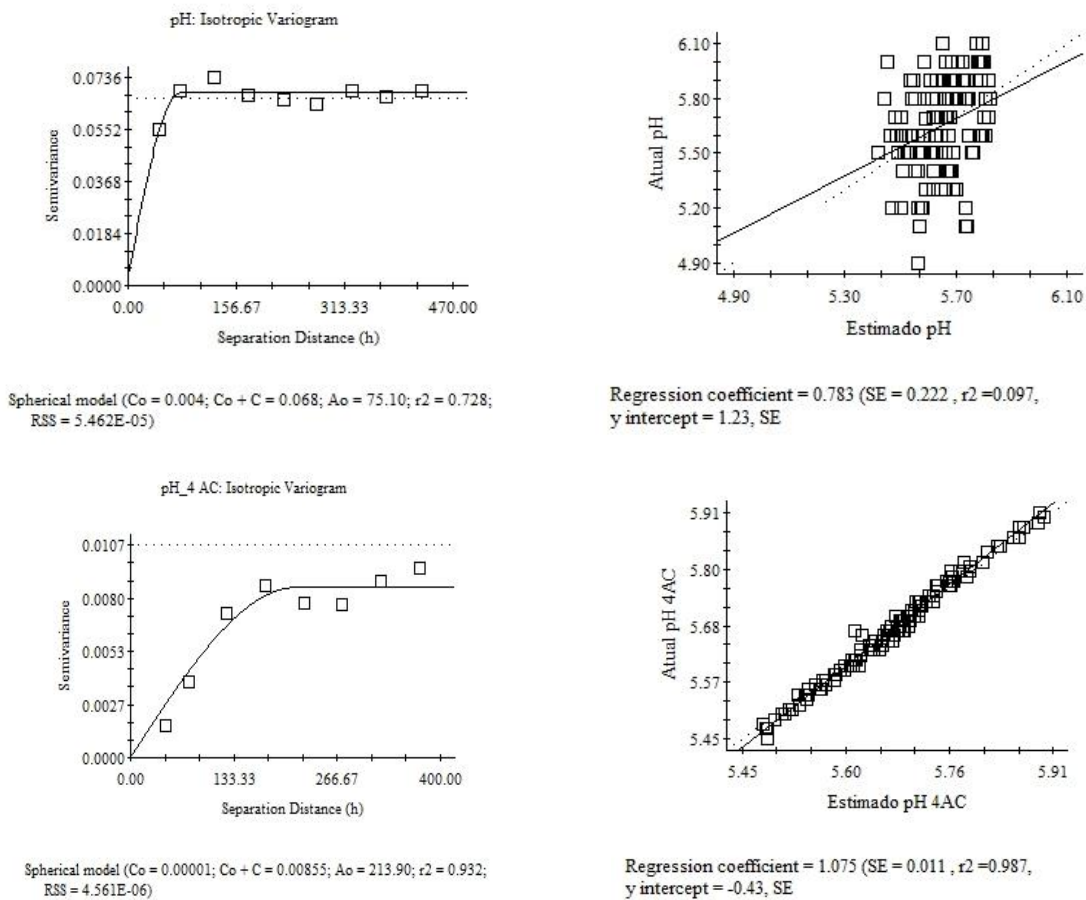


FIGURA 6 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo pH, dos dados determinados pela análise de solo e os estimados pela RNA.

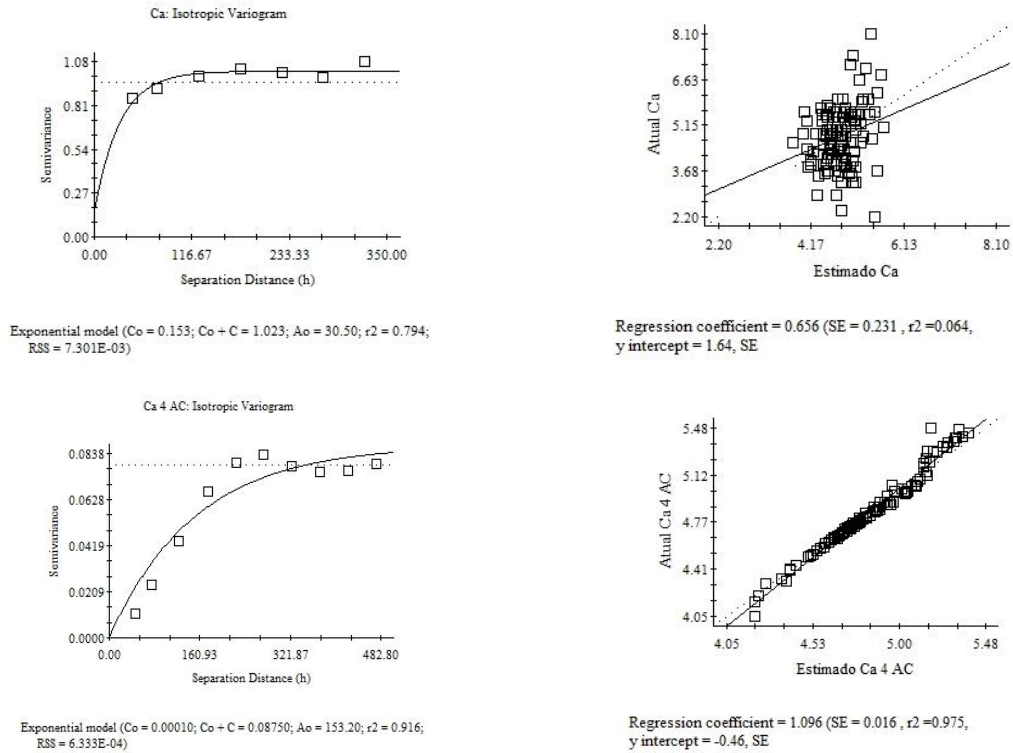


FIGURA 7 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Ca, dos dados determinados pela análise de solo e os estimados pela RNA.

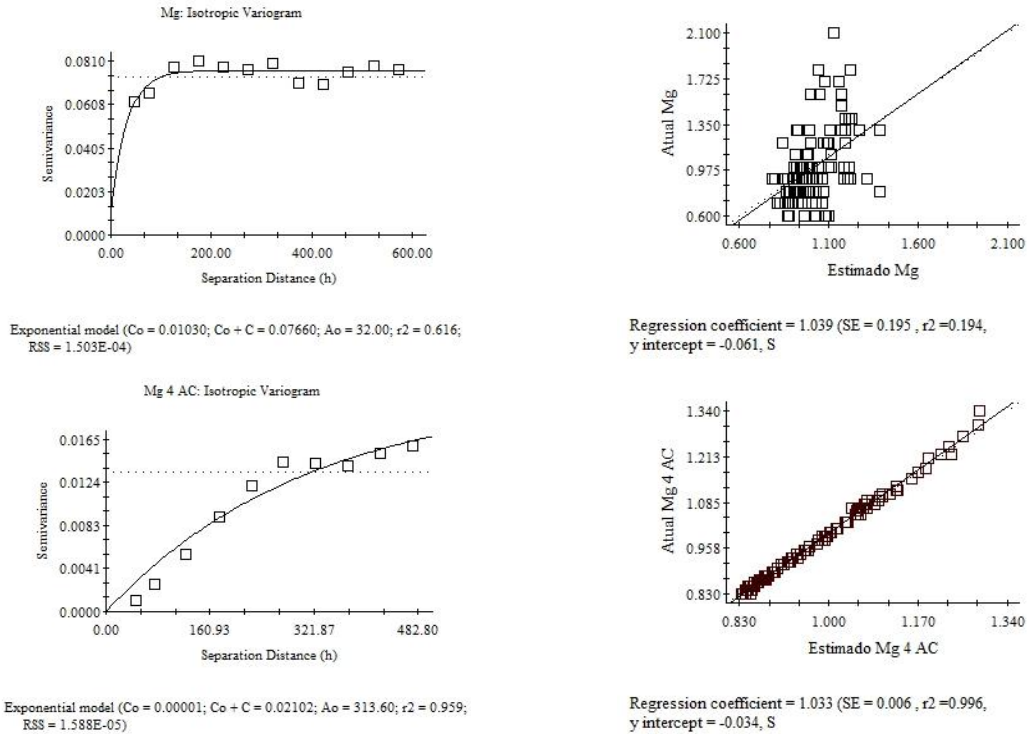


FIGURA 8 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Mg, dos dados determinados pela análise de solo e os estimados pela RNA.

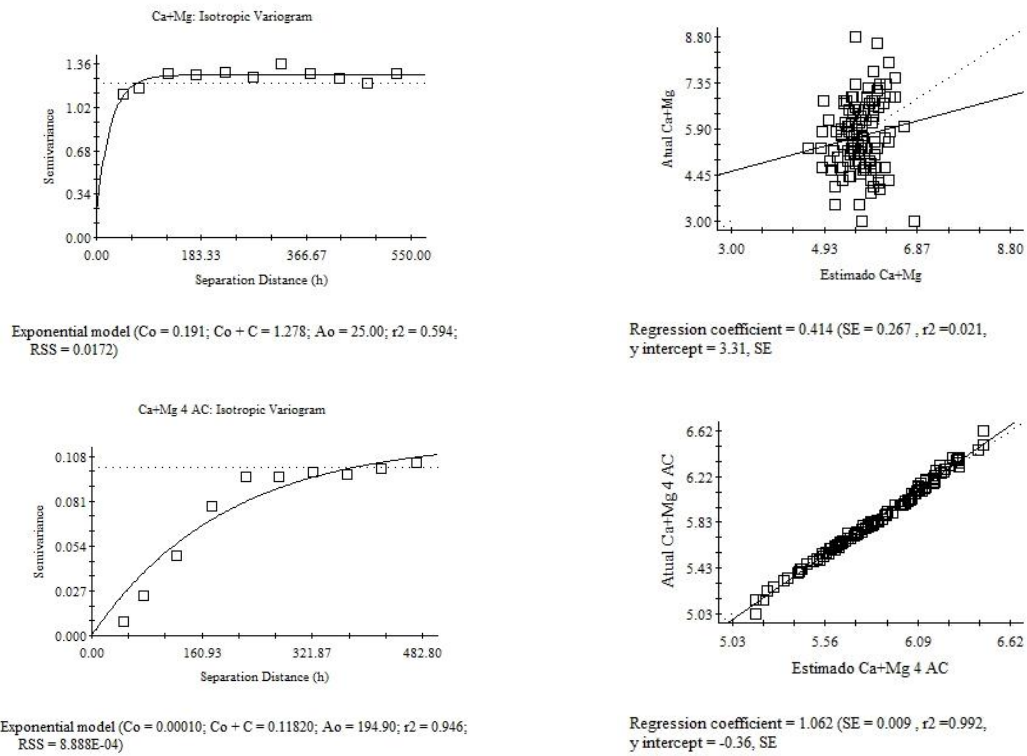


FIGURA 9 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Ca+Mg, dos dados determinados pela análise de solo e os estimados pela RNA.

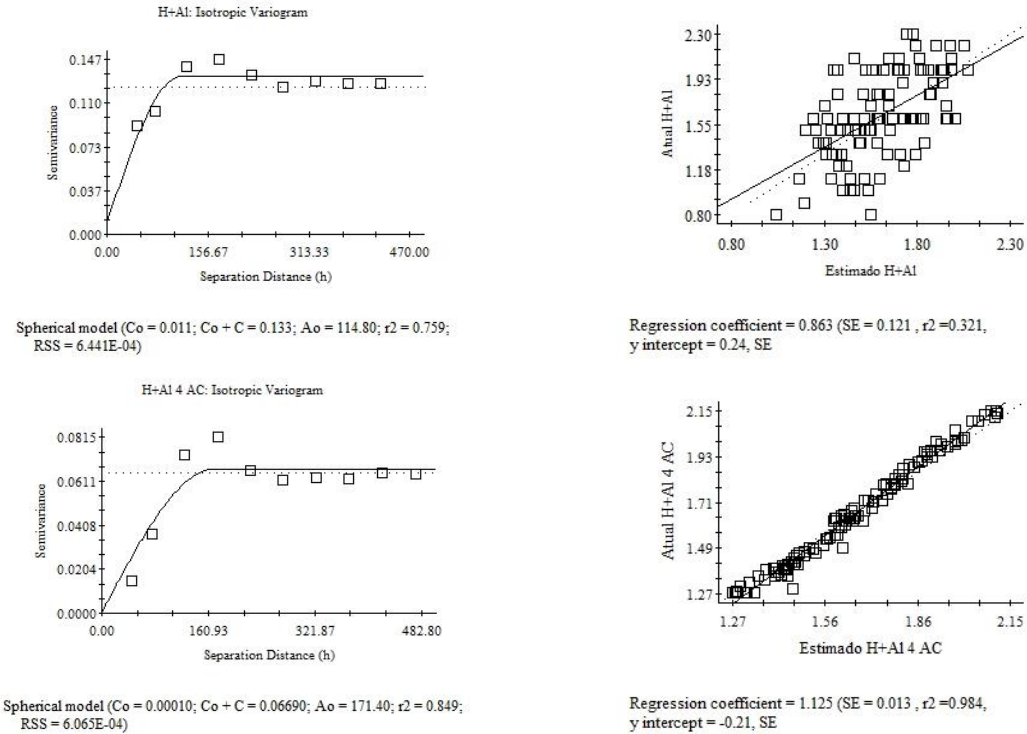


FIGURA 10 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo H+Al, dos dados determinados pela análise de solo e estimados pela RNA.

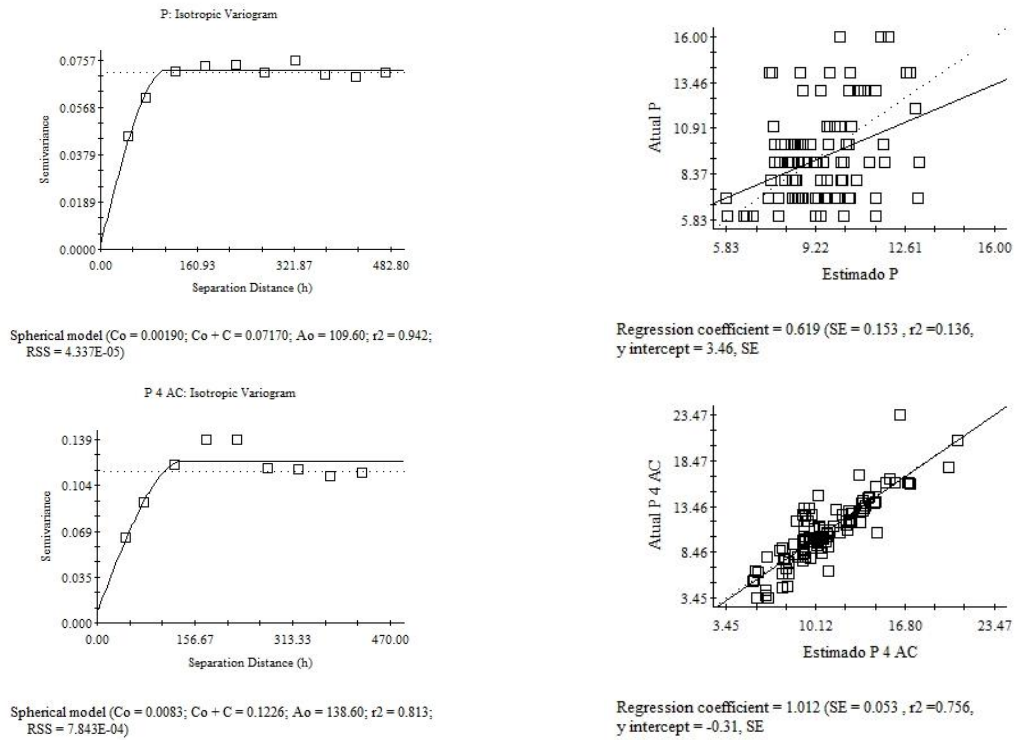


FIGURA 11 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo P, dos dados determinados pela análise de solo e os estimados pela RNA.

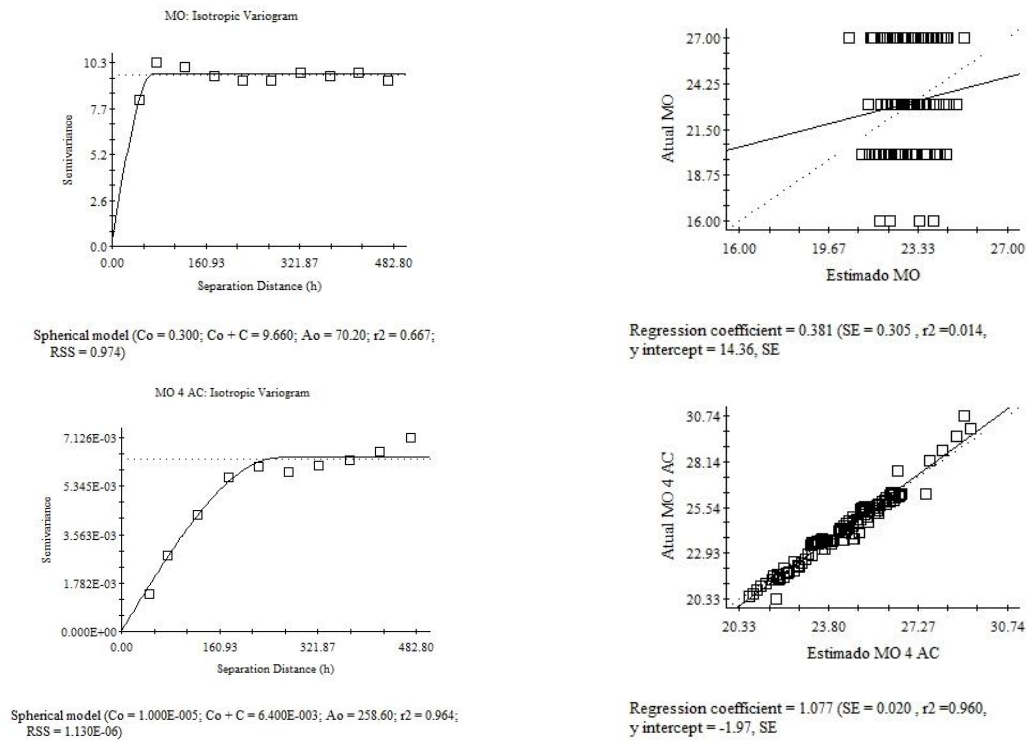


FIGURA 12 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo MO, dos dados determinados pela análise de solo e os estimados pela RNA.

O coeficiente de regressão dos parâmetros utilizados para definição do melhor modelo de semivariograma é calculado após a validação cruzada e, quanto mais próximo de 1 indica que o modelo de semivariograma escolhido explica adequadamente a dependência espacial das

variáveis analisadas. Para os atributos de fertilidade do solo CTC e V% o coeficiente de regressão foi de 0,274 e 0,671 para os dados de análise de solo e 1,054 e 1,018 para os dados estimados pela RNA, respectivamente (Figuras 13 e 14).

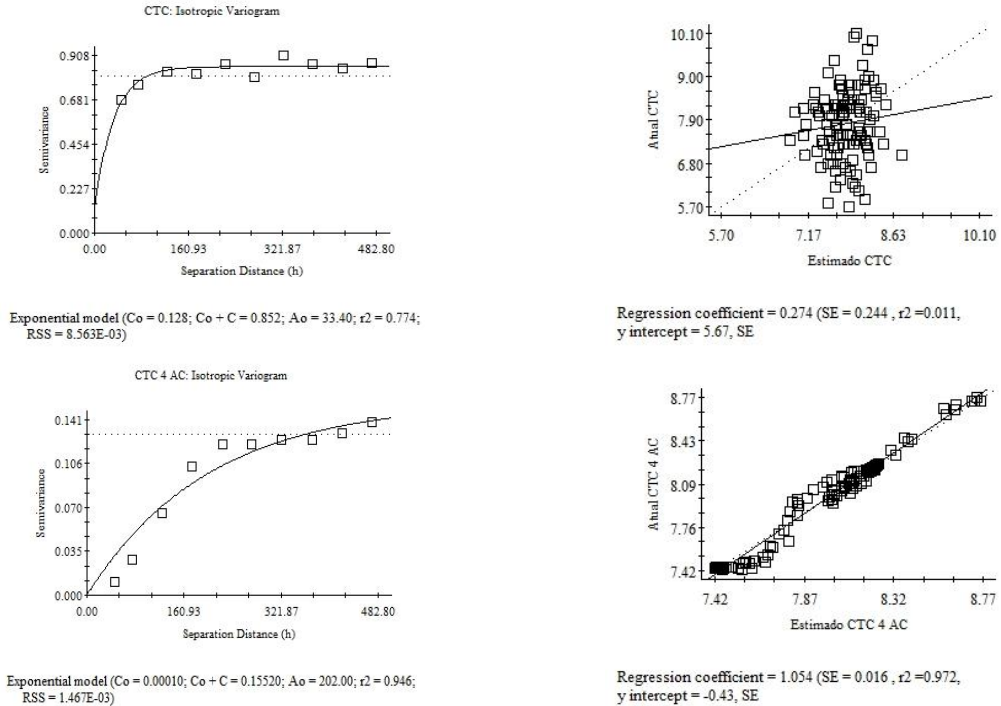


FIGURA 13 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada do atributo CTC, dos dados determinados pela análise de solo e os estimados pela RNA.

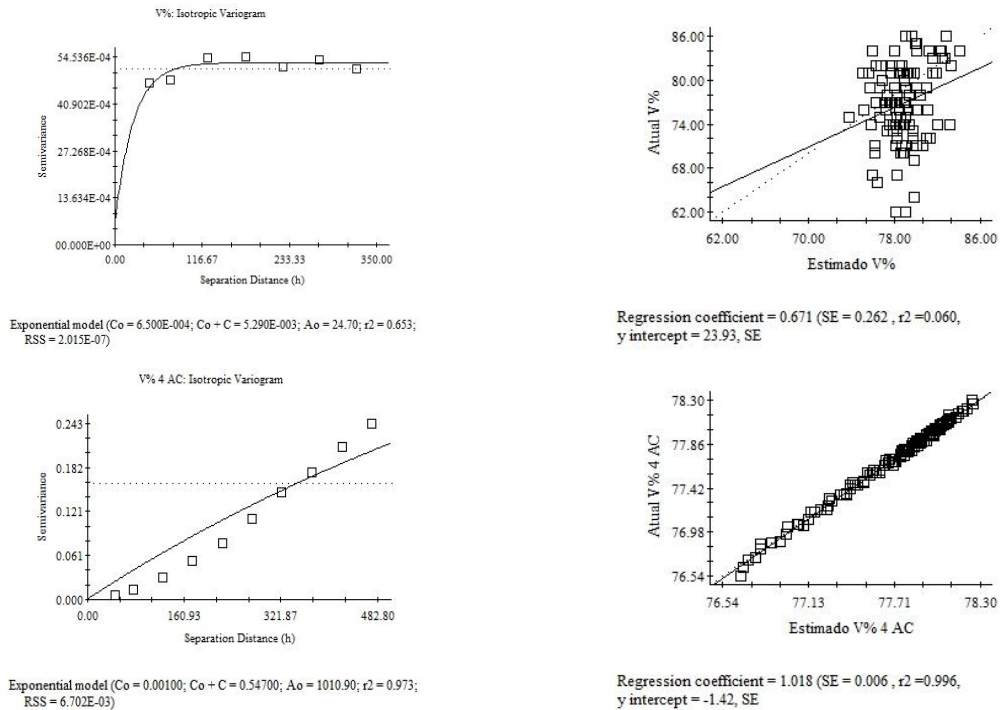


FIGURA 14 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo V%, dos dados determinados pela análise de solo e os estimados pela RNA.

O coeficiente de regressão para o atributo de solo argila foi de 0,812 para os dados determinados na análise de solo e 0,868 para os dados estimados pela RNA (Figura 15). Já o coeficiente de regressão para o atributo de solo silte foi de 0,453 para os dados determinados na análise de solo e 1,194 para os dados estimados pela RNA (Figura 16) e o coeficiente de regressão para o atributo de solo areia foi de 0,723 para os dados determinados na análise de solo e 0,976 para os dados estimados pela RNA (Figura 17). Observou-se que os dados estimados pela RNA para esses atributos resultaram em coeficientes de regressão mais próximos de 1, indicando que o modelo de semivariograma escolhido explica adequadamente a dependência espacial das variáveis analisadas.

Os critérios para a validação cruzada foram utilizados com o objetivo de ajudar a escolher o melhor entre os diferentes modelos teóricos. E o melhor modelo indicado pela validação cruzada foi utilizado para a interpolação por meio da krigagem ordinária.

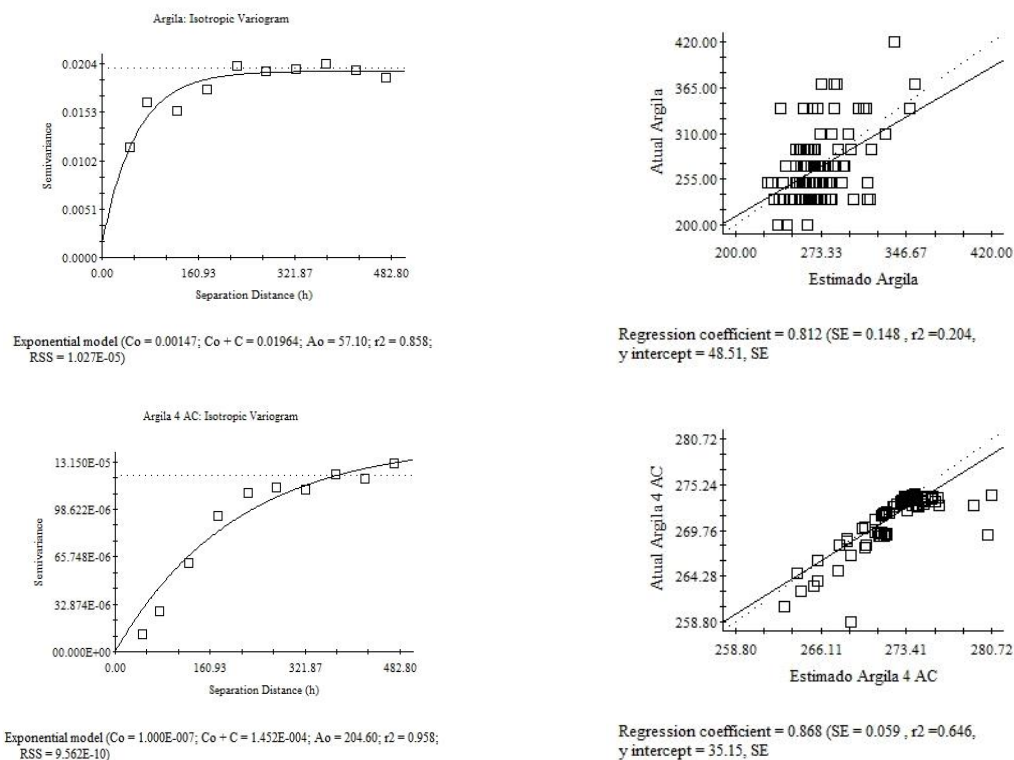


FIGURA 15 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Argila, dos dados determinados pela análise de solo e os estimados pela RNA.

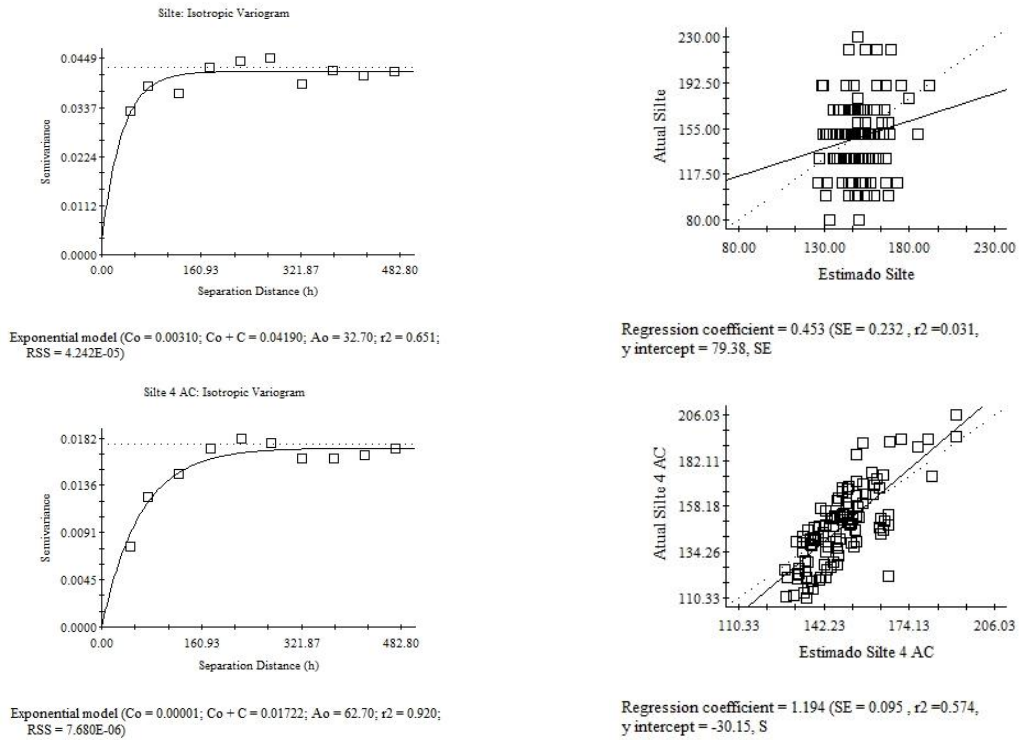


FIGURA 16 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Silte, dos dados determinados pela análise de solo e os estimados pela RNA.

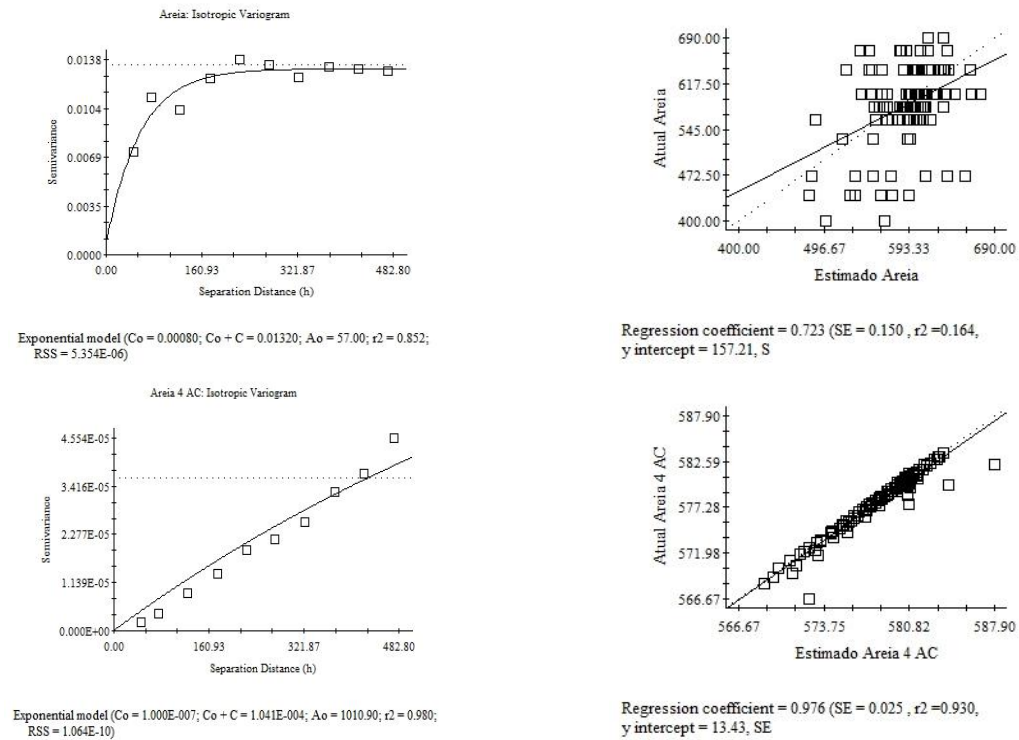


FIGURA 17 - Modelo de semivariograma ajustado e diagrama de dispersão da validação cruzada para o atributo Areia, dos dados determinados pela análise de solo e os estimados pela RNA.

3.3. Comparação dos resultados da análise de solo, resultados da rede neural e da análise geoestatística (krigagem ordinária)

Na Tabela 4, está apresentado o resultado do Teste-t de Student para comparação da média dos 120 pontos, de cada atributo obtidas pela análise de solo com a média dos 120 pontos de cada atributo obtidas pela RNA, com 4 pontos amostrais conhecidos. E também, tem-se o resultado do Test-t Student para a comparação das médias provenientes das estimativas dos 120 pontos após a análise geoestatística utilizando a krigagem ordinária, nos dois conjuntos de dados.

Observa-se que não houve diferença significativa entre nenhuma das médias dos atributos de solos comparados (Tabela 4), verificando que em relação as médias, pode-se afirmar que a RNA conseguiu estimar os atributos com um bom grau de confiança. Aitkenhead et al. (2012), em seus estudos conseguiram prever com um bom grau de confiança a composição química e física do solo utilizando informações de observações de campo em uma rede neural. Estudos utilizando redes neurais artificiais para estimativa de propriedades hidráulicas do solo demonstram que essa ferramenta apresenta alta capacidade preditiva, além de superar as metodologias tradicionais de estimativa (JANA et al., 2008; JANA e MOHANTY, 2011; SOARES et al., 2014).

TABELA 4 - Teste-t de Student para comparação de média dos resultados da análise de solo, resultados da rede neural e da análise geoestatística (krigagem ordinária)

| Origem dos Dados | Média dos 120 pontos análise solo e estimados pela RNA antes da análise geoestatística | | | | | | | | | | | |
|------------------|--|-------------------|-------------------|-------------------|-------------------|-------------------|--------------------|--------------------|--------------------|---------------------|---------------------|---------------------|
| | pH | Ca | Mg | Ca+Mg | H+Al | CTC | P | V% | MO | Areia | Silte | Argila |
| An. solo | 5,65 ^a | 4,77 ^a | 0,99 ^a | 5,70 ^a | 1,63 ^a | 7,90 ^a | 10,08 ^a | 76,85 ^a | 23,88 ^a | 268,42 ^a | 147,42 ^a | 584,17 ^a |
| RNA | 5,67 ^a | 4,83 ^a | 0,97 ^a | 5,86 ^a | 1,65 ^a | 8,02 ^a | 10,64 ^a | 77,70 ^a | 24,37 ^a | 271,71 ^a | 147,75 ^a | 578,12 ^a |
| | Estimativas da média dos 120 pontos após a análise geoestatística - Krigagem Ordinária | | | | | | | | | | | |
| | pH | Ca | Mg | Ca+Mg | H+Al | CTC | P | V% | MO | Areia | Silte | Argila |
| An. solo | 5,65 ^a | 4,77 ^a | 0,99 ^a | 5,69 ^a | 1,63 ^a | 7,97 ^a | 10,61 ^a | 77,60 ^a | 23,89 ^a | 268,74 ^a | 147,33 ^a | 584,62 ^a |
| RNA | 5,67 ^a | 4,81 ^a | 0,96 ^a | 5,80 ^a | 1,66 ^a | 7,90 ^a | 10,63 ^a | 77,61 ^a | 24,19 ^a | 271,08 ^a | 147,79 ^a | 578,05 ^a |

pH - potencial hidrogeniônico; Ca - cálcio ($\text{cmol}_c \text{dm}^{-3}$); Mg - magnésio ($\text{cmol}_c \text{dm}^{-3}$); Ca+Mg - cálcio + magnésio ($\text{cmol}_c \text{dm}^{-3}$); H+Al - acidez potencial ($\text{cmol}_c \text{dm}^{-3}$); CTC - capacidade de troca catiônica ($\text{cmol}_c \text{dm}^{-3}$); P - fósforo (mg dm^{-3}); V% - saturação por bases (%); MO - matéria orgânica (g kg^{-1}); An. solo - Análise de solo; RNA - Rede neural artificial. Médias seguidas da mesma letra na coluna e para cada atributo não diferem estatisticamente pelo teste de t a 5% de probabilidade.

3.4. Erro médio relativo dos dados estimados a partir da krigagem

Com a intenção de comparar a precisão de assertividade das estimativas geradas pela krigagem ordinária dos dados de solo e RNA, por meio dos dados determinados pelas amostras de solo, foi calculado o erro médio relativo (P), conforme Tabela 5. Foram comparados todos os atributos que apresentaram dependência espacial tanto pelos dados da análise de solo e os dados estimados pela RNA. Todos os atributos foram bem estimados pela RNA, porém, o atributo silte foi o que se destacou por apresentar um erro de 13,47% na estimativa pela RNA e um erro de 16,93% na estimativa gerada pela KO.

Os demais atributos pH, Ca, Mg, Ca+Mg, H+Al, CTC, P, V%, MO, argila e areia, apresentaram um erro muito próximo mostrando que as estimativas geradas pela krigagem ordinária dos dados de solo e RNA foram bem previstas.

TABELA 5 - Erro médio relativo P (%) entre os valores obtidos pela análise de solo e obtidos pela RNA estimados pela Krigagem ordinária.

| Atributos | P (KO) | P (KO RNA 4 AC) |
|-----------|--------|-----------------|
| pH | 3,57 | 4,21 |
| Ca | 17,09 | 17,22 |
| Mg | 20,96 | 22,54 |
| Ca+Mg | 16,11 | 17,71 |
| H+Al | 16,97 | 28,50 |
| CTC | 9,74 | 10,71 |
| P | 24,81 | 27,12 |
| V% | 12,73 | 13,63 |
| MO | 12,32 | 15,28 |
| Argila | 10,48 | 11,34 |
| Silte | 16,93 | 13,47 |
| Areia | 7,85 | 8,62 |

pH - potencial hidrogeniônico; Ca - cálcio ($\text{cmol}_c \text{dm}^{-3}$); Mg - magnésio ($\text{cmol}_c \text{dm}^{-3}$); Ca+Mg - cálcio + magnésio ($\text{cmol}_c \text{dm}^{-3}$); H+Al - acidez potencial ($\text{cmol}_c \text{dm}^{-3}$); CTC - capacidade de troca catiônica ($\text{cmol}_c \text{dm}^{-3}$); P - fósforo (mg dm^{-3}); V% - saturação por bases (%); MO - matéria orgânica (g kg^{-1}); KO - krigagem ordinária; RNA - Rede neural artificial; 4 AC - Quatro amostras conhecidas.

3.5. Eficiência da RNA na estimativa dos atributos

A eficiência na estimativa dos quinze atributos de solo foi analisada por meio dos seguintes indicadores estatísticos: erro médio relativo (P%), coeficiente de correlação (r), índice de concordância de Wilmont (c), coeficiente de determinação (R^2) e índice de desempenho (id) (Tabela 6).

Para verificar a eficiência da rede neural artificial na estimativa dos atributos de solo, os dados dos atributos de solo estimados pela rede foram comparados com os dados dos atributos

determinados pela análise laboratorial. Observou-se, que se tratando das médias não houve diferença entre os dados dos atributos de solo estimados e observados (Tabela 6). Soares et al. (2015), verificando a eficiência de uma rede neural artificial observaram que, também que não houve diferença entre os valores da produção de grãos estimados pela RNA e observados em campo.

TABELA 6 - Erro médio relativo (P%), coeficiente linear (a), coeficiente angular (b), coeficiente de determinação (R^2), coeficiente de correlação (r), índice de concordância (c) e índice de desempenho (id), obtidos na comparação entre os dados dos atributos determinados na análise de solo e estimados pela RNA.

| Atributos | Valores médios | | Indicadores estatísticos | | | | | | |
|-----------|---------------------|---------------------|--------------------------|----------|---------|---------|--------|--------|---------|
| | Análise solo | RNA | P% | a | b | r | R^2 | c | id |
| pH | 5,65 ^a | 5,67 ^a | 4,21 | 5,7046 | -0,0055 | -0,0145 | 0,0002 | 0,9923 | -0,0144 |
| Ca | 4,77 ^a | 4,83 ^a | 17,61 | 4,6425 | 0,0394 | 0,1375 | 0,0189 | 0,9914 | 0,1364 |
| Mg | 0,99 ^a | 0,97 ^a | 23,13 | 0,9375 | 0,0361 | 0,0904 | 0,0082 | 0,9924 | 0,0897 |
| Ca+Mg | 5,70 ^a | 5,86 ^a | 17,91 | 5,6305 | 0,0396 | 0,1534 | 0,0235 | 0,9917 | 0,1521 |
| Al | 0,01 ^a | 0,00 ^a | 6,86 | 0,0024 | -0,0162 | -0,0801 | 0,0064 | 0,9823 | -0,0787 |
| H+Al | 1,63 ^a | 1,65 ^a | 28,97 | 1,9209 | -0,1538 | -0,2823 | 0,0797 | 0,9916 | -0,2799 |
| CTC | 7,90 ^a | 8,02 ^a | 10,76 | 7,5816 | 0,0551 | 0,1699 | 0,0289 | 0,9921 | 0,1686 |
| K | 0,48 ^a | 0,48 ^a | 25,45 | 0,4642 | 0,0354 | 0,0689 | 0,0048 | 0,9946 | 0,0686 |
| P | 10,08 ^a | 10,64 ^a | 34,94 | 5,9875 | 0,4368 | 0,6341 | 0,4021 | 0,9967 | 0,6321 |
| m% | 0,18 ^a | 0,10 ^a | 16,13 | 0,1027 | -0,0103 | -0,1712 | 0,0293 | 0,9708 | -0,1662 |
| V% | 76,85 ^a | 77,70 ^a | 13,64 | 77,8457 | -0,0018 | -0,0324 | 0,0011 | 0,9876 | -0,0320 |
| MO | 23,88 ^a | 24,37 ^a | 15,76 | 24,0090 | 0,0152 | 0,0326 | 0,0011 | 0,9926 | 0,0324 |
| Argila | 268,42 ^a | 271,71 ^a | 11,36 | 268,9089 | 0,0104 | 0,1410 | 0,0199 | 0,9888 | 0,1394 |
| Silte | 147,42 ^a | 147,75 ^a | 16,31 | 146,4664 | 0,0087 | 0,0700 | 0,0049 | 0,9887 | 0,0692 |
| Areia | 584,17 ^a | 578,12 ^a | 8,62 | 585,9929 | -0,0135 | -0,2464 | 0,0607 | 0,9871 | -0,2432 |

pH - potencial hidrogeniônico (CaCl_2); Ca - cálcio ($\text{cmol}_c \text{dm}^{-3}$); Mg - magnésio ($\text{cmol}_c \text{dm}^{-3}$); Ca+Mg - ($\text{cmol}_c \text{dm}^{-3}$); Al - alumínio ($\text{cmol}_c \text{dm}^{-3}$); H+Al - acidez potencial ($\text{cmol}_c \text{dm}^{-3}$); CTC - capacidade de troca catiônica ($\text{cmol}_c \text{dm}^{-3}$); K - potássio ($\text{cmol}_c \text{dm}^{-3}$); P - fósforo (mg dm^{-3}); m% - saturação por alumínio (%); V% - saturação por bases (%); MO - matéria orgânica (g kg^{-1}); Argila - (g kg^{-1}); Silte - (g kg^{-1}); Areia - (g kg^{-1}). Desempenho: Critérios de Classificação de Camargo e Sentelhas (1997). Valores médios seguidos da mesma letra na linha para cada atributo não diferem estatisticamente pelo teste de t a 5% de probabilidade.

Para reforçar a validação da rede neural utilizada na estimativa dos atributos de solo, foram determinados os coeficientes lineares e angulares da reta de regressão, dos dados determinados pela análise laboratorial (x) e os dados estimados pela RNA (y), apresentados em (Anexo C, Figura 1). O resultado pode ser observado na Tabela 6, que também apresenta o coeficiente de determinação, o coeficiente de correlação, o índice de concordância e o índice de desempenho.

O coeficiente de correlação pode variar de -1 a 1 e quanto maior o seu valor absoluto, maior o grau de associação entre os valores observados e os valores estimados, sendo que o atributo fósforo (P) apresentou coeficiente de correlação de 0,6341 e um índice de concordância de 0,9967, resultando em um índice de desempenho de 0,6321 classificado como mediano por Camargo e Sentelhas (1997).

Para os demais atributos o coeficiente de correlação variou entre -0,2823 a 0,1699, resultando em uma correlação baixa, como é ressaltado por Braga et al. (2011) se nas RNAs não existir uma correlação linear entre as variáveis de entrada e as variáveis de saída, não pode julgar quais variáveis de entrada foram mais importantes no processo de aprendizagem da rede. Nagaoka et al. (2005) não encontraram relação entre os dados de entrada da rede e os dados de saída, quando testaram diferentes arquiteturas de RNAs com objetivo de estimar a densidade do solo.

O índice de concordância (c) fornece o grau de exatidão dos dados observados e estimados pela RNA, variando entre 0 (zero) (nenhuma concordância) até 1 concordância perfeita. Para todos os atributos observou-se um índice de concordância muito próximo de 1 (Tabela 6), evidenciando que há uma concordância forte entre os dados dos atributos de solo estimados pela rede com os dados dos atributos determinados pela análise laboratorial. Soares et al. (2015) observaram para a produtividade de grãos milho, um índice de concordância de 1,0 entre os valores de produtividade de grãos estimados pelo modelo com os obtidos a campo. Gomes et al. (2014) observaram, para a cultura da soja, índice de concordância entre os valores de produção de matéria seca obtidos por modelo determinístico e os observados a campo, de 0,7435. Rodrigues (2012) observou, para a cultura do milho, que as estimativas das necessidades de nitrogênio obtidas por modelo determinístico, em geral, foram superiores às quantidades observadas desse nutriente nos tecidos da planta, obtendo elevado índice de concordância de 0,94 entre os valores simulados e observados.

A rede de Bittar (2016) foi estruturada independentemente do espaçamento utilizado entre os pontos amostrais. Porém, foi levado em consideração a localização do ponto amostral, ou seja, as coordenadas geográficas (x e y), com isso cada estimativa gerada pela RNA foi alocada a sua respectiva coordenada, facilitando a localização dos pontos na grade amostral que foi definida para a área em estudo.

O Teste-t de Student e o índice de concordância mostraram que entre as médias observadas e estimadas não há diferença significativa, se o objetivo do uso da RNA for apenas para obter um valor médio de cada atributo de solo para a área estudada, a rede apresenta eficiência. Contudo, se o objetivo do uso da RNA for obter valores para cada um dos pontos

amostrais para uso na análise geoestatística, a rede não apresenta eficiência segundo os critérios de Camargo e Sentelhas (1997), indicando assim que a mesma precisa ser aprimorada considerando que, a principal importância da RNA está associada à capacidade de aprender por meio da experiência e armazenar o conhecimento adquirido.

Para aprimoramento do desenvolvimento e treinamento da RNA sugere-se levar em consideração: a distância entre os pontos amostrais, o limite espacial para estimação dos pontos amostrais, incorporar na estrutura da RNA a definição de ambientes não superiores a 10 ha e definir estimativas mais específicas, como por exemplo: desenvolver uma RNA para estimar fertilidade do solo, necessidade de calcário ou necessidade de P e K. Os pontos sugeridos para seu aprimoramento podem ter influência na eficiência das estimativas, uma vez que não foi possível definir nesse trabalho quais foram as variáveis de entrada mais importantes no processo de aprendizagem da rede.

4. CONCLUSÕES

O uso da RNA mostrou-se como um rápido e econômico método de fornecer informações indicativas sobre as características do solo, a partir de um número reduzido de amostras de solo.

Todos os atributos estimados pela RNA apresentaram um erro médio relativo baixo quando comparados aos valores determinados pela análise de solo e com os valores estimados pela krigagem ordinária.

A RNA adquiriu o conhecimento necessário para estimar valores médios dos atributos de solo com eficiência.

As estimativas pontuais obtidas pela RNA, considerando a grade de amostragem para a área estudada, visando aplicação em estudos de variabilidade espacial, apresentaram baixa eficiência indicando a necessidade de aprimoramento da RNA.

Para o aprimoramento da RNA sugere-se levar em consideração a possibilidade de inserir em sua estrutura, novas variáveis de entrada considerando que, as principais características que fundamentam sua ampla aplicabilidade é a habilidade de aprender a partir de dados de entrada.

5. REFERÊNCIAS BIBLIOGRÁFICAS

AITKENHEAD, M.J.; COULL, M.C.; TOWERS, W.; HUDSON, G.; BLACK, H.I.J. Predicting soil chemical composition and other soil parameters from field observations using a neural network. **Computers and Electronics in Agriculture**, Oxford, v.82, s/n, p.108–116, 2012.

ALVES, S.M.F.; QUEIROZ, D.M.; ALCÂNTARA, G.R.; REIS, E.F. Variabilidade espacial de atributos físico-químicos do solo usando técnicas de análise de componentes principais e geoestatística. **Bioscience Journal**, Uberlândia, v.30, n.3, p.22-30, 2014.

ARAÚJO, E.A.; KER, J.C.; NEVES, J.C.L.; LANI, J.L. Qualidade do solo: conceitos, indicadores e avaliação. **Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias**, Guarapuava-PR, v.5, n.1, p.187-196, 2012.

BITTAR, R.D. **Redes neurais artificiais aplicadas à modelagem da variabilidade espacial de atributos físico-químicos de solos do cerrado**. 2016. 112p. (Mestrado em Engenharia Agrícola) – Universidade Estadual de Goiás, Anápolis.

BRAGA, A.P.; CARVALHO, A.P.L.F.; LUDERMIR, T.B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2. ed. Rio de Janeiro: Ed. LTC, 2011. 226p.

CAMARGO, A.P.; SENTELHAS, P.C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, v.5, n.1, p.89-97, 1997.

CHERUBIN, M.R.; SANTI, A.L.; BASSO, C.J.; EITELWEIN, M.T.; VIAN, A.L. Caracterização e estratégias de manejo da variabilidade espacial dos atributos químicos do solo utilizando a análise dos componentes principais. **Enciclopédia Biosfera**, Goiânia, v.7, n.13, p.196-210, 2011.

CHERUBIN, M.R.; SANTI, A.L.; EITELWEIN, M.T.; MENEGOL, D.R.; ROS, C.O.; PIAS, O.H.C.; BERGHETTI, J. Eficiência de malhas amostrais utilizadas na caracterização da variabilidade espacial de fósforo e potássio. **Ciência Rural**, Santa Maria, v.44, n.3, p.425-432, 2014.

COMISSÃO DE FERTILIDADE DE SOLOS DE GOIÁS. **Recomendações de corretivos e fertilizantes para Goiás: 5ª aproximação**. Goiânia, UFG/EMGOPA, (Informativo Técnico 1), 1988. 101p.

DALCHIAVON, F.C.; CARVALHO, M.P.; ANDREOTTI, M.; MONTANARI, R. Variabilidade espacial de atributos da fertilidade de um Latossolo Vermelho Distroférico sob Sistema Plantio Direto. **Revista Ciência Agronômica**, Fortaleza, v.43, n.3, p.453-461, 2012.

DIAS, M.J.; ALVES, S.M.F.; REIS, E.F.; OLIVEIRA, D.G. Probabilidade de ocorrência dos atributos químicos em um latossolo sob plantio direto. **Revista Caatinga**, Mossoró, v.28, n.4, p.181-189, 2015.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. ARRUDA, M.R.; MOREIRA, A.; PEREIRA, J.C.R. **Amostragem e cuidados na coleta de solo para fins de fertilidade**. Manaus: Embrapa Amazônia Ocidental, 2014. 18p.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. **Sistema Brasileiro de Classificação de Solos**. 3. ed. rev. e ampl. Humberto Gonçalves dos Santos et al. Brasília DF, 2013. 353p.

GOMES, A.C.S.; ROBAINA, A.D.; PEITER, M.X.; SOARES, F.C.; PARIZI, A.R.C. Modelo para estimativa da produtividade para a cultura da soja. **Revista Ciência Rural**, Santa Maria, v.44, n.1, p.43-49, 2014.

GONÇALVES, A.C.A.; FOLEGATTI, M.V.; MATA, J.D.V. Análise exploratória e geostatística da variabilidade de propriedades físicas de um Argissolo Vermelho. **Acta Scientiarum**, Maringá, v.23, n.5, p.1149-1157, 2001.

HAYKIN, S. **Redes neurais: princípios e práticas**. 2. ed. Porto Alegre: Ed. Bookman, 2001. 900p.

ISAAKS, E.H.; SRIVASTAVA, M. **An introduction to applied geostatistics**. New York: Oxford University Press, 1989. 560p.

JANA, R.B.; MOHANTY, B.P.; SPRINGER, E.P. Multiscale bayesian neural networks for soil water content estimation. **Water Resources Research**, Washington, v.44, n. 8, p.1-16, 2008.

JANA, R.B.; MOHANTY, B.P. Enhancing PTFs with remotely sensed data for multi-scale soil water retention estimation. **Journal of Hydrology**, v.399, n.3, p.201-211, 2011.

JANA, R.B.; MOHANTY, B.P.A. Comparative study of multiple approaches to soil hydraulic parameter scaling applied at the hillslope scale. **Water Resources Research**, Washington, v.48, n.2, p.1-16, 2012.

JANA, R.B.; MOHANTY, B.P.; SHENG, Z. Upscaling soil hydraulic parameters in the Picacho Mountain region using Bayesian Neural Networks. **Transactions of the ASABE**, St Joseph, v.55, n.2, p.463-473, 2012.

KRAVCHENKO, A.N. Influence of spatial structure on accuracy of interpolation methods. **Soil Science Society of American Journal**, Madison, v.67, p.1564-1571, 2003.

LANDIM, P.M.B. Sobre Geoestatística e mapas. **Terrae Didactica**, Campinas, v.2, n.1, p.19-33, 2006.

LEAL, A.J.F.; MIGUEL, E.P.; BAIO, F.H.R.; NEVES, D.C.; LEAL, U.A.S. Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo. **Bragantia**, Campinas, v.74, n.4, p.436-444, 2015.

NAGAOKA, M.E; SILVA, I.N; LANÇAS K.P. Um método para estimar densidade de solo utilizando redes neurais artificiais. **Energia na Agricultura**, Botucatu, v.20, n.4, p.53-68, 2005.

PEETS, S.; MOUAZEN, A.M.; BLACKBURN, K.; BOYAN, K.; WIEBENSOHN, J. Methods and procedures for automatic collection and management of data acquired from on-the-go sensors with application to on-the-go soil sensors. **Computers and Electronics in Agriculture**, Oxford, v.81, p.104-112, 2012.

PELLISSARI, A.L.; CALDEIRA, S.F.; SANTOS, V.S. Variabilidade espacial dos atributos químicos do solo em povoamento de *Tectona grandis*. **Cerne**, Lavras, v.20, n.3, p.377-384, 2014.

PINHEIRO, R. Agricultura de Precisão: estudos de uma tecnologia favorável, na suscitação de melhoras na qualidade de técnicas empregadas no campo por José Paulo Molin. **Revista Eletrônica Competências Digitais para Agricultura Familiar**, Tupã, v.2, n.1, p.53-71, 2016.

REIS, J. D. S. **Determinação de zonas de manejo para adubação nitrogenada em lavoura de tomate industrial**. 2011. 67p. (Mestrado em Engenharia Agrícola) - Universidade Estadual de Goiás, Anápolis.

RIBEIRO, A.C.; GUIMARÃES, P.T.G.; ALVAREZ, V.H. (ed.). **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais, 5ª aproximação**. Viçosa, MG: Comissão de Fertilidade do Solo do Estado de Minas Gerais, 1999. 359p.

RIBEIRO JUNIOR, P.P.; DIGGLE, P.P. GeoR: a package for geostatistical analysis. **R News**, Rochester, v.1/2, n.2, p.15-18, 2001.

RODRIGUES, M.S. **Modelo determinístico para estimação da adubação nitrogenada na cultura do milho para grãos e silagem**. 2012. 98p. (Mestrado em Agronomia) - Universidade Tecnológica Federal do Paraná, Pato Branco.

ROSA, M.G.; KLAUBERG FILHO, O.; BARTZ, M.L.C.; MAFRA, A.L.; SOUSA, J.P.F.A.; BARETTA, D. Macrofauna edáfica e atributos físicos e químicos em sistemas de uso do solo no planalto catarinense. **Revista Brasileira de Ciência do Solo**, Viçosa, v.39, n.6, p.1544-1553, 2015.

RUSSEL, S.; NORVIG, P. **Inteligência Artificial**. 3. ed. Rio de Janeiro: Ed. Campus, 2013. 1016p.

SANCHES, G.M.; MAGALHÃES, P.S.G.; FRANCO, H.C.J. Agricultura de Precisão: uma realidade para a cana-de-açúcar? **Revista Canavieiros**, São Paulo, n.130, p.46-48, 2017.

SANCHEZ, R.B.; MARQUES JÚNIOR, J.; SOUZA, Z.M.; 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.

SANTI, A.L.; AMADO, T.J.C.; CHERUBIN, M.R.; MARTIN, T.N.; PIRES, J.L.; FLORA, L.P.D.; BASSO, C.J. Análise de componentes principais de atributos químicos e físicos do solo limitantes à produtividade de grãos. **Pesquisa agropecuária brasileira**, Brasília, v.47, n.9, p.1346-1357, 2012.

SCHNEIDER, P.R. **Análise de regressão aplicada à Engenharia Florestal**. 2. Ed. Santa Maria. UFSM/CEPEF, 1998. 236p.

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.

SILVA, E.N.S.; MONTANARI, R.; PANOSSO, A.R., CORREA, A.R.; TOMAZ, P.K.; FERRAUDO, A.S. Variabilidade de atributos físicos e químicos do solo e produção de feijoeiro cultivado em sistema de cultivo mínimo com irrigação. **Revista Brasileira de Ciência do Solo**, Viçosa, v.39, n.2, p.598-607, 2015.

SILVA, I.N.; SPATTI, D.H.; FLAUZINO, R.A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. 1. ed. São Paulo: Ed. Artliber, 2010. 399p.

SILVA, J.; GUEDES, I.M.R.; LIMA, C.E.P. **Adubação e nutrição**. IN: CLEMENTE, F.M.V.T.; BOITEUX, L (Eds.). Produção de Tomate para processamento industrial. Brasília DF: Embrapa, 2012. cap. 5, p. 105-127.

SOARES, F.C.; ROBAINA, A.D.; PEITER, M.X.; RUSSI, J.L; VIVAN, G.A. Redes neurais artificiais na estimativa da retenção de água do solo. **Ciência Rural**, Santa Maria, v.44, n.2, p.293-300, 2014.

SOARES, F.C.; ROBAINA, A.D.; PEITER, M.X.; RUSSI, J.L. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, Santa Maria, v.45, n.11, p.1987-1993, 2015.

SOUZA, Z.M.; SOUZA, G.S.; MARQUES JÚNIOR, J.; PEREIRA, G.T. Número de amostras na análise geoestatística e na krigagem de mapas de atributos do solo. **Ciência Rural**, Santa Maria, v.44, n.2, p.261-268, 2014.

TUKEY, J.W. A survey of sampling from contaminated distribution. In: OLKIN, I. **Contributions to probability and statistics**. California: Stanford University Press, 1960. Chapter 39, p.448-485.

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.

WEBSTER, R.; OLIVER, M.A. **Geostatistics for environmental scientists**. 2. ed. Chichester: Ed. John Wiley e Sons, 2007. 330p.

WILLMONT, C.J. On the validation of models. **Physical Geography**, Palm Beach, v.2, n.2, p.184-194, 1981.

YAMAMOTO, J.K.; LANDIM, P.M.B. **Geoestatística: conceitos e aplicações**. 1. ed. São Paulo: Ed. Oficina de Textos, 2013. 215p.

CAPÍTULO 2

ÍNDICE DE ACURÁCIA DE MAPAS DE VARIABILIDADE ESPACIAL DE FERTILIDADE DO SOLO ORIUNDOS DE DADOS ESTIMADOS POR UMA REDE NEURAL ARTIFICIAL

1. INTRODUÇÃO

As propriedades físicas e químicas do solo são características importantes, para definir o manejo da fertilidade do solo levando à tomada de decisões para aperfeiçoar a aplicação de fertilizantes e corretivos. Ainda se usa muito da técnica de aplicação de fertilizantes baseada em valores médios dos nutrientes do solo por área e essa quantidade de adubo pode ser superestimada, sendo que para isso é importante estabelecer práticas de manejo do solo que visem à produção agrícola e diminuam possíveis danos ambientais (SOUZA et al., 2010).

A correção dessas características do solo, que limitam o desenvolvimento das plantas, assim como o fornecimento adequado de nutrientes, são de grande importância para todas as culturas, mas principalmente para o tomateiro é considerado uma das hortaliças mais exigentes em nutrientes, sendo que os teores e acúmulos de nutrientes pela cultura variam, principalmente de acordo com o estágio de desenvolvimento da planta, com a cultivar e a produção que se deseja obter, sendo dessa forma importante o conhecimento dos atributos de solo para elaborar um programa de adubação (BASTOS et al., 2013).

A produtividade do tomateiro para processamento industrial em algumas regiões do Estado de Goiás tem atingido de 110 a 140 t ha⁻¹. Para alcançar altas produtividades a planta demanda, entre outros fatores, de uma grande quantidade de nutrientes que não são fornecidos totalmente pela maioria dos solos. Tornando-se necessário conhecer e controlar fatores que afetam o desenvolvimento do tomateiro, como os vários atributos de solo, da planta e dos sistemas de manejo. A restituição dos elementos químicos do solo é realizada por meio do uso de corretivos e fertilizantes por isso a importância de determinar a quantidade de nutrientes no solo, bem como os sintomas de deficiência nutricional na planta (SILVA et al., 2012).

Com o surgimento da agricultura de precisão (AP) tornou-se possível realizar a operação de aplicação de corretivos e fertilizantes de forma localizada (BERNARDI et al., 2015). Pois é na AP que são aplicados os princípios da geoestatística que tem por objetivo caracterizar a

variabilidade espacial dos atributos do solo e das culturas e estimar as inter-relações desses atributos no espaço e no tempo (GREGO et al., 2014). Outra possibilidade para tratar de dados quantitativos é através da aplicação da lógica fuzzy, utilizada em problemas de classificação, em que vetores de entrada são combinados por regras e atribuídos a um dos conjuntos de classes de saída especificado (BRESSAN et al., 2006).

De acordo com Meirelles et al. (2007), por meio da geração de um mapa de fertilidade fuzzy pode ser observada a variação gradual dos níveis de fertilidade do solo de uma determinada região, representando assim fronteiras não rígidas entre áreas férteis e não férteis, reduzindo a propagação de erros nos modelos lógicos, proporcionando resultados mais confiáveis, se comparados à utilização da classificação booleana.

Levando em consideração a importância das propriedades físicas e químicas do solo, pesquisadores têm buscado também propor soluções tecnológicas para prever os atributos do solo e o mapeamento dos mesmos, de forma prática e econômica. Alguns métodos de mapeamento digital de solos já estão sendo utilizados, como regressões logísticas múltiplas (GIASSON et al., 2006), modelos logísticos com aplicação de componentes principais (CATEN et al., 2011), redes neurais artificiais (SIRTOLI, 2013), por meio de equações matemáticas, de classes e propriedades de solos (SANCHEZ et al., 2009).

Ao trabalhar com mapas de dados preditos dos atributos do solo é preciso avaliar a precisão dos mesmos, a maneira mais comum para expressar a precisão, tanto de imagens quanto de mapas, está na declaração da porcentagem da área do mapa que foi corretamente classificada quando comparada com dados de referência, denominada Exatidão Global. Neste contexto, é necessário realizar algum procedimento estatístico, no produto da classificação dos mapas, para determinar a acurácia ou exatidão desta classificação (BERNARDES, 2006). A classificação correta gerada pela amostragem dos dados classificados é expressa na forma de matriz de erro, denominada de matriz de confusão.

Objetivou-se com este trabalho, analisar utilizando o sistema de classificação fuzzy a fertilidade de uma área cultivada com tomate industrial. Verificar o índice de acurácia de mapas de fertilidade do solo obtidos na análise geoestatística a partir de dados estimados por uma rede neural artificial.

2. MATERIAL E MÉTODOS

2.1. Caracterização e localização da área experimental

Os dados utilizados para o desenvolvimento deste trabalho foram oriundos de um estudo realizado na Fazenda Palmital localizada no município de Morrinhos, GO ($17^{\circ}45'20''$ S de latitude e $49^{\circ}10'34''$ W de longitude), altitude de 813 m (REIS, 2011), em uma área irrigada por pivô central (Figura 1a). Os dados foram coletados em um talhão de 23 ha (Figura 1b).




FIGURA 1 - (a) Pivô central; (b) Área experimental.

2.2. Mapeamento da área e georreferenciamento dos pontos amostrais

Os dados foram coletados em uma área de 23 hectares em uma grade amostral de 50x50 m, totalizando 120 pontos amostrais. Cada ponto foi georreferenciado utilizando aparelho de Sistema de Posicionamento Global - GPS, marca Garmin modelo Etrex Legend RoHs (erro ± 3 m), com sistema de correção diferencial em tempo real via satélite e com coordenadas em sistema UTM (Universal Transversa de Mercator).

2.3. Atributos físicos e químicos do solo

2.3.1. Determinação dos atributos pela análise de solo

Em cada ponto da grade amostral georreferenciada, foram coletadas amostras deformadas de solo (composta por 5 subamostras) na camada de 0,00 a 0,20 m, com um trado de rosca, coletadas em um raio de um metro, em torno de cada ponto da grade amostral.

Em seguida as amostras foram embaladas, identificadas e encaminhadas para laboratório de Análise de Solos Certificado, com aproximadamente 300 g de amostra de solo de cada ponto amostral, para a determinação dos atributos químicos do solo: (pH), cálcio (Ca), magnésio (Mg), cálcio + magnésio (Ca+Mg), alumínio trocável (Al), acidez potencial (H+Al), potássio (K), fósforo (P), saturação por alumínio (m%), matéria orgânica (MO), capacidade de troca catiônica

(CTC) e saturação por bases (V%). E físicos para a quantificação da composição granulométrica do solo (areia, silte e argila).

2.3.2. Estimativas dos atributos do solo por meio da Rede Neural Artificial (RNA)

Dos dados determinados pela análise de solo foram selecionados 4 pontos amostrais conhecidos para aplicação na RNA desenvolvida por Bittar (2016), para obtenção das estimativas dos atributos de solo estudados nos 120 pontos amostrais, como descrito no Capítulo 1.

Para verificar a precisão dos dados estimados pela RNA, todas as seguintes análises foram realizadas com 2 conjuntos de dados sendo eles: os dados determinados na análise de solo e os dados estimados pela RNA.

2.4. Fertilidade do solo utilizando lógica fuzzy

A classificação contínua dos dados dos atributos químicos P, K, Ca, Mg e MO foi realizada utilizando a lógica fuzzy, para os dados determinados pela análise de solo e os dados estimados pela RNA. Os limites dos graus de pertinência para cada atributo foram definidos de acordo com cada classe de fertilidade (Tabela 1).

Para estimar a fertilidade do solo foi utilizada a metodologia de acordo com Bönisch et al. (2004), com o uso da função linear descrita a seguir:

$$\begin{aligned} MF_A(Z) &= 0 && \text{se } z < p \\ MF_A(Z) &= (1/\alpha)/(z-p) && \text{se } p < z < q \\ MF_A(Z) &= 1 && \text{se } z = q \end{aligned}$$

Em que:

MF_A = é o grau de pertinência com que o elemento Z pertence ao conjunto fuzzy, $\alpha = q-p$;

p, q e r = valores dos limites de classe de dois conjuntos fuzzy pertencentes a um conjunto A.

Os valores dos parâmetros p, q e r foram definidos em função dos valores dos limites dos intervalos dos atributos químicos (Tabela 1), que foram relacionados com uma fertilidade baixa (p e r) e com uma fertilidade boa (q), que correspondem as classes de fertilidade do solo boa, intermediária e baixa, respectivamente.

TABELA 1 - Critério para definição de fertilidade do solo para hortaliças.

| Atributo | Classe de fertilidade | | |
|--|-----------------------|-----------|-------|
| | Baixo | Médio | Alto |
| P (mg dm ⁻³) | <10,0 | 10,0-30,0 | >30,0 |
| K (cmol _c dm ⁻³) | <0,10 | 0,10-0,31 | >0,31 |
| Ca (cmol _c dm ⁻³) | <2,0 | 2,0-5,0 | >5,0 |
| Mg (cmol _c dm ⁻³) | <0,5 | 0,5-1,2 | >1,2 |
| MO (g kg ⁻¹) | <20,0 | 20,0-50,0 | >50,0 |

P - fósforo; K - potássio; Ca - cálcio; Mg - Magnésio; MO - matéria orgânica.

Fonte: Comissão de Fertilidade de Solos de Goiás (1988)

2.5. Recomendação de corretivos e fertilizantes

Foi estimada a necessidade de adubação para o tomateiro industrial utilizando os critérios de acordo com a Tabela 2, para os dois conjuntos de dados (análise de solo e RNA).

TABELA 2 - Recomendação de adubação para o tomate industrial no cerrado.

| Nutrientes | Resultado da análise | Recomendação |
|------------|----------------------|---------------------|
| | mg dm ⁻³ | kg ha ⁻¹ |
| P | <10 | 600 |
| | 10-20 | 500 |
| | 21-30 | 400 |
| | >30 | 300 |
| K | <30 | 250 |
| | 30-60 | 200 |
| | 61-100 | 150 |
| | >100 | 50 |

P - fósforo; K - potássio.

Fonte: Silva et al. (2012)

Para estimar a necessidade de calcário foi utilizado o método que fundamenta-se na relação existente entre o pH e a saturação por bases, conforme Equação 1 (SILVA et al., 2012). Tanto para os dados determinados na análise de solo e os dados estimados pela RNA.

$$NC = \frac{T \cdot (V_2 - V_1)}{100} \quad (1)$$

Em que:

NC = necessidade de calcário, em t ha⁻¹;

T = capacidade de troca catiônica a pH 7,0, em cmol_c dm⁻³;

V₂ = porcentagem de saturação por bases recomendada para tomateiro (70%);

V₁ = saturação por bases atual do solo, em %.

2.6. Estatística descritiva para os dados de fertilidade do solo, recomendação de corretivos e fertilizantes

Os dados estimados para a fertilidade do solo, necessidade de calagem (NC), necessidade de fósforo (NP) e necessidade de potássio (NK), obtidos por meio dos dados determinados na análise de solo e dados estimados pela RNA foram submetidos à estatística descritiva por meio da análise exploratória dos dados, permitindo conhecer e visualizar a tendência, medidas de dispersão e distribuição dos mesmos.

Foram calculadas as medidas descritivas: média, mediana, variância, desvio-padrão, assimetria, curtose e coeficiente de variação para cada variável em estudo. Para verificação da normalidade dos dados com ($p\text{-value} < 0,05$) foi realizado o teste proposto por Shapiro e Wilk (1965). Já a identificação de “*Outliers*”, foi por meio de interpretação gráfica (*Box plot*) e o critério de Tukey (1960). Foram utilizados para a realização das análises estatísticas, planilhas eletrônicas e o software R.

2.7. Análise geoestatística para os dados de fertilidade do solo, recomendação de corretivos e fertilizantes

A análise geoestatística foi realizada no software GS⁺® versão 7.0, (*Geostatistics for the Environmental Sciences*), para verificar a existência e quantificar o grau de dependência espacial dos dados de fertilidade do solo, necessidade de calagem (NC), necessidade de fósforo (NP) e necessidade de potássio (NK), dos dados determinados pela análise de solo e os dados estimados pela RNA, o que foi feito a partir do ajuste de funções teóricas aos modelos com patamar de semivariogramas experimentais: Linear, Esférico, Exponencial e Gaussiano.

Para análise do grau de dependência espacial foi calculado o avaliador de dependência espacial (ADE), o qual foi classificado de acordo com a proposta de Dalchiavon et al. (2012): a dependência espacial fraca para valores $\leq 25\%$; entre 25% e 75% moderada e $\geq 75\%$ dependência forte, como apresentado na Equação 2:

$$ADE = \frac{C}{C + C_0} \times 100 \quad (2)$$

Em que:

ADE = Avaliador de dependência espacial;

C = Variância estrutural;

C₀ = Efeito pepita;

(C + C₀) = Patamar.

O melhor modelo foi escolhido por meio do maior coeficiente de determinação (R^2), a menor soma dos quadrados dos resíduos (SQR) e o maior grau de dependência espacial. Após definição dos modelos e parâmetros dos semivariogramas e comprovada a dependência espacial foi utilizado o método de interpolação por meio da técnica denominada krigagem ordinária, para confecção dos mapas de isolinhas (dados determinados na análise de solo e os dados estimados pela RNA), nos quais foram geradas estimativas de valores em pontos não amostrados a partir de pontos amostrados. Os mapas de isolinhas para os atributos de solo foram elaborados no software Surfer[®]13 para o detalhamento espacial, permitindo visualizar a variabilidade espacial.

2.8. Acurácia temática dos mapas

Com a intenção de verificar a acurácia dos mapas elaborados por meio da técnica de krigagem ordinária foram calculados os índices de acurácia Kappa e Exatidão Global.

2.8.1. Matriz de confusão (ou matriz de erro)

O método padrão para avaliação da acurácia temática dos mapas são os índices derivados da matriz de confusão. A matriz de confusão fornece a base para descrever a acurácia da classificação e caracterizar os erros, ajudando a refinar a classificação. Na Tabela 3, tem-se a representação de uma matriz de confusão formada por um arranjo de números dispostos em linhas e colunas. Os elementos da diagonal principal (em negrito) indicam o nível de acerto, ou concordância, entre os dois conjuntos de dados.

TABELA 3 - Modelo da matriz de confusão utilizada para o cálculo da acurácia temática.

| | | Classes | 1 | 2 | c | Soma das linhas |
|------------------------|---|---------|-----------------------|-----------------------|-----------------------|-----------------|
| Dados classificados | 1 | | X₁₁ | X ₁₂ | X _{1c} | X ₊₁ |
| | 2 | | X ₂₁ | X₂₂ | X _{2c} | X ₊₂ |
| | c | | X ₃₁ | X ₃₂ | X_{3c} | X _{+c} |
| Soma das colunas | | | X ₊₁ | X ₊₂ | X _{+c} | n |

Fonte: Adaptada de Bastiani et al. (2012)

2.8.1.1. Definição das classes da matriz de confusão

Os dois conjuntos de dados, compostos pelos 120 pontos amostrais para cada atributo de solo estudado foram submetidos, quando apresentaram dependência espacial, ao método de interpolação por meio da técnica denominada krigagem ordinária, com o objetivo de gerar estimativas de valores em pontos não amostrados a partir de pontos amostrados. Essas inúmeras estimativas geradas para cada atributo de solo determinados pela análise de solo e para os

estimados pela RNA foram divididas em 3 classes, compondo a matriz de confusão. Para a composição dessa matriz foi utilizado o critério de classificação apresentado na Tabela 4 (SILVA et al., 2012; Comissão de Fertilidade de Solos de Goiás, 1988).

TABELA 4 - Critério para definição das classes para compor a matriz de confusão.

| Atributo | Classe de fertilidade | | |
|--|-----------------------|------------------|-----------------|
| | Baixo (Classe 1) | Médio (Classe 2) | Alto (Classe 3) |
| pH (CaCl ₂) | <4,5 | 4,5-7,0 | >7,0 |
| Ca (cmol _c dm ⁻³) | <2,0 | 2,0-5,0 | >5,0 |
| Mg (cmol _c dm ⁻³) | <0,5 | 0,5-1,2 | >1,2 |
| Al (cmol _c dm ⁻³) | <0,5 | 0,5-1,0 | >1,0 |
| H+Al (cmol _c dm ⁻³) | <2,5 | 2,5-5,0 | >5,0 |
| CTC (cmol _c dm ⁻³) | <2,3 | 2,3-8,0 | >8,0 |
| P (mg dm ⁻³) | <10,0 | 10,0-30,0 | >30,0 |
| K (cmol _c dm ⁻³) | <0,10 | 0,10-0,31 | >0,31 |
| V% (%) | <20,0 | 20,0-60,0 | >60,0 |
| MO (g kg ⁻¹) | <20,0 | 20,0-50,0 | >50,0 |
| Fertilidade | <0,25 | 0,25-0,75 | >0,75 |

pH - potencial hidrogeniônico; Ca - cálcio; Mg - magnésio; H+Al - acidez potencial; CTC - capacidade de troca catiônica; P - fósforo; K - potássio; V% - saturação por bases; MO - matéria orgânica.

Fonte: Silva et al. (2012); Comissão de Fertilidade de Solos de Goiás (1988)

2.8.2. Exatidão Global

A exatidão global foi calculada dividindo a soma da diagonal principal da matriz de erros x_{ii} , pelo número total de amostras coletadas n , conforme Equação 3.

$$\text{Exatidão global} = \frac{\sum_{i=1}^k x_{ii}}{n} \quad (3)$$

Em que:

x_{ii} = valor na linha i e coluna i da matriz de confusão;

n = número total de amostras.

2.8.3. Índice Kappa

O índice Kappa (K) é uma técnica multivariada usada na avaliação da acurácia temática e utiliza todos os elementos da matriz de confusão no seu cálculo, indicando o quanto a classificação está de acordo com os dados de referência (BASTIANI et al., 2012; FOODY, 2010; BAZZI et al., 2008). O cálculo do índice Kappa leva em consideração os valores da diagonal

principal corretamente classificados e os valores fora da diagonal que correspondem aos erros de classificação em relação aos dados reais e foi calculado por meio da Equação 4.

$$\text{Índice Kappa} = \frac{n \sum_{i=1}^k x_{ii} - \sum_{i=1}^k x_{i+} x_{+i}}{n^2 - \sum_{i=1}^k x_{i+} x_{+i}} \quad (4)$$

Em que:

x_{ii} = valor na linha i e coluna i da matriz de confusão;

x_{i+} = soma da linha i da matriz de confusão;

x_{+i} = soma da coluna i da matriz de confusão;

n = número total de amostras;

k = número total de classes.

O resultado do índice Kappa (K) foi classificado de acordo com Krippendorff (2004): baixa acurácia para valores $\leq 0,67$; entre 0,67 e 0,80 média acurácia e $\geq 0,80$ alta acurácia.

3. RESULTADOS E DISCUSSÃO

3.1. Rede neural artificial na predição dos atributos de solo

Dos 120 pontos amostrais coletados na área em estudo, foram selecionados aleatoriamente 4 pontos amostrais para aplicação na RNA para obtenção das estimativas dos atributos físicos e químicos do solo. Para a seleção dos pontos amostrais a área foi dividida em 4 glebas de 5,75 ha cada uma (Figura 2a) e foi selecionado aleatoriamente um ponto amostral correspondente para cada gleba, estimando a partir de 4 pontos amostrais 120 estimativas para cada atributo de solo em toda a área, conforme Figura 2b.




FIGURA 2 - (a) 4 pontos amostrais conhecidos selecionados; (b) 120 estimativas obtidas a partir de 4 pontos amostrais conhecidos.

3.2. Estatística descritiva para os dados de fertilidade do solo, recomendação de corretivos e fertilizantes

Os resultados das análises de fertilidade do solo estimada por meio de classificação fuzzy, recomendação de fertilizantes e corretivos do solo da área experimental para a cultura do tomate industrial, com os dados determinados pela análise de solo e os dados estimados pela RNA, estão apresentados na Tabela 5. Para o cálculo da necessidade de calcário foi utilizado o método de saturação por bases. O cálculo da necessidade de P e K foi realizado de acordo com o proposto por Silva et al. (2012).

De acordo com a classificação proposta por Warrick e Nielsen (1980), o coeficiente de variação para os dados de fertilidade do solo, necessidade de calagem (NC) e necessidade de fósforo (NP) foram baixos ($CV < 12\%$) e médio para necessidade de potássio (NK) ($12\% < CV < 60\%$). A fertilidade do solo, o atributo NC e NP apresentaram assimetria e curtose negativa e NK assimetria positiva forte, para os dados determinados na análise de solo, Tabela 5.

Já os dados estimados pela RNA, seguindo a classificação proposta por Warrick e Nielsen (1980), o valor de coeficiente de variação para os dados de fertilidade do solo, necessidade de calagem (NC), necessidade de fósforo (NP) e necessidade de potássio (NK) foram baixos ($CV <$

12%). Em exceção da fertilidade do solo, todos os demais atributos NC, NP e NK apresentaram assimetria positiva forte, Tabela 5.

TABELA 5 - Estatística descritiva da fertilidade, recomendação de corretivos e fertilizantes do solo.

| Atributos | Origem dos dados | | Média | MD | Var | DP | Ass | Cur | CV (%) | P-Value |
|-------------|------------------|-----|--------|--------|---------|-------|-------|--------|--------|---------|
| | An. solo | RNA | | | | | | | | |
| Fertilidade | An. solo | | 0,72 | 0,73 | 0,00 | 0,06 | -0,15 | -1,30 | 8,90 | 0,0001 |
| | RNA | | 0,74 | 0,74 | 0,00 | 0,04 | 0,21 | -0,88 | 5,55 | 0,0090 |
| NC | An. solo | | -0,64 | -0,58 | 0,27 | 0,52 | -0,14 | -0,40 | -80,70 | 0,4423 |
| | RNA | | -0,56 | -0,60 | 0,03 | 0,17 | 2,88 | 6,82 | -30,76 | 0,0000 |
| NP | An. solo | | 557,69 | 600,00 | 2658,70 | 51,56 | -0,53 | -1,23 | 9,25 | 0,0000 |
| | RNA | | 505,00 | 500,00 | 478,99 | 21,89 | 4,18 | 15,75 | 4,33 | 0,0000 |
| NK | An. solo | | 50,96 | 50,00 | 96,15 | 9,81 | 10,20 | 104,00 | 19,24 | 0,0000 |
| | RNA | | 50,00 | 50,00 | 0,00 | 0,00 | 10,82 | 115,01 | 0,002 | 0,0000 |

NC - necessidade de calcário ($t\ ha^{-1}$); NP - necessidade de fósforo ($kg\ ha^{-1}$); NK - necessidade de potássio ($kg\ ha^{-1}$); MD - mediana; Var - variância; DP - desvio padrão; Ass – coeficiente de assimetria; Cur - curtose; CV(%) - coeficiente de variação; P-value - teste de normalidade de Shapiro Wilk a 5%; An. solo - Análise de solo; RNA - Rede neural artificial.

3.3. Análise geoestatística para os dados de fertilidade do solo, recomendação de corretivos e fertilizantes

Os modelos teóricos de semivariograma ajustados para os atributos de fertilidade, NC, NP e NK estão apresentados na Tabela 6. Os dados que apresentaram distribuição assimétrica positiva (Tabela 5) foram transformados para evitar a influência de valores altos nas estimativas de pontos da vizinhança (YAMAMOTO e LANDIM, 2013).

Em exceção do atributo NK, os demais atributos apresentaram dependência espacial (Tabela 6), sendo possível elaborar os mapas de isolinhas (Figura 3). O atributo NK apresentou efeito pepita representando que o componente da variabilidade espacial não pode ser relacionado com uma causa específica (variabilidade ao acaso), o que pode estar relacionado ao número de dados utilizados ou o espaçamento entre os pontos que não foi suficiente para descrever a variabilidade espacial do atributo considerado. Neste caso a restituição do fertilizante potássico no solo será realizado por meio da média, sendo o elemento extraído em maior quantidade pelo tomateiro participando de processos importantes no interior da planta, como a fixação do fruto à planta evitando a sua queda (SILVA et., 2012).

TABELA 6 - Modelos teóricos de semivariograma ajustados para os atributos de fertilidade, recomendação de corretivos e fertilizantes do solo.

| Atributos | Origem dos dados | Semivariograma | A | C ₀ | C ₀ +C | SQR | R ² | ADE | GD |
|-------------|------------------|----------------|--------|----------------|-------------------|------|----------------|--------|----------|
| Fertilidade | An. solo | Exponencial | 111,90 | 0,00 | 0,00 | 0,00 | 0,85 | 90,70 | Forte |
| | RNA | Gaussiano | 222,57 | 0,00 | 0,00 | 0,00 | 0,95 | 100,00 | Forte |
| NC | An. solo | Exponencial | 82,80 | 0,04 | 0,28 | 0,00 | 0,50 | 86,40 | Forte |
| | RNA | Esférico | 152,80 | 0,00 | 0,13 | 0,00 | 0,93 | 99,20 | Forte |
| NP | An. solo | Exponencial | 94,20 | 0,00 | 0,01 | 0,00 | 0,86 | 93,40 | Forte |
| | RNA | Gaussiano | 338,96 | 0,00 | 0,00 | 0,00 | 0,96 | 67,60 | Moderado |
| NK | An. solo | EPP | - | - | - | - | - | - | - |
| | RNA | EPP | - | - | - | - | - | - | - |

A - alcance; C₀ - Efeito Pepita; C₀+C - Patamar; SQR - soma de quadrado do resíduo; R² - coeficiente de determinação; ADE - Avaliador de Dependência Espacial (%); GD - grau de dependência; NC - necessidade de calcário (t ha⁻¹); NP - necessidade de fósforo (kg ha⁻¹); NK - necessidade de potássio (kg ha⁻¹); EPP - Efeito peita puro; An. solo - Análise de solo; RNA - Rede neural artificial.

3.4. Mapas de fertilidade do solo, recomendação de corretivo e fertilizante

Visando aperfeiçoar as práticas culturais na produção do tomate industrial, levando em consideração as informações do solo em cada ponto da grade amostral (LIMA et al., 2014; ZONTA et al., 2014; CARNEIRO et al., 2016), foram elaborados os mapas de isolinhas da variabilidade espacial da fertilidade, recomendação de corretivo e fertilizante do solo com os dados determinados pela análise de solo e os dados estimados pela RNA, Figura 3.

Observa-se no mapa de fertilidade do solo (Figura 3a e 3b) para a cultura do tomateiro industrial que a fertilidade variou de mediana (0,60) à forte (0,85) indicando que o solo em estudo tem uma boa fertilidade. A fertilidade do solo representa o estoque de nutrientes nele contido, determinando a necessidade ou não de adição de produtos químicos, incorporando os principais elementos necessários ao desenvolvimento das plantas. Um solo fértil é aquele que contém, em quantidades suficientes e balanceadas, todas as propriedades físicas e químicas que atendam a demanda das culturas (ZHU et al., 2018).

Pelos mapas de recomendação de calagem (Figura 3c e 3d), observou-se que não há necessidade de fazer a correção do solo isso ocorreu, pois, a saturação de bases recomendada para a cultura de tomate é de 70% e em média a V% desse solo em estudo foi de 76,85%. Outro atributo que tem uma relação direta com a necessidade de calagem é o pH indicando as condições que se encontra o solo, quanto a disponibilidade de nutrientes às plantas (SANA et al., 2014). O tomateiro geralmente tem um desenvolvimento e uma produtividade melhor quando o pH do solo se encontra na faixa entre 5,5 e 6,5 sendo o caso deste estudo, nesta faixa de pH estão mais

disponíveis para as plantas os macronutrientes fósforo, potássio, cálcio e magnésio (SILVA et al., 2012).

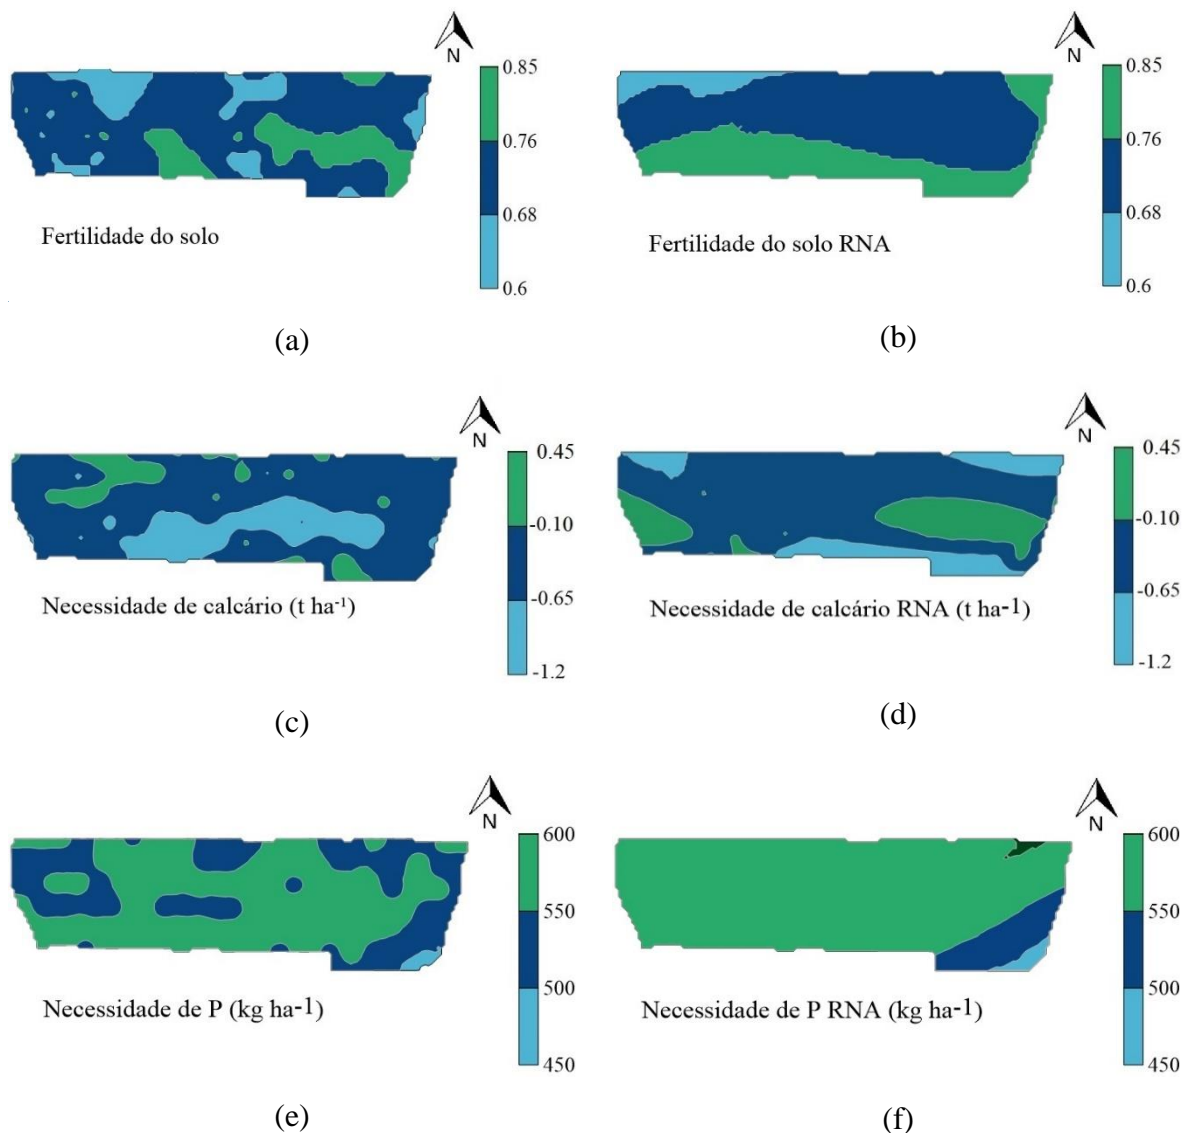


FIGURA 3 - Mapas de isolinhas da (a) fertilidade do solo, (b) fertilidade do solo RNA, (c) necessidade de calcário, (d) necessidade de calcário RNA, (e) necessidade de fósforo e (f) necessidade de fósforo RNA.

Quando é necessário que seja realizada a correção da acidez do solo, essa correção é realizada pela calagem no intuito de corrigir o pH do solo, reduzir a atividade do Al trocável, promover maior eficiência de absorção de água pela planta e atingir o suprimento de Ca e Mg para a máxima eficiência econômica do tomateiro (RHEINHEIMER et al., 2018; SILVA et al., 2012). A área experimental deste estudo apresentou teores de Mg e Ca classificados como médio, esses teores podem ter sido maiores em decorrência da aplicação do calcário no solo, conforme (PAULETTI et al., 2014).

São considerados fatores importantes, o conhecimento do estado nutricional do solo pela análise química, a textura do solo e o potencial de produção da cultivar a ser plantada, para a definição das quantidades de nutrientes a serem utilizados. Considerando os mapas recomendação de adubação fosfatada (Figura 3e e 3f) para o tomateiro industrial, observa-se que há zonas de manejo com maior e menor exigência de insumos. Caso o agricultor optar por aplicar os fertilizantes a taxa variada poderia haver maior homogeneidade da fertilidade do solo com um melhor controle na distribuição e economia com aquisição de insumos (CARNEIRO et al., 2016). O fósforo aplicado no solo de forma correta promove para a cultura do tomate industrial, a rápida formação e crescimento das raízes e melhora a qualidade dos frutos quanto a formação de sementes com boas características e aumento do peso do fruto (ZHU et al., 2018; GATTA et al., 2015)

Muitos erros são cometidos na adubação das culturas agrícolas, principalmente nas hortaliças por confundir uma cultura bem nutrida com uma cultura nutrida em excesso. O uso excessivo de fertilizantes, sem considerar a quantidade disponível no solo e a necessidade que a cultura precisa, tem se tornado um problema principalmente para a cultura do tomate, em todas as regiões do Brasil (SILVA et al., 2012). Por isso o estudo da distribuição espacial da fertilidade do solo, por meio dos mapas de isolinhas são partes fundamentais da agricultura de precisão, sendo utilizados com a finalidade de buscar uma adubação mais efetiva e econômica (BOTTEGA et al., 2013).

3.5. Acurácia temática dos mapas

Na Tabela 7, estão apresentados os resultados obtidos dos índices de acurácia de Kappa e Exatidão Global (EG), obtidos por meio da matriz de erros (Anexo D, Tabelas 1 a 15) para comparar os mapas de variabilidade espacial da fertilidade do solo obtidos na análise geostatística elaborados pelos dados determinados na análise de solo e os valores estimados pela RNA.

Os dois conjuntos de dados, compostos por 120 pontos amostrais para cada atributo de solo estudado quando submetidos ao método de interpolação por meio da técnica denominada krigagem ordinária geraram 4996 estimativas de valores em pontos não amostrados a partir de pontos amostrados. Essas 4996 estimativas para cada atributo de solo foram divididas em 3 classes, seguindo interpretação da disponibilidade de nutrientes presentes no solo compondo a matriz de confusão, a partir da qual foi efetuado o cálculo dos índices Kappa e Exatidão Global.

TABELA 7 - Resultados dos índices de acurácia Kappa e Exatidão Global.

| Atributo | Índice Kappa | Exatidão global |
|-------------|--------------|-----------------|
| pH | 0,0000 | 1,0000 |
| Ca | 0,0367 | 0,6455 |
| Mg | -0,0497 | 0,8769 |
| Ca+Mg | 0,1363 | 0,6221 |
| H+Al | 0,0000 | 1,0000 |
| CTC | 0,1236 | 0,5268 |
| P | 0,3201 | 0,6369 |
| V% | 0,0000 | 0,9972 |
| MO | 0,0000 | 0,9305 |
| Argila | 0,0000 | 0,7248 |
| Silte | -0,0099 | 0,2102 |
| Areia | 0,0000 | 0,4424 |
| Fertilidade | 0,0803 | 0,5162 |
| NC | 0,0128 | 0,4215 |
| NP | -0,0975 | 0,0657 |

pH - potencial hidrogeniônico (CaCl_2); Ca - cálcio ($\text{cmol}_c \text{dm}^{-3}$); Mg - magnésio ($\text{cmol}_c \text{dm}^{-3}$); Ca+Mg - ($\text{cmol}_c \text{dm}^{-3}$); H+Al - acidez potencial ($\text{cmol}_c \text{dm}^{-3}$); CTC - capacidade de troca catiônica ($\text{cmol}_c \text{dm}^{-3}$); P - fósforo (mg dm^{-3}); V% - saturação por bases (%); MO - matéria orgânica (g kg^{-1}); NC - necessidade de calagem (t ha^{-1}); NP - necessidade de fósforo (kg ha^{-1}).

Verificou-se que os mapas dos atributos químicos e físicos do solo (Anexo E, Figura 1), mapa de fertilidade, mapa de necessidade de calagem e mapa de necessidade de fósforo (Figura 3) foram classificados com baixa acurácia quanto ao índice Kappa segundo Krippendorff (2004) (Tabela 7), indicando pouca similaridade entre os mapas. O motivo pelo qual o índice Kappa apresentou baixa acurácia entre os mapas comparados pode estar relacionado ao fato, que a RNA não apresentou eficiência para estimar o valor de cada um dos pontos amostrais, conforme apresentado no Capítulo 1, para uso na análise geoestatística.

O índice de exatidão global é calculado pelo total de pontos corretamente classificados dividido pelo número total de pontos da validação. O valor calculado pode variar em um intervalo de 0 a 1, porém segundo Anderson et al. (2001) o nível mínimo de acurácia para sugerir uma boa classificação para a exatidão global é $\geq 0,85$. De acordo com esse índice proposto pode-se observar que os atributos pH, Mg, H+Al, V% e MO apresentaram acurácia de classificação superior a 0,85, Tabela 7. Gonçalves et al. (2016), estudando a classificação de estratos florestais utilizando redes neurais artificiais e dados de sensoriamento remoto, observaram que a rede neural apresentou um valor de acurácia global de 88%, indicando que a RNA foi considerada como um classificador muito bom.

4. CONCLUSÕES

A fertilidade da área experimental variou de mediana (0,60) à forte (0,85) indicando que o solo em estudo tem uma boa fertilidade para o cultivo do tomate industrial.

O uso da aplicação de fertilizantes a taxa variada pode contribuir para o processo de cultivo de tomate industrial de forma sustentável reduzindo o uso de insumos agrícolas.

A área experimental por ter apresentado áreas com maior e menor exigência de fertilizante fosfatado pode ser dividida em zonas de manejo facilitando a aplicação de forma variável.

Os índices de acurácia Kappa e Exatidão Global permitiram realizar a comparação entre os mapas de variabilidade espacial dos atributos de solo obtidos na análise geoestatística a partir de dados estimados por uma rede neural artificial.

O Índice de Kappa mostrou ausência de semelhança entre os mapas considerando as classes de interpretação de disponibilidade de nutrientes no solo, para os atributos estudados.

Para o aprimoramento da rede neural artificial devem ser realizados testes com distintas configurações de redes, de forma a conseguir maior correlação entre os dados determinados pela análise de solo e os dados estimados pela RNA, obtendo assim maiores acurácias nas estimativas das variáveis de interesse.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ANDERSON, J.F.; HARDY, E.E.; ROACH J.T.; WITMER R.E. **A land use and land cover classification system for use with remote sensor data**. Washington, Geologic Survey Professional Paper, 2001. 41p.
- BASTIANI, F.; URIBE-OPAZO, M.A.; DALPOSSO, G.H. Comparison of maps of spatial variability of soil resistance to penetration constructed with and without covariables using a spatial linear model. **Engenharia Agrícola**, Jaboticabal, v.32, n.2, p.394-404, 2012.
- BASTOS, A.R.R.; ALVARENGA, M.A.R.; CARVALHO, J.G.; PINHO, P.J. Nutrição mineral e adubação In: ALVARENGA, M.A.R. **Tomate: produção em campo, em casa de vegetação e hidroponia**. 2. ed. rev. e ampl. Ed. Universitária de Lavras, 2013. cap.5, p.63-130.
- BAZZI, C.L.; SOUSA, E.G.; URIBE-OPAZO, M.A.; NÓBREGA, L.H.P.; PINHEIRO, R. Influência da distância entre passadas de colhedora equipada com monitor de colheita na precisão dos mapas de produtividade na cultura do milho. **Engenharia Agrícola**, Botucatu, v.28, n.2, p.355-363, 2008.
- BERNARDES, T. **Caracterização do ambiente agrícola do Complexo Serra Negra por meio de sensoriamento remoto e sistemas de informação geográfica**. 2006. 119p. (Mestrado em Agronomia) - Universidade Federal de Lavras, Minas Gerais.
- BERNARDI, A.C.C.; BETTIOL, G.M.; GREGO, C.R.; ANDRADE, R.G.; RABELLO, L.M.; INAMASU, R.Y. Ferramentas de agricultura de precisão como auxílio ao manejo da fertilidade do solo. **Cadernos de Ciência e Tecnologia**, Brasília, v.32, n.1/2, p.205-221, 2015.
- BITTAR, R.D. **Redes neurais artificiais aplicadas à modelagem da variabilidade espacial de atributos físico-químicos de solos do cerrado**. 2016. 112p. (Mestrado em Engenharia Agrícola) – Universidade Estadual de Goiás, Anápolis.
- BÖNISCH, S.; LOPES ASSAD, M.L.; CÂMARA, G.; MONTEIRO, A.M.V. Representação e propagação de incertezas em dados de solos. **Revista Brasileira de Ciências do Solo**, Viçosa, n.1, v.28, p.21-32, 2004.
- BOTTEGA, E.L.; QUEIROZ, D.M.; PINTO, F.A.C.; SOUZA, C.M.A. Variabilidade espacial de atributos do solo em sistema de semeadura direta com rotação de culturas no cerrado brasileiro. **Revista Ciência Agronômica**, Fortaleza, v.44, n.1, p.1-9, 2013.
- BRESSAN, G.M.; KOENIGKAN, L.V.; OLIVEIRA, V.A.; CRUVINEL, P.E.; KARAM, D. Sistema de classificação fuzzy para risco de infestação por plantas daninhas considerando a sua variabilidade espacial. **Planta Daninha**, Viçosa, v.24, n.2, p.229-238, 2006.
- CARNEIRO, J.S.S.; SANTOS, A.C.M.; FIDELIS, R.R.; NETO, S.P.S.; SANTOS, A.C.; SILVA, R.R. Diagnóstico e manejo da variabilidade espacial da fertilidade do solo no cerrado do Piauí. **Revista de Ciências Agroambientais**, Alta Floresta, v.14, n.2, p.10-21, 2016.
- CATEN, A.T.; DALMOLIN, R.S.D.; PEDRON, F.A.; SANTOS, M.L.M. Componentes principais como preditores no mapeamento digital de classes de solos. **Ciência Rural**, Santa Maria, v.41, n.7, p.1170-1176, 2011.

COMISSÃO DE FERTILIDADE DE SOLOS DE GOIÁS. **Recomendações de corretivos e fertilizantes para Goiás: 5ª aproximação**. Goiânia, UFG/EMGOPA, (Informativo Técnico 1), 1988. 101p.

DALCHIAVON, F.C.; CARVALHO, M.P.; ANDREOTTI, M.; MONTANARI, R. Variabilidade espacial de atributos da fertilidade de um Latossolo Vermelho Distroférico sob Sistema Plantio Direto. **Revista Ciência Agronômica**, v.43, n.3, p.453-461, 2012.

FOODY, G.M. Assessing the accuracy of land cover change with imperfect ground reference data. **Remote Sensing of Environment**, New York, v.114, n.10, p.2271-2285, 2010.

GATTA, G.; LIBUTTI, A.; GAGLIARDI, A.; BENEDUCE, L.; BRUSETTI, L.; BORRUSO, L.; DISCIGLIO, G.; TARANTINO, E. Treated agro-industrial wastewater irrigation of tomato crop: Effects on qualitative/quantitative characteristics of production and microbiological properties of the soil. **Agricultural Water Management**, v.149, p.33-43, 2015.

GIASSON, E.; CLARKE, R.T.; INDA JUNIOR, A.V.; MERTEN, G.H.; TORNQUIST, C.G. Digital soil mapping using multiple logistic regressions on terrain parameters in Southern Brazil. **Scientia Agricola**, Piracicaba, v.63, n.3, p.262-268, 2006.

GONÇALVES, W.G.; RIBEIRO, H.M.C.; SÁ, J.A.S.; MORALES, G.P.M.; FERREIRA FILHO, H.R.; ALMEIDA, A.C. Classificação de estratos florestais utilizando redes neurais artificiais e dados de sensoriamento remoto. **Revista Ambiente e Água**, Taubaté, v.11, n.3, p.612-624, 2016.

GREGO, C.R.; OLIVEIRA, R.P.; VIEIRA, S.R. Geoestatística aplicada a agricultura de precisão. In: BERNARDI, A.C.C.; NAIME, J.M.; RESENDE, A.V.; BASSOI, L.H.; INAMASU, R.Y. (Ed.). **Agricultura de precisão: resultados de um novo olhar**. Brasília, DF: Embrapa, 2014. cap.5, p.74-83.

KRIPPENDORFF, K. **Content analysis: an introduction to its methodology**. 2. ed. Beverly Hills: Ed. Sage Publications, 2004. 412p.

LIMA, G.C.; SILVA, M.L.N.; OLIVEIRA, M.S.; CURI, N.; SILVA, M.A.; OLIVEIRA, A.H. Variabilidade de atributos do solo sob pastagens e mata atlântica na escala de microbacia hidrográfica. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.18, n.5, p.517-526, 2014.

MEIRELLES, M.S.P.; MOREIRA, F.R.; CAMARA, G. Técnicas de inferência espacial. In: MEIRELLES, M.S.P.; CAMARA, G.; ALMEIDA, C.M. (Eds.). **Geomática: Modelos e aplicação Tecnológica**, 2007. cap. 3, p.105-191.

PAULETTI, V.; PIERRI, L.; RANZAN, T.; BARTH, G.; MOTTA, A.C.V. Efeitos em longo prazo da aplicação de gesso e calcário no sistema de plantio direto. **Revista Brasileira de Ciência do Solo**, v.38, n.2, p.495-505, 2014.

REIS, J.D.S. **Determinação de zonas de manejo para adubação nitrogenada em lavoura de tomate industrial**. 2011. 67p. (Mestrado em Engenharia Agrícola) - Universidade Estadual de Goiás, Anápolis.

RHEINHEIMER, D.S.; TIECHER, T.; GONZATTO, R.; ZAFAR, M.; BRUNETTO, G. Residual effect of surface-applied lime on soil acidity properties in a longterm experiment under no-till in a Southern Brazilian sandy Ultisol. **Geoderma**, v.313, p.7-16, 2018.

SANA, R.S.; ANGHINONI, I.; BRANDÃO, Z.N.; HOLZSCHUH, M.J. Variabilidade espacial de atributos físico-químicos do solo e seus efeitos na produtividade do algodoeiro. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.18, n.10, p.994-1002, 2014.

SANCHEZ, P.A.; AHAMED, S.; CARRÉ, F.; HARTEMINK, A.E.; HEMPEL, J.; HUISING, J.; LAGACHERIE, P.; MCBRATNEY, A.B.; MCKENZIE, N.J.; SANTOS, M.L.M.; MINASNY, B.; MONTANARELLA, L.; OKOTH, P.; PALM, C.A.; SACHS, J.D.; SHEPHERD, K.D.; VAGEN, T.G.; VANLAUWE, B.; WALSH, M.G.; WINOWIECKI, L.A.; ZHANG, G.L. Digital soil map of the world. **Science**, v.325, p.680-681, 2009.

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.

SILVA, J.; GUEDES, I.M.R.; LIMA, C.E.P. **Adubação e nutrição**. IN: CLEMENTE, F.M.V.T.; BOITEUX, L (Eds.). Produção de Tomate para processamento industrial. Brasília DF: Embrapa, 2012. cap. 5, p. 105-127.

SIRTOLI, A.E.; SILVEIRA, C.T.; BOTELHO, M.F.; MANTOVANI, L.E. Pedometria apoiada em atributos topográficos, índices espectrais e geologia com uso de redes neurais artificiais. **Geociências**, São Paulo, v.32, n.3, p.516-531, 2013.

SOUZA, Z.M.; CERRI, D.G.P.; MAGALHAES, P.S.G.; SIQUEIRA, D.S. Variabilidade espacial de atributos do solo e produtividade da cultura de cana-de-açúcar em relação a localização topográfica. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.14, n.12, p.1250-1256, 2010.

TUKEY, J.W. A survey of sampling from contaminated distribution. In: OLKIN, I. **Contributions to probability and statistics**. California: Stanford University Press, 1960. Chapter 39, p.448-485.

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.

YAMAMOTO, J.K.; LANDIM, P.M.B. **Geoestatística: conceitos e aplicações**. 1. ed. São Paulo: Ed. Oficina de Textos, 2013. 215p.

ZHU, J.; LI, M.; WHELAN, M. Phosphorus activators contribute to legacy phosphorus availability in agricultural soils: A review. **Science of the Total Environment**, v.612, p.522-537, 2018.

ZONTA, J.H.; BRANDÃO, Z.N.; MEDEIROS, J.C.; SANA, R.S.; SOFITTI, V. Variabilidade espacial da fertilidade do solo em área cultivada com algodoeiro no Cerrado do Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v.18, n.6, p.595-602, 2014.

6. CONCLUSÕES GERAIS

O uso da RNA mostrou-se como um rápido método de fornecer informações indicativas sobre as características do solo, a partir de um número reduzido de amostras de solo, o que pode representar uma redução no custo com análises laboratoriais.

Os dados dos atributos de solo estimados pela RNA mostram-se promissores para serem usados nos estudos de variabilidade espacial.

A RNA adquiriu o conhecimento necessário para estimar valores médios dos atributos de solo com eficiência, mas o mesmo não ocorreu para estimar os atributos pontualmente.

Para o aprimoramento da rede sugere-se implementação em sua estrutura, visando a possibilidade de inserir novas variáveis de entrada, definir o limite espacial para estimação dos pontos amostrais e poder selecionar dentre os atributos químicos e físicos só aqueles de interesse para obter suas estimativas.

ANEXO A - Gráficos boxplot para identificação de outliers e critério de rejeição de Tukey (1960)




FIGURA 1 - Gráficos boxplot de atributos pH, Ca+Mg, H+Al, P e V% que tiveram a presença de outliers à esquerda. Gráficos boxplot dos atributos do solo após eliminação de outliers pelo teste de Tukey à direita.

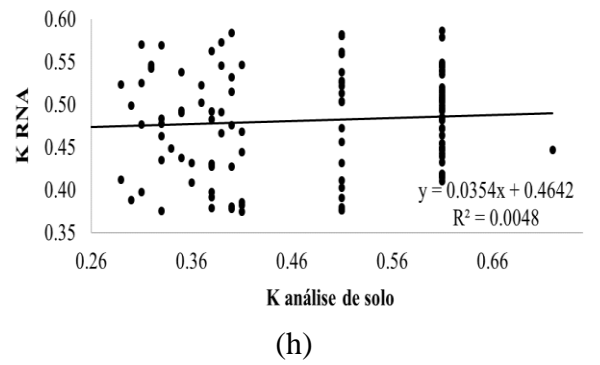
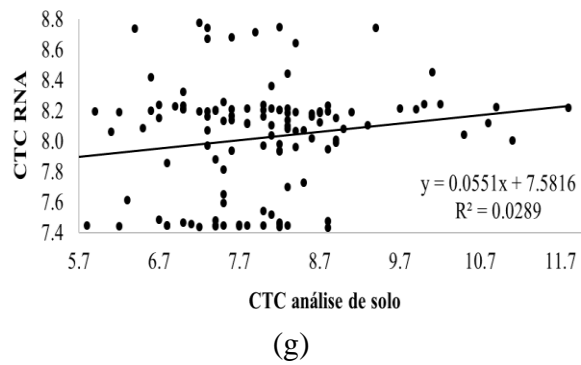




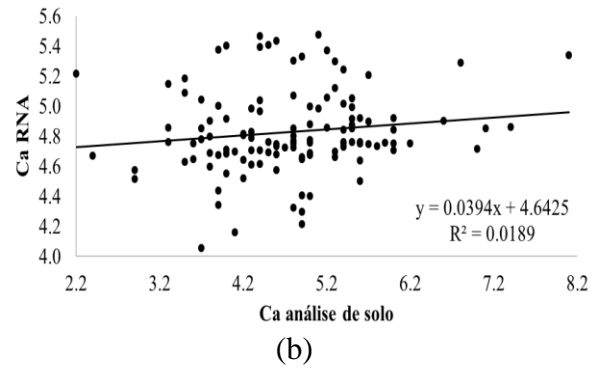
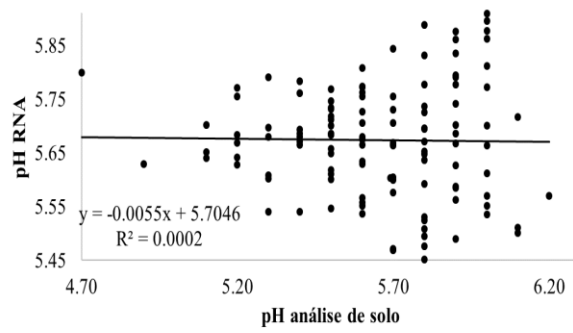
ANEXO B - Análise descritiva dos atributos com e sem a presença de outliers

TABELA 1 - Análise descritiva dos atributos com e sem a presença de outliers.

| Atributos | Análise outliers | Origem dos dados | Média | Mín | Quartil 1 | Quartil 2 | Quartil 3 | Máx | Ass | CV (%) | Teste Shapiro |
|-----------|------------------|------------------|-------|-------|-----------|-----------|-----------|-------|-------|--------|---------------|
| pH | antes | An. solo | 5,65 | 4,70 | 5,50 | 5,70 | 5,88 | 6,20 | -0,60 | 4,86 | 0,0024 |
| | depois | An. solo | 5,65 | 4,90 | 5,50 | 5,70 | 5,90 | 6,10 | -0,44 | 4,56 | 0,0026 |
| Ca+Mg | antes | An. solo | 5,76 | 3,00 | 4,90 | 5,70 | 6,53 | 9,70 | 0,56 | 21,38 | 0,0243 |
| | depois | An. solo | 5,70 | 3,00 | 4,90 | 5,65 | 6,50 | 8,80 | 0,41 | 20,33 | 0,0203 |
| H+Al | antes | An. solo | 1,73 | 0,80 | 1,40 | 1,60 | 2,00 | 3,70 | 0,81 | 27,05 | 0,0008 |
| | depois | An. solo | 1,63 | 0,80 | 1,40 | 1,60 | 2,00 | 2,30 | -0,24 | 21,54 | 0,0106 |
| P | antes | An. solo | 10,66 | 6,00 | 7,00 | 9,00 | 13,00 | 29,00 | 1,87 | 45,08 | 0,0000 |
| | depois | An. solo | 10,08 | 6,00 | 7,00 | 9,00 | 11,25 | 24,00 | 1,32 | 36,60 | 0,0000 |
| V% | antes | An. solo | 77,79 | 47,00 | 74,00 | 77,50 | 82,25 | 92,00 | -0,80 | 9,07 | 0,0012 |
| | depois | An. solo | 76,85 | 62,00 | 74,00 | 77,00 | 81,00 | 86,00 | -0,43 | 7,00 | 0,0201 |

pH - potencial hidrogeniônico; Ca+Mg - cálcio + magnésio; H+Al - acidez potencial; P - fósforo; V% - saturação por bases.

ANEXO C - Gráficos de regressão para os dados determinados pela análise de solo e os dados estimados pela RNA



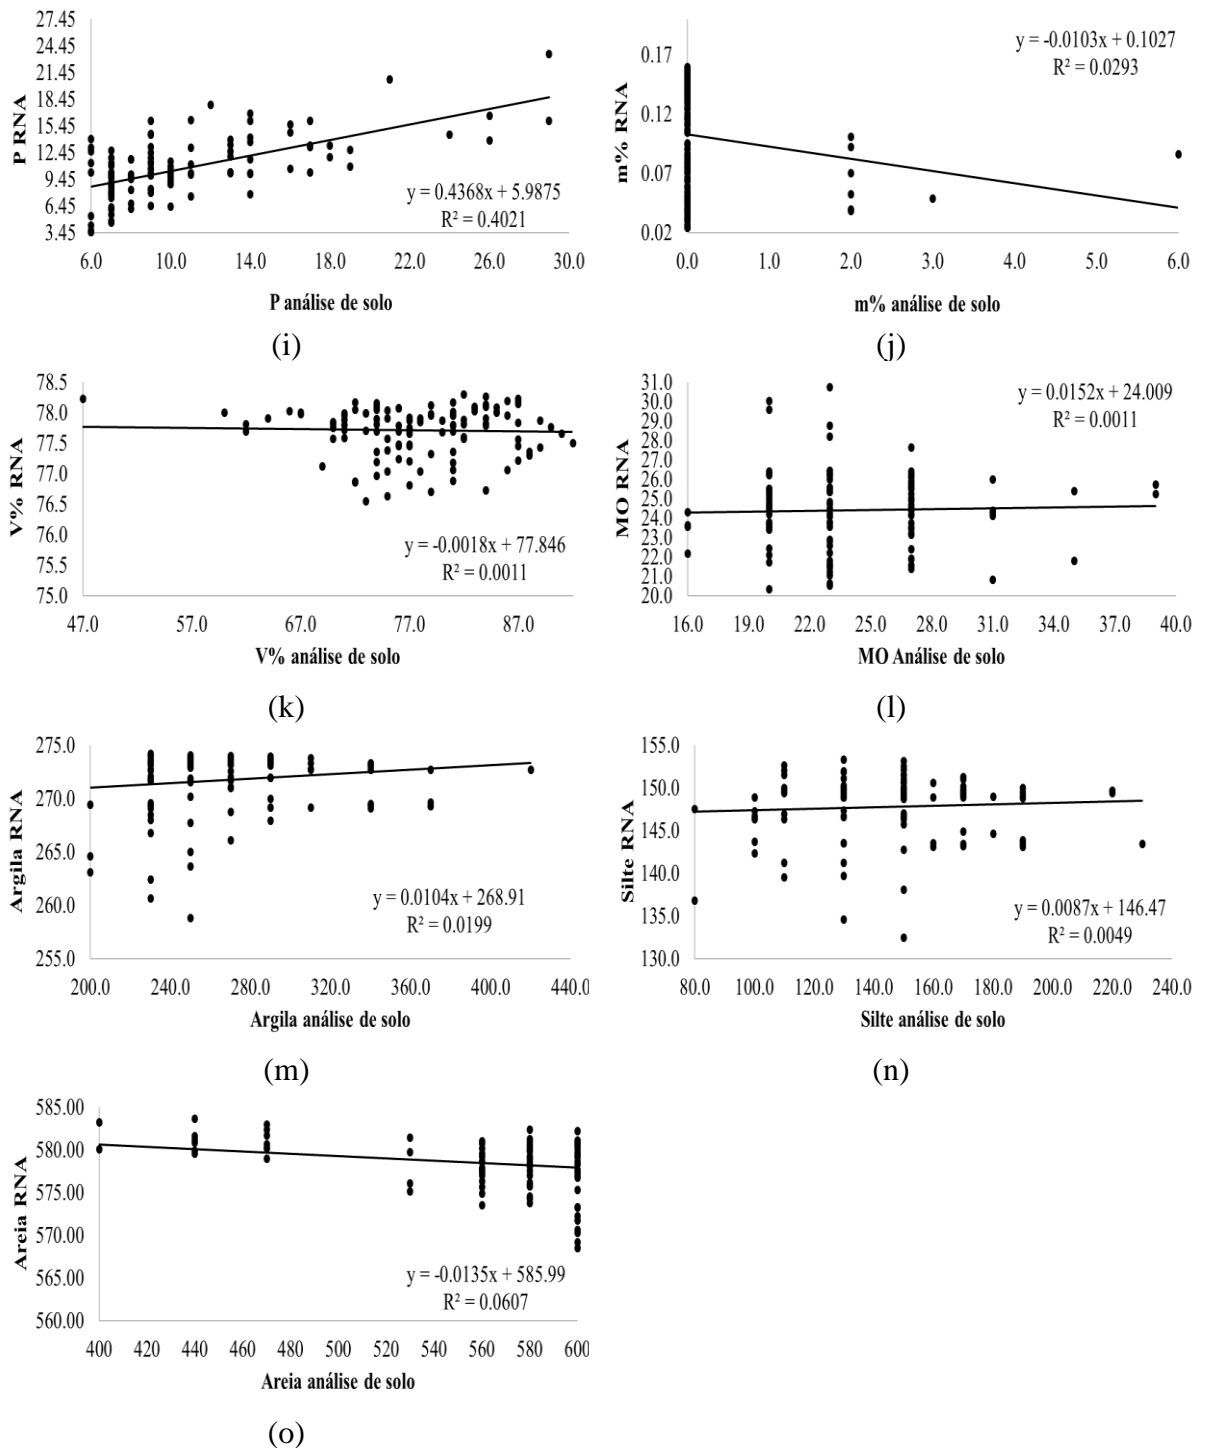


FIGURA 1 - Gráficos de regressão para os dados determinados pela análise de solo e os dados estimados pela RNA. (a) pH - potencial hidrogeniônico; (b) Ca - cálcio; (c) Mg - magnésio; (d) Ca+Mg - cálcio + magnésio; (e) Al - alumínio; (f) H+Al - acidez potencial; (g) CTC - capacidade de troca catiônica; (h) K - potássio; (i) P - fósforo; (j) m% - saturação por alumínio; (k) V% - saturação por bases; (l) MO - matéria orgânica; (m) Argila; (n) Silte; (o) Areia.

ANEXO D - Matriz de erro e cálculo dos índices Kappa e Exatidão Global dos dados determinados pela análise de solo em relação aos dados estimados pela RNA

TABELA 1 - Matriz de erro para a análise da acurácia das estimativas do atributo potencial hidrogeniônico (pH).

| | | KO RNA | | | |
|---------|--------------|---------|------|---|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 0 | 0 | 0 | 0 |
| | 2 | 0 | 4996 | 0 | 4996 |
| | 3 | 0 | 0 | 0 | 0 |
| | Soma colunas | 0 | 4996 | 0 | 4996 |

Classes: 1 (<4,5); 2 (4,5-7,0); 3 (>7,0)

$$\text{Índice kappa} = \frac{(4996 \times 4996) - 24960016}{4996^2 - 24960016} = 0$$

$$\text{Exatidão Global} = \frac{4996}{4996} = 1$$

Acurácia RNA

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{4996}{4996} = 1$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

Acurácia Solo

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{4996}{4996} = 1$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

TABELA 2 - Matriz de erro para a análise da acurácia das estimativas do atributo cálcio (Ca).

| | | KO RNA | | | |
|---------|--------------|---------|------|-----|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 0 | 0 | 0 | 0 |
| | 2 | 8 | 2953 | 513 | 3474 |
| | 3 | 6 | 1244 | 272 | 1522 |
| | Soma colunas | 14 | 4197 | 785 | 4996 |

Classes: 1 (<2,0); 2 (2,0-5,0); 3 (>5,0)

$$\text{Índice kappa} = \frac{(4996 \times 3225) - 15775148}{4996^2 - 15775148} = 0,0367$$

$$\text{Exatidão Global} = \frac{3225}{4996} = 0,6455$$

Acurácia RNA

$$\text{Classe 1} = \frac{0}{14} = 0$$

$$\text{Classe 2} = \frac{2953}{4197} = 0,7036$$

$$\text{Classe 3} = \frac{272}{785} = 0,3465$$

Acurácia Solo

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{2953}{3474} = 0,8500$$

$$\text{Classe 3} = \frac{272}{1522} = 0,1787$$

TABELA 3 - Matriz de erro para a análise da acurácia das estimativas do atributo Magnésio (Mg).

| | | KO RNA | | | |
|---------|--------------|---------|------|-----|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 0 | 0 | 0 | 0 |
| | 2 | 0 | 4381 | 160 | 4541 |
| | 3 | 0 | 455 | 0 | 455 |
| | Soma colunas | 0 | 4836 | 160 | 4996 |

Classes: 1 (<0,5); 2 (0,5-1,2); 3 (>1,2)

$$\acute{\text{Indice kappa}} = \frac{(4996 \times 4381) - 22033076}{4996^2 - 22033076} = -0,0497$$

$$\text{Exatid\~{a}o Global} = \frac{4381}{4996} = 0,8769$$

Acurácia RNA

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{4381}{4836} = 0,9059$$

$$\text{Classe 3} = \frac{0}{160} = 0$$

Acurácia Solo

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{4381}{4541} = 0,9648$$

$$\text{Classe 3} = \frac{0}{455} = 0$$

TABELA 4 - Matriz de erro para a análise da acurácia das estimativas do atributo Cálcio + Magnésio (Ca+Mg).

| | | KO RNA | | | |
|---------|--------------|---------|------|-----|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 310 | 313 | 71 | 694 |
| | 2 | 350 | 2721 | 733 | 3804 |
| | 3 | 0 | 421 | 77 | 498 |
| | Soma colunas | 660 | 3455 | 881 | 4996 |

Classes: 1 (<5,5); 2 (5,5-6,5); 3 (>6,5)

$$\acute{\text{Indice kappa}} = \frac{(4996 \times 3108) - 14039598}{4996^2 - 14039598} = 0,1363$$

$$\text{Exatid\~{a}o Global} = \frac{3108}{4996} = 0,6221$$

Acurácia RNA

$$\text{Classe 1} = \frac{310}{660} = 0,4697$$

$$\text{Classe 2} = \frac{2721}{3455} = 0,7876$$

$$\text{Classe 3} = \frac{77}{881} = 0,0874$$

Acurácia Solo

$$\text{Classe 1} = \frac{310}{694} = 0,4467$$

$$\text{Classe 2} = \frac{2721}{3804} = 0,7153$$

$$\text{Classe 3} = \frac{77}{498} = 0,1546$$

TABELA 5 - Matriz de erro para a análise da acurácia das estimativas do atributo acidez potencial (H+A1).

| | | KO RNA | | | |
|---------|--------------|---------|---|---|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 4996 | 0 | 0 | 4996 |
| | 2 | 0 | 0 | 0 | 0 |
| | 3 | 0 | 0 | 0 | 0 |
| | Soma colunas | 4996 | 0 | 0 | 4996 |

Classes: 1 (<2,5); 2 (2,5-5,0); 3 (>5,0)

$$\text{Índice kappa} = \frac{(4996 \times 4996) - 24960016}{4996^2 - 24960016} = 0$$

$$\text{Exatidão Global} = \frac{4996}{4996} = 1$$

Acurácia RNA

$$\text{Classe 1} = \frac{4996}{4996} = 1$$

$$\text{Classe 2} = \frac{0}{0} = 0$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

Acurácia Solo

$$\text{Classe 1} = \frac{4996}{4996} = 1$$

$$\text{Classe 2} = \frac{0}{0} = 0$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

TABELA 6 - Matriz de erro para a análise da acurácia das estimativas do atributo Capacidade de troca catiônica (CTC).

| | | KO RNA | | | |
|---------|--------------|---------|------|------|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 0 | 0 | 0 | 0 |
| | 2 | 0 | 1332 | 1888 | 3220 |
| | 3 | 0 | 476 | 1300 | 1776 |
| | Soma colunas | 0 | 1808 | 3188 | 4996 |

Classes: 1 (<2,3); 2 (2,8-8,0); 3 (>8,0)

$$\text{Índice kappa} = \frac{(4996 \times 2632) - 11483648}{4996^2 - 11483648} = 0,1236$$

$$\text{Exatidão Global} = \frac{2632}{4996} = 0,5268$$

Acurácia RNA

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{1332}{1808} = 0,7367$$

$$\text{Classe 3} = \frac{1300}{3188} = 0,4078$$

Acurácia Solo

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{1332}{3220} = 0,4137$$

$$\text{Classe 3} = \frac{1300}{1776} = 0,7320$$

TABELA 7 - Matriz de erro para a análise da acurácia das estimativas do atributo fósforo (P).

| | | KO RNA | | | |
|---------|--------------|---------|------|---|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 1948 | 1650 | 0 | 3598 |
| | 2 | 164 | 1234 | 0 | 1398 |
| | 3 | 0 | 0 | 0 | 0 |
| | Soma colunas | 2112 | 2884 | 0 | 4996 |

Classes: 1 (<10); 2 (10-30); 3 (>30)

$$\text{Índice kappa} = \frac{(4996 \times 3182) - 11630808}{4996^2 - 11630808} = 0,3201$$

$$\text{Exatidão Global} = \frac{3182}{4996} = 0,6369$$

Acurácia RNA

$$\text{Classe 1} = \frac{1948}{2112} = 0,9223$$

$$\text{Classe 2} = \frac{1234}{2884} = 0,4279$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

Acurácia Solo

$$\text{Classe 1} = \frac{1948}{3598} = 0,5414$$

$$\text{Classe 2} = \frac{1234}{1398} = 0,8827$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

TABELA 8 - Matriz de erro para a análise da acurácia das estimativas do atributo saturação por bases (V%).

| | | KO RNA | | | |
|---------|--------------|---------|---|------|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 0 | 0 | 0 | 0 |
| | 2 | 0 | 0 | 0 | 0 |
| | 3 | 14 | 0 | 4982 | 4996 |
| | Soma colunas | 14 | 0 | 4982 | 4996 |

Classes: 1 (<20); 2 (20-60); 3 (>60)

$$\text{Índice kappa} = \frac{(4996 \times 4982) - 24890072}{4996^2 - 24890072} = 0$$

$$\text{Exatidão Global} = \frac{4982}{4996} = 0,9972$$

Acurácia RNA

$$\text{Classe 1} = \frac{0}{14} = 0$$

$$\text{Classe 2} = \frac{0}{0} = 0$$

$$\text{Classe 3} = \frac{4982}{4982} = 1,0000$$

Acurácia Solo

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{0}{0} = 0$$

$$\text{Classe 3} = \frac{4982}{4996} = 0,9972$$

TABELA 9 - Matriz de erro para a análise da acurácia das estimativas do atributo Matéria orgânica (MO).

| | | KO RNA | | | |
|---------|--------------|---------|------|---|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 0 | 347 | 0 | 347 |
| | 2 | 0 | 4649 | 0 | 4649 |
| | 3 | 0 | 0 | 0 | 0 |
| | Soma colunas | 0 | 4996 | 0 | 4996 |

Classes: 1 (<20); 2 (20-50); 3 (>50)

$$\text{Índice kappa} = \frac{(4996 \times 4649) - 23226404}{4996^2 - 23226404} = 0$$

$$\text{Exatidão Global} = \frac{4649}{4996} = 0,9305$$

Acurácia RNA

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{4649}{4996} = 0,9305$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

Acurácia Solo

$$\text{Classe 1} = \frac{0}{347} = 0$$

$$\text{Classe 2} = \frac{4649}{4649} = 1,000$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

TABELA 10 - Matriz de erro para a análise da acurácia das estimativas do atributo Argila.

| | | KO RNA | | | |
|---------|--------------|---------|------|---|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 0 | 1072 | 0 | 1072 |
| | 2 | 0 | 3621 | 0 | 3621 |
| | 3 | 0 | 303 | 0 | 303 |
| | Soma colunas | 0 | 4996 | 0 | 4996 |

Classes: 1 (<250); 2 (250-350); 3 (>350)

$$\text{Índice kappa} = \frac{(4996 \times 3621) - 18090516}{4996^2 - 18090516} = 0,0000$$

$$\text{Exatidão Global} = \frac{3621}{4996} = 0,7248$$

Acurácia RNA

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{3621}{4996} = 0,7248$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

Acurácia Solo

$$\text{Classe 1} = \frac{0}{1072} = 0$$

$$\text{Classe 2} = \frac{3621}{3621} = 1,0000$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

TABELA 11 - Matriz de erro para a análise da acurácia das estimativas do atributo Silte.

| | | KO RNA | | | |
|---------|--------------|---------|------|------|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 76 | 307 | 438 | 821 |
| | 2 | 39 | 734 | 3111 | 3884 |
| | 3 | 0 | 51 | 240 | 291 |
| | Soma colunas | 115 | 1092 | 3789 | 4996 |

Classes: 1 (<145); 2 (145-155); 3 (>155)

$$\acute{\text{Indice kappa}} = \frac{(4996 \times 1050) - 5438342}{4996^2 - 5438342} = -0,0099$$

$$\text{Exatid\~{a}o Global} = \frac{1050}{4996} = 0,2102$$

Acurácia RNA

$$\text{Classe 1} = \frac{76}{115} = 0,6609$$

$$\text{Classe 2} = \frac{734}{1092} = 0,6722$$

$$\text{Classe 3} = \frac{240}{3789} = 0,0633$$

Acurácia Solo

$$\text{Classe 1} = \frac{76}{821} = 0,0926$$

$$\text{Classe 2} = \frac{734}{3884} = 0,1890$$

$$\text{Classe 3} = \frac{240}{291} = 0,8247$$

TABELA 12 - Matriz de erro para a análise da acurácia das estimativas do atributo Areia.

| | | KO RNA | | | |
|---------|--------------|---------|------|------|------|
| | | Classes | 1 | 2 | 3 |
| KO Solo | 1 | 0 | 0 | 0 | 0 |
| | 2 | 268 | 2210 | 2518 | 4996 |
| | 3 | 0 | 0 | 0 | 0 |
| | Soma colunas | 268 | 2210 | 2518 | 4996 |

Classes: 1 (<500); 2 (500-600); 3 (>600)

$$\acute{\text{Indice kappa}} = \frac{(4996 \times 2210) - 11041160}{4996^2 - 11041160} = 0,0000$$

$$\text{Exatid\~{a}o Global} = \frac{2210}{4996} = 0,4424$$

Acurácia RNA

$$\text{Classe 1} = \frac{0}{268} = 0$$

$$\text{Classe 2} = \frac{2210}{2210} = 1,0000$$

$$\text{Classe 3} = \frac{0}{2518} = 0$$

Acurácia Solo

$$\text{Classe 1} = \frac{0}{0} = 0$$

$$\text{Classe 2} = \frac{2210}{4996} = 0,4424$$

$$\text{Classe 3} = \frac{0}{0} = 0$$

TABELA 13 - Matriz de erro para a análise da acurácia das estimativas da Fertilidade do solo.

| | | KO RNA | | | | |
|---------|--------------|---------|-----|------|------|-------------|
| | | Classes | 1 | 2 | 3 | Soma linhas |
| KO Solo | 1 | | 182 | 336 | 216 | 734 |
| | 2 | | 157 | 2081 | 1123 | 3361 |
| | 3 | | 0 | 585 | 316 | 901 |
| | Soma colunas | | 339 | 3002 | 1655 | 4996 |

Classes: 1 (<0,25); 2 (0,25-0,75); 3 (>0,75)

$$\acute{\text{Indice kappa}} = \frac{(4996 \times 2579) - 11829703}{4996^2 - 11829703} = 0,0803$$

$$\text{Exatid\~{a}o Global} = \frac{2579}{4996} = 0,5162$$

Acurácia RNA

$$\text{Classe 1} = \frac{182}{339} = 0,5369$$

$$\text{Classe 2} = \frac{2081}{3002} = 0,6932$$

$$\text{Classe 3} = \frac{316}{1655} = 0,1909$$

Acurácia Solo

$$\text{Classe 1} = \frac{182}{734} = 0,2480$$

$$\text{Classe 2} = \frac{2081}{3361} = 0,6192$$

$$\text{Classe 3} = \frac{316}{901} = 0,3507$$

TABELA 14 - Matriz de erro para a análise da acurácia das estimativas da necessidade de calagem (NC).

| | | KO RNA | | | | |
|---------|--------------|---------|-----|------|-----|-------------|
| | | Classes | 1 | 2 | 3 | Soma linhas |
| KO Solo | 1 | | 225 | 1440 | 772 | 2437 |
| | 2 | | 528 | 1881 | 91 | 2500 |
| | 3 | | 22 | 37 | 0 | 59 |
| | Soma colunas | | 775 | 3358 | 863 | 4996 |

Classes: 1 (<-0,65); 2 (-0,65-0,45); 3 (>0,45)

$$\acute{\text{Indice kappa}} = \frac{(4996 \times 2106) - 10334592}{4996^2 - 10334592} = 0,0128$$

$$\text{Exatid\~{a}o Global} = \frac{2106}{4996} = 0,4215$$

Acurácia RNA

$$\text{Classe 1} = \frac{225}{775} = 0,2903$$

$$\text{Classe 2} = \frac{1881}{3358} = 0,5602$$

$$\text{Classe 3} = \frac{0}{836} = 0$$

Acurácia Solo

$$\text{Classe 1} = \frac{225}{2437} = 0,0923$$

$$\text{Classe 2} = \frac{1881}{2500} = 0,7524$$

$$\text{Classe 3} = \frac{0}{59} = 0$$

TABELA 15 - Matriz de erro para a análise da acurácia das estimativas da necessidade de fósforo (NP).

| | | KO RNA | | | Soma linhas |
|--------------|---|---------|------|-----|-------------|
| | | Classes | 1 | 2 | |
| KO Solo | 1 | 0 | 0 | 59 | 59 |
| | 2 | 1185 | 262 | 384 | 1831 |
| | 3 | 2250 | 790 | 66 | 3106 |
| Soma colunas | | 3435 | 1052 | 509 | 4996 |

Classes: 1 (<500); 2 (500-550); 3 (>550)

$$\text{Índice kappa} = \frac{(4996 \times 328) - 3709831}{4996^2 - 3709831} = -0,0975$$

$$\text{Exatidão Global} = \frac{328}{4996} = 0,0657$$

Acurácia RNA

$$\text{Classe 1} = \frac{0}{3435} = 0$$

$$\text{Classe 2} = \frac{262}{1052} = 0,2490$$

$$\text{Classe 3} = \frac{66}{509} = 0,1297$$


Acurácia Solo

$$\text{Classe 1} = \frac{0}{59} = 0$$


$$\text{Classe 2} = \frac{262}{1831} = 0,1431$$

$$\text{Classe 3} = \frac{66}{3106} = 0,0212$$


ANEXO E - Mapas de isolinhas para os atributos químicos e físicos do solo dados determinados pela análise de solo e os dados estimados pela RNA




(a)




(b)




(c)




(d)




(e)




(f)




(g)




(h)




(i)




(j)




(k)




(l)




(m)




(n)




(o)



(p)



(q)



(r)

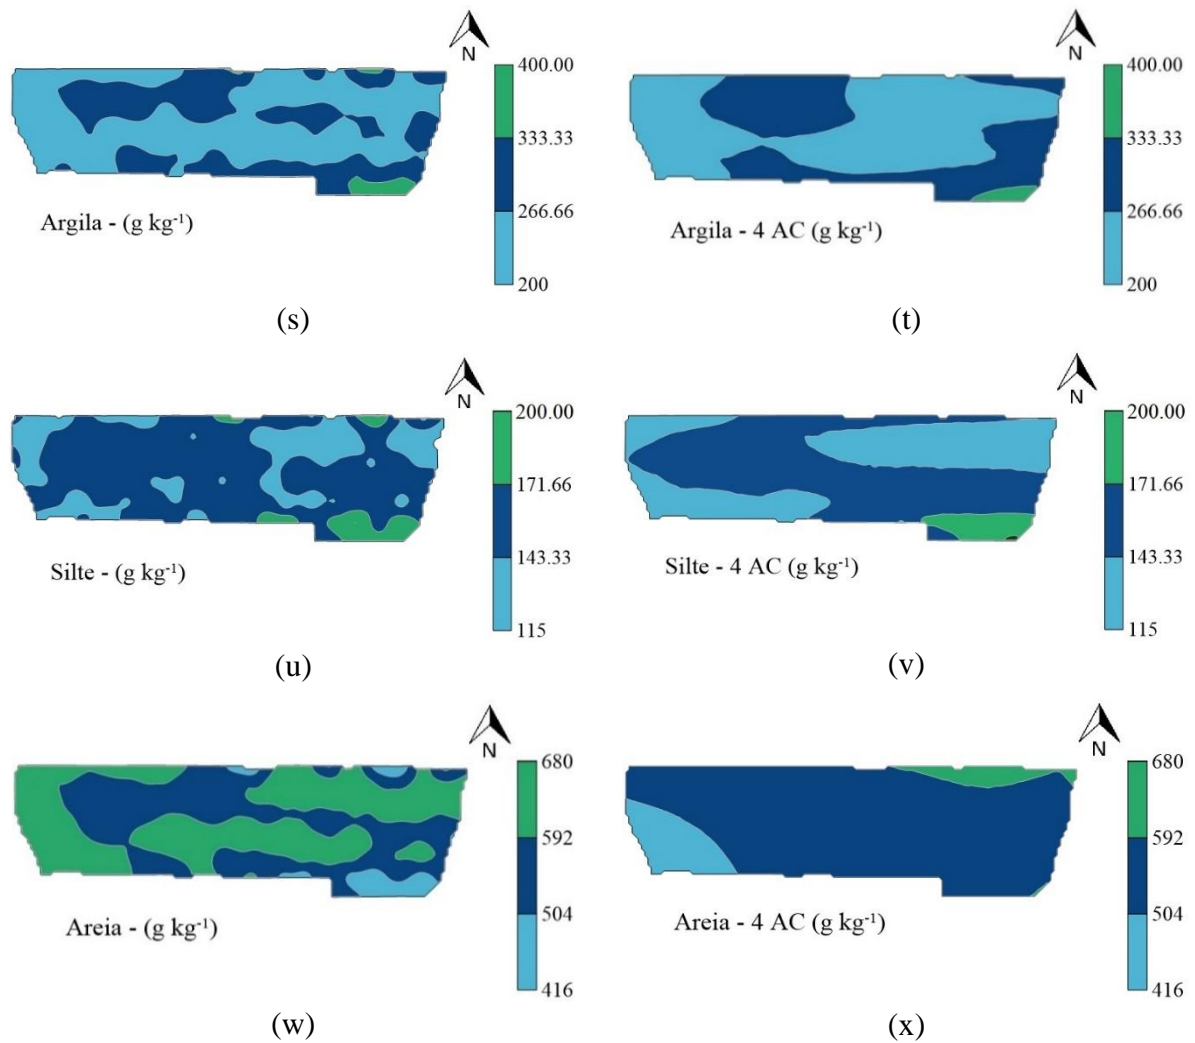


FIGURA 1 - Mapas de isolinhas para os atributos pH, Ca, Mg, Ca+Mg, H+Al, P, MO, CTC, V%, argila, silte e areia dos dados determinados na análise de solo e os dados estimados por meio da RNA utilizando 4 pontos amostrais conhecidos.

pH - potencial hidrogeniônico; Ca - cálcio; Mg - magnésio; Ca+Mg - cálcio + magnésio; H+Al - acidez potencial; P - fósforo; MO - matéria orgânica; CTC - capacidade de troca catiônica; V% - saturação por bases; 4 AC - 4 pontos amostrais conhecidos.