

UNIVERSIDADE ESTADUAL DE GOIÁS
CÂMPUS DE CIÊNCIAS EXATAS E TECNOLÓGICAS
PROGRAMA DE MESTRADO EM ENGENHARIA AGRÍCOLA

**REDES NEURAIS ARTIFICIAIS APLICADAS À MODELAGEM
DA VARIABILIDADE ESPACIAL DE ATRIBUTOS FÍSICO-
QUÍMICOS DE SOLOS DO CERRADO**

Roberto Dib Bittar

ANÁPOLIS - GO
FEVEREIRO DE 2016

**REDES NEURAIS ARTIFICIAIS APLICADAS À MODELAGEM
DA VARIABILIDADE ESPACIAL DE ATRIBUTOS FÍSICO-
QUÍMICOS DE SOLOS DO CERRADO**

ROBERTO DIB BITTAR

Orientador(a): Prof^a Dr^a Sueli Martins de Freitas Alves
Coorientador: Prof Dr Francisco Ramos de Melo

Dissertação apresentada à Universidade Estadual de Goiás – UEG, Câmpus de Ciências Exatas e Tecnológicas de Anápolis como parte das exigências do Programa de Pós-Graduação *Stricto Sensu* em Engenharia Agrícola, Área de concentração de Sistemas agroindustriais, para obtenção do título de MESTRE.

Anápolis
Goiás
2016

BITTAR, Roberto Dib.

**REDES NEURAIAS ARTIFICIAIS APLICADAS À
MODELAGEM DA VARIABILIDADE ESPACIAL
DE ATRIBUTOS FÍSICO-QUÍMICOS DE SOLOS
DO CERRADO– 2016.
112 f. il.**

Orientador(a): Prof^ª Dr^a Sueli Martins de Freitas Alves

Dissertação (Mestrado) – Universidade Estadual de Goiás.
Mestrado Stricto Sensu em Engenharia Agrícola, 2016.

Bibliografia.

1. Ciências Agrárias. 2. Engenharia Agrícola. 3.
ESTATÍSTICA. I. Título.


**REDES NEURAIS ARTIFICIAIS APLICADAS À MODELAGEM DA
VARIABILIDADE ESPACIAL DE ATRIBUTOS FÍSICO-QUÍMICOS DE
SOLOS DO CERRADO**

por

Roberto Dib Bittar

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


Aprovado em 22/03/2016



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



Prof. Dr. Ivano Alessandro Devilla
Membro
UEG/CCET



Prof. Dr. Weber Martins
Membro
UFG/EEE

Texto para reflexão

*“Dizem que a vida é para quem sabe viver,
mas ninguém nasce pronto. A vida é para
quem é corajoso o suficiente para arriscar
e humilde o bastante para aprender”
(Autor desconhecido)*

*A minha esposa (Adriana), minhas filhas (Paula e Luísa),
meu pai e mães, irmãos, tia Áurea e demais familiares.*

DEDICATÓRIA

AGRADECIMENTOS

A Deus,

... Deus no comando!!! Sempre!!!!

À minha esposa Adriana,

... que me ensina com seu exemplo a enfrentar todos os desafios. Me apoia de forma incondicional, mesmo que, para isso tenha que abrir mão de muitas coisas. Quanto mais vivemos juntos mais entendo o significado de “dois que se tornam apenas um”.

Às minhas filhas Paula e Luísa,

... por entenderem a minha necessidade de “isolamento” e colaborarem em inúmeros momentos.

À minha orientadora Prof^a Dr^a Sueli Freitas,

... que me ajudou muito a evoluir, me indicou caminhos, não só me orientou com conteúdo, mas me fez crescer enquanto pessoa, estudante e educador.

Ao meu coorientador Prof. Dr. Francisco Ramos de Melo,

... que ao abrir a porta do conhecimento não me deixou cair mesmo nos momentos mais difíceis, teve muita paciência e também me orientou no conteúdo e me fez crescer enquanto pessoa, estudante e educador.

Aos professores e colaboradores da UEG,

... a todos, em especial aos professores com quem tive a grata oportunidade de aprender: Elton Fialho dos Reis, Ivano Alessandro Devilla, Roberta Passini, Anamaria Achtschin Ferreira e Itamar Rosa Teixeira;

... a Eliete Feitosa Lima Fernandes e ao Sr. Waldeir Costa.

À Jacqueline de Sousa Reis,

... na cessão dos dados.

Aos colegas de curso,

...que contribuíram de maneira especial de diversas formas. Agradecimento especial ao Guiliano Rangel pelos questionamentos e ideias que ajudaram muito e ao Danilo Oliveira pela ajuda fundamental com o software de análise geoestatística.

Aos amigos,

... que torceram por mim em todos momentos. Agradecimento especial ao meu amigo irmão Luís C.G.C. da Silva e aos que me emprestaram computadores para conseguir processar tudo que era necessário em tempo hábil.

As Instituições CCET e a FAPEG,

À Universidade Estadual de Goiás– UEG, Câmpus de Ciências Exatas e Tecnológicas - CCET, ao departamento de Engenharia Agrícola e ao Programa de Pós-Graduação em Engenharia Agrícola;

À Fundação de Amparo à Pesquisa do Estado de Goiás - FAPEG, pela concessão de bolsa de formação de Mestrado.

SUMÁRIO

PÁGINA

LISTA DE TABELAS	viii
LISTA DE FIGURAS	ix
RESUMO	xi
ABSTRACT	xii
1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	4
2.1. Agricultura de precisão	4
2.2. Geoestatística	5
2.2.1. Semivariogramas	7
2.2.2. Dependência espacial	9
2.2.3. Krigagem	10
2.3. Redes neurais artificiais	11
2.3.1. Neurônio artificial.....	11
2.3.2. Breve histórico.....	12
2.3.3. Funções de ativação	14
2.3.4. Arquitetura das redes neurais artificiais	15
2.3.4.1. Redes alimentadas adiante com camada única	16
2.3.4.2. Redes alimentadas adiante com múltiplas camadas	16
2.3.4.3. Redes recorrentes	17
2.3.5. Aprendizado das redes neurais artificiais	17
2.3.5.1. Aprendizado não supervisionado	18
2.3.5.2. Aprendizado supervisionado	18
2.3.5.3. Finalização do aprendizado/treinamento	19
2.4. Redes neurais artificiais aplicadas na agricultura	20
3. MATERIAL E MÉTODOS	22
3.1. Origem dos dados experimentais	22
3.2. Análise descritiva e exploratória	23
3.3. Aplicação de rede neural artificial	24
3.3.1. Definição das variáveis de entrada	24
3.3.2. Normalização dos dados	25
3.3.3. Separação dos conjuntos de dados	26

3.3.4. Geração das matrizes de dados para treinamento	27
3.3.5. Treinamento das redes neurais artificiais	28
3.4. Escolha das redes neurais artificiais	29
3.5. Teste e validação das redes neurais artificiais selecionadas	29
3.6. Análise geoestatística	30
3.7. Comparação com resultados da análise geoestatística	31
4. RESULTADOS E DISCUSSÃO	33
4.1. Análise descritiva e exploratória	33
4.2. Análise geoestatística	35
4.2.1. Análise das janelas móveis	35
4.2.2. Análise dos semivariogramas	38
4.3. Análise do treinamento das redes neurais artificiais	40
4.4. Análise das estimativas das redes neurais artificiais selecionadas	42
4.4.1 Análise individual: atributo de solo <i>versus</i> estimativa RNA selecionada	43
4.5. Comparação das estimativas RNAs <i>versus</i> da geoestatística	59
5. CONCLUSÕES	62
6. SUGESTÕES PARA TRABALHOS FUTUROS	63
7. REFERÊNCIAS BIBLIOGRÁFICAS	64
APÊNDICE A	70
APÊNDICE B	73
APÊNDICE C	87
APÊNDICE D	93
APÊNDICE E	98

LISTA DE TABELAS

	PÁGINA
TABELA 1. Atributos de solo utilizados para entrada de dados da RNA	23
TABELA 2. Limites para normalização das variáveis de entrada da RNA	26
TABELA 3. Definição dos conjuntos de dados para RNA	27
TABELA 4. Análise descritiva dos atributos do solo	33
TABELA 5. Modelos teóricos de semivariância ajustados para os atributos de solo ..	38
TABELA 6. Resultados das RNAs selecionadas no treinamento	40
TABELA 7. Resultados dos testes das RNAs selecionadas	44
TABELA 8. Resumo do erro médio relativo entre valores aferidos e estimados pela Krigagem ordinária e redes neurais artificiais	59
TABELA 9. Teste-t para comparação de cada média estimada com a média dos dados originais considerando os valores dos 120 pontos amostrais.....	61
TABELA 10.Comparação valores aferidos x valores estimados: Mg.....	98
TABELA 11.Comparação valores aferidos x valores estimados: CTC	101
TABELA 12.Comparação valores aferidos x valores estimados: m%.....	104
TABELA 13.Comparação valores aferidos x valores estimados: MO.....	107
TABELA 14.Comparação valores aferidos x valores estimados: Argila	110

LISTA DE FIGURAS

	PÁGINA
FIGURA 1. Esquema do semivariograma experimental e teórico e os parâmetros que o descrevem	8
FIGURA 2. Interpretação geométrica da função semivariograma em um diagrama de dispersão	8
FIGURA 3. Neurônio McCulloch e Pitts (MCP)	12
FIGURA 4. Topologia de um Perceptron simples com uma única saída	13
FIGURA 5. Função desempenhada pelos neurônios das diferentes camadas da rede MLP	14
FIGURA 6. Porta de limiar quadrática	15
FIGURA 7. Rede feedforward com uma camada oculta e uma camada de saída	16
FIGURA 8. Rede recorrente com neurônios ocultos	17
FIGURA 9. Gráfico Performance Rede gerado pelo Matlab	20
FIGURA 10. Imagem da área experimental; grade de amostragem	22
FIGURA 11. Topologia da RNA MLP utilizada	24
FIGURA 12. Separação dos conjuntos de dados	27
FIGURA 13. Modelos matemáticos para ajuste do semivariograma experimental	31
FIGURA 14. Janela móvel dos atributos: Al e m%	35
FIGURA 15. Janela móvel dos atributos: pH, K, P, Ca, Mg, Ca+Mg, H+Al, MO	36
FIGURA 16. Janela móvel dos atributos: CTC e V%	37
FIGURA 17. Janela móvel dos atributos: Argila, Silte, Areia	38
FIGURA 18. Gráfico Comparativo Valores estimados RNA x aferidos: pH	43
FIGURA 19. Boxplot, Histograma e gráfico densidade: pH	45
FIGURA 20. Gráfico Comparativo Valores estimados RNA x aferidos: Ca	45
FIGURA 21. Boxplot, Histograma e gráfico densidade: Ca	46
FIGURA 22. Gráfico Comparativo Valores estimados RNA x aferidos: Mg	46
FIGURA 23. Boxplot, Histograma e gráfico densidade: Mg	47
FIGURA 24. Gráfico Comparativo Valores estimados RNA x aferidos: Ca+Mg	47
FIGURA 25. Boxplot, Histograma e gráfico densidade: Ca+Mg	48
FIGURA 26. Gráfico Comparativo Valores estimados RNA x aferidos: Al	48
FIGURA 27. Boxplot e Histograma: Al	49
FIGURA 28. Gráfico Comparativo Valores estimados RNA x aferidos: H+Al	49

FIGURA 29. Boxplot, Histograma e gráfico densidade: H+Al	50
FIGURA 30. Gráfico Comparativo Valores estimados RNA x aferidos: CTC	50
FIGURA 31. Boxplot, Histograma e gráfico densidade: CTC	51
FIGURA 32. Gráfico Comparativo Valores estimados RNA x aferidos: K	51
FIGURA 33. Boxplot, Histograma e gráfico densidade: K.....	52
FIGURA 34. Gráfico Comparativo Valores estimados RNA x aferidos: P	52
FIGURA 35. Boxplot, Histograma e gráfico densidade: P	53
FIGURA 36. Gráfico Comparativo Valores estimados RNA x aferidos: m%.....	53
FIGURA 37. Boxplot, Histograma e gráfico densidade: m%	54
FIGURA 38. Gráfico Comparativo Valores estimados RNA x aferidos: V%	54
FIGURA 39. Boxplot, Histograma e gráfico densidade: V%	55
FIGURA 40. Gráfico Comparativo Valores estimados RNA x aferidos: MO	55
FIGURA 41. Boxplot, Histograma e gráfico densidade: MO	56
FIGURA 42. Gráfico Comparativo Valores estimados RNA x aferidos: Argila	56
FIGURA 43. Boxplot, Histograma e gráfico densidade: Argila	57
FIGURA 44. Gráfico Comparativo Valores estimados RNA x aferidos: Silte	57
FIGURA 45. Boxplot, Histograma e gráfico densidade: Silte	58
FIGURA 46. Gráfico Comparativo Valores estimados RNA x aferidos: Areia	58
FIGURA 47. Boxplot, Histograma e gráfico densidade: Areia.....	59
FIGURA 48. Gráfico comparativo dos valores do erro médio das estimativas por krigagem e RNAs selecionadas	60
FIGURA 49. Semivariogramas dos atributos químicos: pH, K, P, Ca, Mg, Al.....	70
FIGURA 50. Semivariogramas dos atributos químicos: H+Al, MO e m%.	71
FIGURA 51. Semivariograma dos atributos de fertilidade do solo: CTC, V%	71
FIGURA 52. Semivariograma dos atributos de físicos: Argila, Silte, Areia	72

RESUMO

REDES NEURAIS ARTIFICIAIS APLICADAS À MODELAGEM DA VARIABILIDADE ESPACIAL DE ATRIBUTOS FÍSICO-QUÍMICOS DE SOLOS DO CERRADO

A agricultura, como outras atividades, está inserida na globalização. Desta forma, sofre concorrência e influência do que acontece no mundo, implicando na necessidade de melhor gerenciamento com o objetivo de minimizar custos e aumentar a produtividade. A agricultura de precisão oferece a tecnologia necessária para realizar esse gerenciamento. Possibilita aquisição de dados em uma vasta gama, processamento adequado e posterior utilização dessas informações para que impliquem em efetiva melhoria. Desta forma, racionaliza insumos, recursos naturais e humanos, logo, permite maior ganho final. Um dos fatores que influenciam a produção é a variabilidade espacial e temporal dos atributos do solo. Ao conhecer essa variação, é possível usar técnicas para adequar o solo às necessidades de cada cultura. A geoestatística está inserida na agricultura de precisão, possibilitando, a partir de determinado número de pontos georeferenciados amostrados, detectar e modelar essa variabilidade, resultando em conhecimento da área com o detalhamento necessário. As Redes Neurais Artificiais (RNA), ramo da inteligência artificial, buscam imitar o raciocínio humano e se mostram capazes de realizar inferência de dados. É considerada um aproximador universal, com capacidade de aprender. Uma qualidade das RNAs é estabelecer relação das características multidimensionais consideradas no problema para identificar o padrão ou classe do objeto apresentado. Desta forma, tem capacidade de ser uma razoável alternativa para realização da modelagem da variabilidade espacial. Neste trabalho aplicou-se as RNAs com objetivo de realizar a modelagem da variabilidade espacial de atributos do solo. Para tal foi realizada: coleta de dados, análise estatística descritiva, análise geoestatística, definição, treinamento de diferentes RNAs e consecutiva escolha das redes que apresentaram menor erro médio, posterior comparação entre os resultados estimados versus aferidos, cálculo do erro médio relativo finalizando com comparação das estimativas realizadas por Krigagem ordinária dos atributos que apresentaram dependência espacial. Foi possível concluir que as RNAs apresentam potencial para realizar satisfatoriamente a modelagem da variabilidade espacial de atributos físico-químicos do solo.

Palavras Chave: Inteligência Artificial, geoestatística, inferência, agricultura de precisão.

ABSTRACT

ARTIFICIAL NEURAL NETWORKS APPLIED TO MODELLING OF PHYSICAL AND CHEMICAL SPATIAL VARIABILITY ATTRIBUTES FROM CERRADO SOIL

Agriculture, like other activities is becoming global and therefore, it suffers competition and influence from what happens around the world. This behaviour is forcing the use of better management in order to minimize costs and increase productivity. The precision agriculture provides the necessary technology to achieve this level of management. Additionally, it enables the acquisition of wide range data, proper processing of this data and subsequent use of the information for effective improvement. Consequently, it optimizes material, natural and human resources and therefore allows higher productivity. One of the factors that influence the production is the spatial and temporal variability of soil properties. By knowing this variation, one can use management techniques to adjust the soil to the needs of each crop. By using the geostatistics inserted in precision agriculture, it is possible with a certain number of sample points to detect and model this variability, inferring the understanding of the area with the necessary detail. The Artificial Neural Networks (ANN), a branch of artificial intelligence, seeks to emulate human reasoning and is able to perform data inference and it is considered a universal approximator with ability to learn. One of the ANN features is the capability to establish multidimensional characteristic functions to identify presented patterns or object classes. Thus, it has the capacity of becoming a reasonable alternative to successfully implement modeling of spatial variability. Were applied the ANN for modeling the spatial variability of soil attributes and to accomplish this goal the following tasks have taken place: data collection, descriptive statistics and geostatistics analysis. The definition, training of different ANN and consequent choice of networks that had lower mean error have finished with the comparison between estimated versus measured results and the calculation of the mean relative error ending with comparing the estimates values made by ordinary Kriging of the attributes that presented spatial dependence. Consequently, it was possible to conclude that ANN has the potential to accomplish the modeling of spatial variability of physical and chemical soil properties.

Keywords: Artificial Intelligence, geostatistics, inference, computing, precision agriculture.

1. INTRODUÇÃO

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

Uma dessas estratégias é realizar a adequação dos nutrientes do solo utilizando análise de fertilidade com enfoque na cultura que será produzida. Para tal, deve-se realizar a limitação da área levando em conta a vegetação, a posição topográfica, às características perceptíveis do solo, a quantidade de amostras a ser coletada, a distribuição espacial dessas amostras e o seu histórico, buscando-se uma amostragem de solo representativa. Posteriormente faz-se a análise dessas amostras com objetivo de conhecer determinadas características e valores de atributos do solo. Entretanto, este conhecimento refere-se especificamente aos pontos coletados e podem não refletir toda a área considerada. Os valores conhecidos continuarão sendo apenas os amostrados e os demais deverão ser estimados (CANTARUTTI et al., 1999).

Uma propriedade intrínseca dos solos é a sua heterogeneidade, logo, o conhecimento da distribuição espacial dos atributos do solo em determinada área é fundamental na agricultura de precisão. Busca-se então, por inferência, conhecer características e valores dos atributos de solo em locais não amostrados considerando os valores conhecidos nos locais amostrados (VIEIRA, 2000).

O conhecimento da variação espacial de atributos de solo pode contribuir para o planejamento de lavouras comerciais. O solo, por mais uniforme que seja, mesmo em áreas consideradas homogêneas, apresenta variações nos seus atributos físicos e químicos. Existe variação espacial de determinados atributos em grau suficiente para interferir na produtividade das culturas, mesmo a curtas distâncias. O conhecimento desta variabilidade deve ser incorporado aos procedimentos e técnicas aplicadas à agricultura de precisão (FILHO et al., 2007).

Na agricultura de precisão o solo não é tratado como homogêneo, a variação espacial dos seus atributos e suas características produtivas precisam ser conhecidas

para que seja possível otimizar o ganho na produção, reduzir gastos, conservar o meio ambiente e propiciar desenvolvimento humano (SIQUEIRA, et al., 2008).

O conhecimento da área com maior detalhamento possibilita indicar os locais onde diferentes ações devem ocorrer. É possível, por exemplo, realizar correção de atributos do solo considerando seu valor em determinada localização geográfica. Dentro deste contexto a geoestatística é uma ferramenta eficaz para o estudo da variabilidade espacial dos solos, pois permite a descrição quantitativa desta variabilidade, realiza estimativa não tendenciosa e com variância mínima dos valores desses atributos em locais não amostrados (VIEIRA, 2000).

Uma das abordagens apropriadas para caracterizar as variáveis de solo e sua distribuição espacial é a análise geoestatística. Os atributos do solo não estão distribuídos randomicamente dentro dos ecossistemas, seguem uma distribuição regionalizada. Algumas amostras possuem maior similaridade de valores dos seus atributos que outras e essa relação se dá pela distância que as separa (SANTOS et al., 2013).

Outras tecnologias podem ser utilizadas com o propósito de estimar a variabilidade espacial de atributos de solo. As Redes Neurais Artificiais (RNA) são programas computacionais que procuram imitar o raciocínio dos seres vivos, o neurônio artificial é seu componente básico. As RNAs compõem uma estrutura matemática flexível capaz de realizar mapeamentos não lineares entre informações de entrada e de saída. São modelos computacionais que possuem a capacidade de aquisição e manutenção do conhecimento e podem ser treinadas para responder a determinada (NOROUZI et al., 2010; ANGELICO e SILVA, 2014).

Resultados promissores são relatados sobre a utilização das redes neurais como ferramenta de interpolação com capacidade de resolver problemas muito complexos em diversas áreas do conhecimento (SÁRKÖZY, 1999). Outros trabalhos são relatados por Norouzi (2010) e indicam bons resultados com aplicação nas ciências agrárias. Angelico (2005), por exemplo, utilizou co-relação para que as RNAs estimassem determinado atributo de solo considerando os valores de outros atributos.

Com a potencialidade de solução oferecida como o emprego de RNA, surgiu a motivação para utilizá-la na modelagem da variabilidade espacial de atributos físico-químicos de solos do cerrado. Buscou-se verificar a quantidade necessária de amostras de solo conhecidas para para que as RNAs após treinadas pudessem, em uma área determinada, realizar a modelagem da variabilidade espacial dos atributos de solo

considerados com resultado satisfatório. Angelico (2005) manteve a quantidade de pontos amostrais utilizados igual à utilizada para aplicar as técnicas geoestatísticas. Neste trabalho a relação de distâncias geográficas das coordenadas x,y entre pontos amostrais conhecidos e os que se busca estimar será considerado. Após o treinamento e escolha das RNAs espera-se que estas possam modelar a variabilidade espacial utilizando menor quantidade de amostras de solo que a quantidade de amostras utilizada para realizar estimativa por krigagem, assim como não seja necessário a ocorrência de dependência espacial para sua realização.

Almejou-se a possibilidade de realizar a inferência dos seguintes atributos do solo: a) Químicos: pH, Potássio (K), Fósforo (P), Cálcio (Ca), Magnésio (Mg), Alumínio trocável (Al), Acidez Potencial (H+Al), Matéria Orgânica (MO) e Saturação por Alumínio (m%). b) De fertilidade: Capacidade de Troca Catiônica (CTC) e Saturação por Bases (V%). c) Físicos: Argila, Areia e Silte. Para isso, foi necessário definir o modelo para entrada dos dados para treinamento da RNA que considerasse tanto a auto correlação quanto a distância entre as amostras de solo. Gerar programas computacionais para manipulação desses dados, realizar o treinamento das respectivas RNAs testando diferentes topologias e proceder a validação, teste e comparação de resultados apresentados.

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

2. REVISÃO DE LITERATURA

2.1. Agricultura de precisão

A necessidade de produção de alimentos para uma população em crescimento, sem degradar o meio ambiente, exige maior conhecimento dos fatores envolvidos no sistema de produção agrícola. Progressos técnico-científicos são responsáveis pela crescente eficiência agrícola, a ciência aplicada à agricultura tem conseguido além de aumentar a produção dos alimentos, reduzir ou até eliminar danos ao meio ambiente. Foi a agricultura que garantiu a sobrevivência da espécie humana e possibilitou sucessivos e contínuos aumentos da população. O aumento da eficiência agrícola possibilitou a grande parte da população se dedicar a outras atividades que não a produção de alimentos e permitiu o florescimento de sociedades cada vez mais complexas (PATERNIANI, 2001).

A agricultura atualmente está inserida na globalização, em uma situação de competição expressiva e que exige do produtor maior especialização e capacidade de gerenciamento. Nesse sentido, a Agricultura de Precisão (AP) tem o intuito de obter e avaliar informações sobre possíveis variações de fatores que podem influenciar na produção. Desta forma, é possível manejar essas diferenças buscando obter maior produtividade. Insumos são aplicados na proporção correta minimizando os custos de produção, a contaminação ambiental e os riscos da atividade agrícola, permitindo então, aumento do rendimento (FILHO, 2014).

Dezesseis elementos químicos da natureza, presentes nos solos, são essenciais para o crescimento de cada cultura, classificados como macronutrientes ou micronutrientes, de acordo com a quantidade que a planta os absorve do meio ambiente, sendo a produtividade limitada pelo nutriente que estiver em menor disponibilidade (ANGELICO, 2005). O autor indica também que a quantidade de nutrientes presentes no solo é extremamente dinâmica e pode apresentar variabilidade espacial e/ou temporal. A variabilidade temporal verifica diferenças em função do tempo enquanto que a variabilidade espacial trata das variações em função da localização geográfica.

Bolfe et al. (2007) também apontam para necessidade da competitividade dos produtos agrícolas na economia globalizada, o que implica na necessidade de maior controle de informações, proporcionando melhor domínio e eficiência na utilização de

insumos, serviços e recursos naturais. Conhecer de forma detalhada as características do solo, seus atributos e sua variabilidade espacial é um fator indispensável à instalação de um programa de agricultura de precisão visando obter melhor relação entre produção e gasto (BOLFE et al., 2007).

Coelho (2005) aponta que a variabilidade é um dos pilares da AP e que essas diferenças precisam ser avaliadas e corrigidas com a maior exatidão possível para que não ocorra falta ou sobra de algum atributo, permitindo obter a melhor produção em toda área plantada, independente da variabilidade existente.

Os atributos do solo são divididos em físicos e químicos sendo avaliados em função das suas influências específicas para cada planta.

No caso dos atributos físicos, a textura do solo constitui uma das características mais estáveis e representa a distribuição quantitativa das partículas sólidas minerais menores que 2mm em diâmetro (VAN LIER, 2010).

Os atributos químicos do solo usualmente avaliados são: valores de pH (medido em escala logarítmica) que normalmente exibem pouca variação, Nitrogênio Inorgânico (NO_3 e NH_4) e Potássio (K) disponível que exibem altos valores de Coeficiente de Variação (CV), o Fósforo (P) disponível que frequentemente exhibe valores extremamente altos de CV. Os micronutrientes: Zinco (Zn), Manganês (Mn), Ferro (Fe) e Cobre (Cu) também têm mostrado alta variabilidade espacial e sua distribuição depende da textura do solo, da Matéria Orgânica (MO), da Capacidade de Troca de Cátions (CTC) e pH. A parte orgânica é formada pela acumulação de resíduos animais e vegetais em diferentes graus de decomposição. Outros elementos químicos também avaliados: Cálcio (Ca), Magnésio (Mg), Sódio (Na) e Alumínio (Al) (COELHO, 2005).

Mesmo em áreas consideradas homogêneas, o solo, por mais uniforme que seja, normalmente apresenta variações nos seus atributos. Existe variação espacial de determinados atributos, que mesmo a curtas distâncias, ocorrem em grau suficiente para interferir na produtividade das culturas. Essa variabilidade e seu gerenciamento devem necessariamente ser incorporados aos procedimentos e técnicas aplicados na agricultura, sendo necessário conhecê-la para otimizar a aplicação de corretivos, fertilizantes, água, etc (AMARO et al., 2007).

2.2. Geoestatística

A geoestatística tem por objetivo a caracterização espacial de uma variável de interesse, por meio de sua distribuição e variabilidade espacial, com determinação das

incertezas associadas. O fenômeno espacial é o conjunto de todos os valores possíveis da variável de interesse, que define a distribuição e a variabilidade espacial dessa variável dentro de determinado domínio bidimensional ou tridimensional (YAMAMOTO e LANDIM, 2013).

A análise geoestatística permite detectar a existência da variabilidade e distribuição espacial das medidas estudadas e constitui importante ferramenta na análise e descrição detalhada da variabilidade das propriedades do solo. Conhecendo coordenadas geográficas de pontos amostrados é possível representar a área com maior detalhamento (GREGO e VIEIRA, 2005).

A geoestatística é o método mais utilizado para se estudar a variabilidade espacial de solo, é utilizada para se obter as características dos solos em locais não amostrados (ANGELICO, 2005).

A geoestatística pode ser considerada como uma aplicação prática da Teoria das Variáveis Regionalizadas. Conforme escrito por GENÚ (2004) variáveis regionalizadas são definidas como um tipo de variável aleatória que assume diferentes valores Z em função da posição x dentro de uma certa região S , e representa pares de coordenadas (x_i, y_i) . O ponto de referência para o sistema de coordenadas é arbitrário e fixado a critério do interessado. O conjunto de variáveis $Z(x)$ medidas em toda a área S pode ser considerada uma função aleatória $Z(x)$ uma vez que são variáveis aleatórias regionalizadas e assume-se que a dependência entre elas é especificada por algum mecanismo probabilístico.

Inicia-se a análise geoestatística com o estudo de auto correlação chamado de variograma ou análise de semivariograma, em que o grau de similaridade espacial é exibido como um variograma. O semivariograma é uma função da distância entre os pontos de amostragem, em que os pesos mudam de acordo com o arranjo geográfico desses pontos. A influência será maior quanto menor a distância entre os pontos e, menor quanto maior a distância entre esses (BOLFE et al., 2007).

O semivariograma consiste em uma ferramenta geoestatística que mostra a natureza estrutural de uma variável regionalizada definida pela comparação entre dois ou mais pontos obtidos simultaneamente, considerando as suas distâncias (SANTOS et al., 2013).

A análise geoestatística identifica a variabilidade espacial de uma dada variável na lavoura por meio do ajuste de semivariogramas e permite a criação de mapas temáticos por meio de interpolação por krigagem. Esses mapas, gerados na agricultura

de precisão, permitem ao agricultor um conhecimento detalhado da sua propriedade, possibilitando melhor gerenciamento e definição de estratégias mais eficientes de aumento de produção (CARVALHO et al., 2014).

Todo processo de inferência espacial tem início com a coleta de uma amostra composta por n pontos de dados e espera-se que essa amostra seja representativa do fenômeno em estudo, em termos de distribuição e variabilidade espacial. Estimativas geoestatísticas de variabilidade espacial ou temporal são, em geral, superiores aos demais métodos de interpolação numérica. Após a obtenção da amostra de dados é feita a análise variográfica. Se for possível utilizar a função variograma, aplica-se a Krigagem para modelar o fenômeno em estudo (YAMAMOTO e LANDIM, 2013).

2.2.1. Semivariogramas

Para entender variação espacial de uma determinada variável em um processo aleatório subjacente, deve-se levar em consideração a possibilidade de que o valor de cada ponto no espaço está relacionado, de algum modo, com valores obtidos situados a certa distância. Desta forma é possível supor que a variação de valor da variável ocorre de forma relacionada à distância entre os pontos analisados. A influência será maior quanto menor a distância e menor quanto maior a distância. Logo, uma inferência estatística torna-se possível considerando a distância $h = x_1 - x_2$ (correlação espacial de acordo com pontos amostrais). A função variograma mede a variância entre pontos separados por uma distância h . Assim, para pontos próximos, a diferença é pequena, o que implica também em variância pequena. Ao aumentar a distância, os valores dos pontos tendem a tornarem-se diferentes e, conseqüentemente a variância aumenta. Para determinar essa inferência da continuidade espacial a partir de valores amostrais calcula-se a função covariância e função variograma, esse modelo teórico permite determinar o valor da correlação espacial para qualquer distância dentro do espaço amostrado. A vantagem em utilizar o variograma é que, além da função da distância entre pontos, também é considerada a existência ou não do efeito pepita, do alcance (amplitude) e a presença da anisotropia (YAMAMOTO e LANDIM, 2013).

O Efeito pepita (C_0) é o valor da função na origem, representando a descontinuidade. O Alcance (A_0) indica o valor a partir de onde as amostras se tornam independentes. O patamar (C) é valor no qual ocorre a estabilidade no campo aleatório e contribuição (C_1) indica as diferenças espaciais entre os valores de uma variável analisada em dois pontos com distâncias sucessivamente maiores (Figura 1).

Anisotropia, no contexto da geoestatística, significa haver direções privilegiadas que condicionam a ocorrência da dependência espacial. Sua constatação é percebida nos semivariogramas quando o alcance ou o patamar, ou ambos, variam conforme a direção (0° , 45° , 90° e 135°). Por outro lado, quando o variograma não se altera com a direção, diz-se que é um fenômeno isotrópico (BERVEGLIERI et al., 2011; YAMAMOTO e LANDIM, 2013).




FIGURA 1. Esquema do semivariograma experimental e teórico e os parâmetros que o descrevem.
Fonte: REICHARDT e TIMM (2012).

Alguns autores preferem a terminologia variograma, outros semivariograma. Consequentemente, $2\gamma(h)$ é chamado de variograma e $\frac{1}{2}\gamma(h)$ de semivariograma devido a divisão da média das diferenças ao quadrado por dois. Essa divisão por dois não é empírica, Journel (1989) citado por Yamamoto e Landim (2013) realizou a demonstração de sua origem pela interpretação geométrica dos pares de pontos em um diagrama de dispersão (Figura 2).




FIGURA 2. Interpretação geométrica da função semivariograma em um diagrama de dispersão.
Fonte: YAMAMOTO e LANDIM (2013).

Muitos pesquisadores chamam o semivariograma de variograma, mas, nos cálculos sempre consideram a divisão por dois. Quanto maior a dispersão, maior o momento de inércia e menor a correlação. Se não houver dispersão, isto é, se todos os pares de pontos recaem sobre a reta 45°, o momento de inércia é zero e o coeficiente de correlação é igual a 1, isto é, máxima correlação. Isso faz com que o vetor h apresente-se infinitamente pequeno, a variância seja mínima e a covariância, máxima (YAMAMOTO e LANDIM, 2013).

O variograma é por definição (Equação 1),

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

e pode ser estimado através da Equação 2 (SILVA et al., 2011)

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

em que: $y(h)$ = semivariograma estimado;

$Z(x)$ = valor determinado de cada ponto amostrado;

$Z(x_i + h)$ = valor medido num ponto mais uma distância h ;

$N(h)$ = pares de observações pela distância h (ou módulo de h).

2.2.2. Dependência espacial

A continuidade geográfica de uma variável espacial se manifesta pela semelhança de valores da variável em dois pontos vizinhos. Esta continuidade ocorre pelo fato de existir certa medida de tendência e/ou certo grau de dependência espacial, onde observações próximas são associadas, e essa associação é maior para distâncias menores. A avaliação da significância da dependência espacial, quando feita, é realizada através da interpretação de algum indicador de dependência espacial (SEIDEL e OLIVEIRA, 2014).

A dependência espacial indica a ocorrência que o valor de qualquer ponto amostrado para se determinar variabilidade espacial de atributos de solo, depende de algum modo de seu vizinho. Na análise geoestatística os locais de amostragem são importantes porque se considera a dependência espacial entre as medidas. A partir dos dados amostrais é possível, por métodos de interpolação, gerar uma superfície contínua da área estabelecendo pelo semivariograma que melhor descreve a variabilidade espacial dos dados a tendência da semivariância em relação à distância. A Krigagem é o método de interpolação que confere maior exatidão às estimativas obtidas (FILHO et al., 2007).

2.2.3. Krigagem

A Krigagem é uma técnica usada na geoestatística para estimar valores para locais não amostrados, considerando os parâmetros do semivariograma, que resulta em valores sem tendência e com variância mínima (SILVA et al., 2008).

A Krigagem é usada para estimar o valor de uma variável em determinado local dentro do campo geométrico. Para isso, utiliza procedimento de interpolação exata que considera valores observados e respectivos posicionamentos para estimar o ponto desejado. É um processo de estimativa de valores de variáveis distribuídas no espaço, e/ou no tempo, a partir de valores adjacentes considerados como interdependentes pelo semivariograma. O engenheiro de minas sul-africano, Daniel G. Krige foi pioneiro na aplicação de técnicas estatísticas em avaliação mineira, e a técnica recebe este nome em sua homenagem (LANDIM, 2003).

A krigagem abrange uma família de algoritmos conhecidos como Krigagem: simples, da média, ordinária e universal. Usam informações a partir do semivariograma para encontrar os pesos ótimos a serem associados às amostras que irão estimar um ponto, um painel ou um bloco. Devido ao semivariograma ser uma função da distância dentre os pontos de amostragem, os pesos mudam de acordo com o arranjo geográfico desses pontos (YAMAMOTO e LANDIM, 2013).

De acordo com Cressie (1991) e Isaaks e Stivastava (1989) para realizar a Krigagem, não há exigência que os valores analisados estejam numa distribuição normal. É suficiente que a distribuição dos dados não tenha uma calda muito alongada, desta forma a estimação por krigagem não será comprometida. Entretanto, a presença de distribuição assimétrica com valores anômalos deve ser considerada, pois a krigagem é um estimador linear que se baseia em análises de regressão, sejam lineares ou transformações não-lineares devendo procurar minimizar a variância estimada a partir de um modelo prévio que leva em conta a dependência espacial entre os dados distribuídos no espaço (LANDIM, 2003).

Outra forma possível de determinar variabilidade espacial é pelo uso das Redes Neurais Artificiais (RNA) que se mostram capazes de adquirir conhecimento usando exemplos, sendo utilizadas no reconhecimento de padrões, aproximações de funções, predições e controle, possibilitando então, realizar a estimativa de dados na análise de

solos (ANGELICO, 2005). Galo et al. (2013) também indicam a capacidade de as Redes Neurais Artificiais realizarem a modelagem da distribuição espacial de variáveis.

2.3. Redes Neurais Artificiais

As RNAs, conforme Haykin (2001) são modelos matemáticos simplificados do sistema nervoso central humano em que o conhecimento é adquirido do universo de discurso por meio um processo de aprendizagem. Utilizando este aprendizado, a RNA será capaz, por exemplo, de tomar decisões, de dar respostas a novas situações utilizando a experiência adquirida (ANDRADE, 2008). As RNAs são sistemas de inteligência artificial baseados no sistema nervoso de seres vivos e seu elemento principal é o neurônio artificial. Um sistema de inteligência artificial deve ser capaz de fazer três coisas: armazenar conhecimento, aplicar o conhecimento armazenado para resolver problemas e adquirir novo conhecimento através da experiência (HAYKIN, 2001).

2.3.1. Neurônio Artificial

Os neurônios artificiais imitam o comportamento dos neurônios biológicos que recebem informações por meio dos dendritos (no neurônio artificial equivalem à camada de entrada). Se a intensidade de sinais recebidos for suficientemente alta (no neurônio artificial é indicado pela somatória das informações ponderadas recebidas e é feita na camada de processamento) será disparado resposta para as células seguintes chamadas neurônios pós-sinápticos (no neurônio artificial a resposta ocorre de qualquer maneira e é feita pela camada de saída). É pela sinapse que os neurônios se unem funcionalmente e uma das funções básicas executadas por um neurônio é a combinação de sinais recebidos de neurônios anteriores (BRAGA et al., 2012).

Esses neurônios (Figura 3) recebem informações, valores de entrada: $x_1, x_2, \dots, x_n$, por meio dos dendritos. Acoplados a esses valores de entrada são associados pesos, que podem ser positivos ou negativos, representados respectivamente por: $w_1, w_2, \dots, w_n$. Os valores são ponderados pelo combinador linear (Σ) a fim de produzir um valor potencial de ativação, sendo θ o patamar dessa ativação. O potencial de ativação (u) é então calculado pela função de ativação (g), sendo o resultado desta função y disparado como resposta pelo axônio (SILVA et al., 2010).




FIGURA 3. 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. (2010).

2.3.2. Breve histórico

Será apresentado um breve histórico sobre as Redes Neurais Artificiais utilizando compendio dos autores: Haykin (2001); Braga et al. (2012); Lima et al. (2014); Kovács (2006) e Silva et al. (2010).

O artigo de 1943 escrito por Warren McCulloch e Walter Pitts é considerado o marco inicial do trabalho com RNAs. A proposta do referido artigo era indicar que a inteligência é equivalente ao cálculo de predicados que por sua vez poderia ser implementado por funções lógicas (*booleanas*) assim como o sistema nervoso que com as devidas simplificações é composto de redes de neurônios e possui também essa capacidade.

Em 1949, Hebb mostrou a plasticidade da aprendizagem das redes neurais realizado com a variação dos pesos de entrada de neurônios. Propôs teoria conhecida como regra de Hebb que se baseia no reforço das ligações sinápticas entre neurônios excitados, ainda utilizada em vários algoritmos de aprendizado. Outra regra ainda empregada é a chamada regra delta de Widrow e Hoff de 1960, que busca gradiente descendente para minimização do erro de saída de um neurônio de resposta linear (saída igual a 1 ou 0).

Frank Roseblatt introduziu a possibilidade do aprendizado no neurônio artificial. Seu modelo de neurônio recebe o nome de perceptron e é composto por uma estrutura de rede com unidades básicas McCulloch e Pitts (MCP) e uma regra de aprendizado. Roseblatt demonstrou que um neurônio MCP treinado com algoritmo de aprendizado sempre irá convergir se houver possibilidade, ou seja, adquirir conhecimento, aprender. O aprendizado nesse tipo de rede é realizado por meio da aplicação de ajuste no vetor de pesos w . O Δw é a variação ou cálculo aplicado ao novo

peso, n a taxa de aprendizado, e indica o erro, x o valor de entrada associado ao respectivo peso. A estrutura básica descrita por Rossenblatt (Figura 4) é composta por unidades de entrada (retina), por um nível intermediário (unidades de associação) e por um nível de saída (unidades de resposta).




FIGURA 4. Topologia de um Perceptron simples com uma única saída.
Fonte: BRAGA et al. (2012).

Em 1969, Minsky e Papert indicaram que o modelo de Rosenblatt, (*perceptron* simples ou de uma única camada), possuía restrições, pois os pesos só poderiam ser ajustados à resolução de problemas linearmente separáveis, ou seja, a solução só poderia ter duas regiões e não estariam prontos para solução dos chamados problemas difíceis de aprender - *hard learning problems*, como por exemplo, detectar paridade, conectividade e simetria.

Na década de 70 e início dos anos 80, as pesquisas e a produção científica sobre redes neurais diminuem, entretanto, alguns trabalhos apresentaram destaque. Por exemplo, em 1974, Paul Werbos descreveu o processo de treinamento das RNAs com retropropagação de erros (*back-propagation of errors*). Em 1982 John Hopfield chamou atenção para as propriedades associativas das RNA demonstrando a relação entre redes auto associativas e redes físicas.

Em 1986, um estudo de Rumelhart, Hilton e Willians intitulado: *Learning representations by back-propagations erros*, trouxe a descrição do algoritmo *back-propagation* e a indicação que as RNAs de múltiplas camadas são, sem dúvida, capazes de resolver os problemas difíceis de aprender.

Para resolver problemas não linearmente separáveis é preciso adicionar uma ou mais camadas intermediárias, criando uma rede do tipo multicamadas de *perceptrons* (MLP - sigla proveniente do inglês *Multi Layer Perceptron*). Uma rede com uma camada intermediária pode implementar qualquer função contínua e a utilização de duas

camadas intermediárias (escondidas) permite a aproximação de qualquer função (CYBENKO, 1989).

O processamento realizado por cada neurônio de uma determinada camada é definido pela combinação dos processamentos realizados pelos neurônios conectados a ele conforme pode ser notado na Figura 5 (FACELLI et al., 2011).




FIGURA 5. Função desempenhada pelos neurônios das diferentes camadas da rede MLP.
Fonte: FACELLI et al. (2011).

2.3.3. Funções de ativação

A função de ativação é a função que gera a saída y do neurônio a partir da soma ponderada dos valores dos pesos $w = (w_1, w_2, \dots, w_n)$ e de entrada $x = (x_1, x_2, \dots, x_n)$ (equação = $\sum_{i=1}^n x_i w_i$). Quando o resultado indicado por θ (Figura 3) for maior ou igual a 0 o valor da função ativação y será 1, caso contrário y será zero (DIAS, 2004; SILVA et al., 2010).

Portas de limiar têm o objetivo de realizar uma soma ponderada das entradas. São divididas em: limiar linear, limiar quadrática e limiar polinomial. A função de comparação dessas portas realiza basicamente o mesmo procedimento: caso a soma ponderada das entradas exceda o limiar, a saída é ativada, caso contrário permanece desativada. No modelo MCP inicial, a função de ativação é do tipo degrau deslocada do limiar de ativação θ . O tipo de porta é de limiar linear e a superfície de decisão está restrita a uma reta. Desta forma, pode ser reescrita da forma geral da equação de uma reta na qual $y=f(x)$. Outras funções de ativação lineares comuns são: ativação sigmoidal e ativação linear enquanto que as RNAs de ativação radial *Radial Basis Functions*, (RBF) utilizam funções de ativação gaussiana (BRAGA et al., 2012).

Para aumentar o poder computacional de resolução de problemas, permitir definir regiões de decisão mais complexas e também para que as regiões de resposta possam assumir formas mais elaboradas são utilizadas funções de ativação de portas de limiar quadráticas. Estas funções possuem um número maior de parâmetros livres ajustáveis e são, ao mesmo tempo, mais complexas do que os da porta limiar conforme pode ser observado na Figura 6. A equação geral de ativação da porta possui também, no somatório, n termos quadráticos adicionais para todas as variáveis de entrada X_i , além dos $n(n-1)$ produtos cruzados entre todas variáveis de entrada. Essas características possibilitam definir regiões de decisão mais complexas. A escolha do tipo de função acontece conforme o problema a ser abordado no neurônio (BRAGA et al., 2012).




FIGURA 6. Porta de limiar quadrática.
Fonte: BRAGA et al. (2012).

2.3.4. Arquitetura das Redes Neurais Artificiais

Independente da função de ativação escolhida, neurônios individuais possuem capacidade computacional limitada, porém, um conjunto de neurônios artificiais conectados na forma de uma rede neural (RNA) é capaz de resolver problemas de complexidade elevada. A arquitetura ou topologia da rede indica como esses neurônios estão estruturados. O número de neurônios e a sua respectiva estruturação determina a capacidade da rede em resolver problemas. Quanto maior a complexidade da rede, maior é a sua abrangência em termos de soluções possíveis. Desta forma, a determinação do número de neurônios por si só é um desafio para o aprendizado das redes neurais e motiva boa parte das pesquisas da área. Deve haver equivalência entre a complexidade do problema e da rede (BRAGA et al., 2012; HAYKIN, 2001).

Fundamentalmente podemos identificar três classes de arquiteturas diferentes, são elas: redes alimentadas adiante com camada única, redes alimentadas adiante com múltiplas camadas e redes recorrentes (HAYKIN, 2001),

2.3.4.1.Redes alimentadas adiante com camada única

Rede neural de camada única (monocamada) alimentada para frente (*feedforward*) é capaz de resolver problemas multivariáveis de múltiplas funções acopladas. A quantidade de saídas sempre coincide com o número de neurônios. São tipicamente utilizadas em problemas envolvendo classificação de padrões e filtragem linear (SILVA et al., 2010).

2.3.4.2.Redes alimentadas adiante com múltiplas camadas

Se distinguem pela presença de duas ou mais camadas ocultas (Figura 7). A camada intermediária, que contém os nós computacionais correspondentes aos neurônios ocultos (camada oculta) tem como função intervir entre a entrada externa e a saída da rede. Conferem à RNA maior capacidade computacional e possibilitam a universalidade na aproximação de funções, classificação de padrões, identificação de sistemas, otimização, robótica e controle de processos dentre outras. Um dos principais tipos de rede que utiliza está arquitetura é o *Perceptron* multicamadas (BRAGA et al., 2012; HAYKIN, 2001; SILVA et al., 2010).




FIGURA 7. Rede *feedforward* com uma camada oculta e uma camada de saída.
Fonte: HAYKIN (2001).

2.3.4.3. Redes recorrentes ou realimentadas

As Redes recorrentes não são estáticas como as redes alimentadas adiante. São dinâmicas por possuírem recorrência entre camadas (Figura 8). As suas saídas podem ser retroalimentadas, essa recorrência ocorre, por exemplo, entre saídas e camada intermediária. A saída depende não somente das entradas, mas também do seu valor atual. É utilizada em resolução de problemas que envolvam processamento temporal, como, por exemplo, previsão de eventos futuros, e também utilizadas para otimização e identificação de sistemas e controle de processos (BRAGA et al., 2012; HAYKIN, 2001; SILVA et al., 2010).




FIGURA 8. Rede recorrente com neurônios ocultos.

Fonte: HAYKIN (2001).

2.3.5. Aprendizado das Redes Neurais Artificiais

Uma das principais características das RNA é a sua capacidade de aprendizado sem utilização de regras explícitas como ocorre em outros modelos computacionais. Este aprendizado é chamado de treinamento e ocorre por exemplos ou semelhanças em um processo iterativo no qual os parâmetros, os pesos da rede vão sendo ajustados. O objetivo desse procedimento é obter respostas com valores mais precisos possíveis. A precisão é avaliada de acordo com critério preestabelecido. Ao final do treinamento, o conhecimento que a rede adquiriu fica registrado nesses parâmetros nominados pesos da rede (W_n) (LIMA et al., 2014; SILVA et al., 2010).

O processo de aprendizado da RNA, chamado de treinamento, pode ser visto como um problema de ajuste de curva onde generalização é a capacidade da rede em realizar o mapeamento de entrada-saída computada de maneira correta ou

aproximadamente correta. A generalização é influenciada por três fatores: tamanho do conjunto de treinamento e o quanto esse conjunto representa o ambiente de interesse, a arquitetura da rede neural e a complexidade do problema em questão (HAYKIN, 2001).

Inicialmente a RNA fornece uma saída qualquer em função da condição inicial de peso aleatório, mas a cada iteração, com ajuste gradual dos pesos, o *perceptron* é treinado para fornecer saídas de acordo com os dados do conjunto de treinamento e o critério preestabelecido. Espera-se então que o erro diminua à medida que o aprendizado avance (HAYKIN, 2001; SILVA et al., 2014). De uma forma genérica, a fórmula para ajuste de pesos pode ser escrita conforme Equação 3.

$$w(t + 1) = w(t) + \Delta w(t) \quad (3)$$

em que: $w(t)$ = peso no instante t ;
 $w(t+1)$ = pesos nos instantes $t + 1$;
 $\Delta w(t)$ é o ajuste aplicado nos pesos.

Os algoritmos de aprendizado das redes do tipo *perceptron* diferem basicamente na forma como o $\Delta w(t)$ é calculado e podem ser agrupados em dois paradigmas principais: aprendizado não supervisionado e aprendizado supervisionado.

2.3.5.1. Aprendizado não supervisionado

O aprendizado não supervisionado se aplica a problemas que visam à descoberta de características estatisticamente relevantes nos dados de entrada, como, por exemplo a descoberta de agrupamentos ou classes. A própria rede se organiza identificando subconjuntos que contenham similaridade, esses subconjuntos são chamados de *clusters*. Os modelos mais conhecidos são os mapas auto organizáveis de Kohonen e os modelos *Adaptive Resonance Theory* (ART). Não há o papel do supervisor para acompanhar o processo de aprendizado, alternativamente existe a possibilidade de se estabelecer a quantidade máxima de possíveis *clusters*. Regularidade e redundância nas entradas são características para haver aprendizado não-supervisionado (BRAGA et al., 2012; SILVA et al., 2010).

2.3.5.2. Aprendizado supervisionado

No aprendizado supervisionado existe para cada conjunto de sinais/valores de entrada as respectivas saídas desejadas. Há o papel do supervisor ou professor que age para que a RNA acerte o resultado da relação (resposta estimada pela RNA; resposta

desejada), isto ocorre por comparação entre a saída da rede e o valor conhecido desejado. Para cada padrão de entrada é feita a comparação (resposta estimada pela RNA; resposta desejada) e os pesos $\Delta \mathbf{w}(t)$ são ajustados com objetivo de igualar esses valores. A minimização da diferença é incremental, os ajustes são feitos a cada etapa do treinamento de tal forma que caminhem, se houver solução possível, para a solução. Ao atingir essa situação, é possível dizer que a rede convergiu (BRAGA et al., 2012; SILVA et al., 2010).

Este tipo de aprendizado se aplica a problemas em que se deseja obter um mapeamento entre os padrões de entrada e saída. Os exemplos mais conhecidos de algoritmos de aprendizado supervisionado são a regra delta e sua generalização para redes de múltiplas camadas o *back-propagation* (BRAGA et al., 2012).

O algoritmo da retropropagação de erros ou *back-propagation* é utilizado para calcular o ajuste dos pesos associados aos neurônios nas redes de múltiplas camadas. Este algoritmo utiliza gradiente descendente e estima o erro das camadas intermediárias por meio de uma estimativa do efeito que estas causam no erro da camada de saída. Então, o erro de saída da rede é calculado e retroalimentado para as camadas intermediárias para que se realize o ajuste dos pesos proporcionalmente aos valores das conexões entre camadas (BRAGA et al., 2012; LIMA, 2014).

2.3.5.3. Finalização do aprendizado/treinamento

O treinamento ou aprendizado da rede é finalizado mediante análise de critério de parada quando os seguintes valores devem ser concomitantemente observados: I) número máximo de ciclos de aprendizado; II) taxa máxima de erro, III) taxa de acerto aceitável e IV) análise da ocorrência de especialização (*overfitting*) (BRAGA et al., 2012; HAYKIN, 2001)

Para análise de especialização da rede o seguinte processo é efetivado: a cada determinado número de ciclos de treinamento realizado com o conjunto de dados nominado treinamento é inserido um determinado conjunto de dados chamado de validação. Esses conjuntos de dados apresentam diferentes ocorrências da totalidade dos dados apresentados para a rede. No início do treinamento as taxas de erro para os dados de treinamento - *Train* e validação - *Validation* tem a mesma tendência a diminuir. Em um determinado ponto (Figura 9) apenas a taxa de erro dos dados do conjunto de validação começa a subir enquanto a taxa de erro do conjunto de treinamento se mantém diminuindo. Esse é o ponto em que a rede será escolhida, é o ponto de convergência da

rede, indica o melhor índice de acerto e o menor índice de erro alcançado sem que a rede esteja especializada. Apenas o conjunto de dados de treinamento é utilizado para o ajuste dos pesos da rede, desta forma, os demais conjuntos são usados com objetivo de confirmar a não especialização da rede na situação caracterizada pelos dados do treinamento (FACELLI et al., 2011).




FIGURA 9. Gráfico Performance Rede gerado pelo Matlab.

2.4. Redes Neurais Artificiais aplicadas na agricultura

A capacidade das RNAs em resolver problemas é demonstrada em trabalhos e em diferentes áreas, nesse tópico serão abordados exemplos de sua utilização na área de ciências agrárias.

A RNA mostrou resultados satisfatórios na estimação dos dados de precipitação, utilizando RNAs foi possível realizar preenchimento de falhas de dados pluviométricos em locais que não possuíam estações pluviométricas o que possibilitou compreender e modelar a variabilidade da distribuição da precipitação no estado de Alagoas (WANDERLEY et al., 2011).

Na cultura da soja foi realizado o reconhecimento de variedades por meio do processamento de imagens digitais usando redes neurais artificiais. Padilha e Khatchatourian (2008) aplicaram o processamento de imagens digitais auxiliado pelas RNAs com a finalidade de identificar algumas variedades de soja por meio da forma e do tamanho das sementes. A validação da RNA treinada mostrou que o processamento aplicado pode ser usado para a identificação das variedades consideradas.

Foi realizada a análise da evolução de doenças dos frutos cítricos, mancha preta e Huanglongbing utilizando técnicas geoestatísticas e de RNA. Foi feita comparação dos resultados aplicando validação cruzada. Nesta aplicação as RNAs tiveram desempenho inferior à geoestatística. O autor indica na sua conclusão que outras topologias e algoritmos de treinamentos devem ser estudados antes de descartar a técnica (ANDRADE, 2008).

Nääs et al. (2008) usaram RNAs na identificação de vocalização de suínos para verificar o bem-estar dos animais de forma não invasiva. Ao implementar algoritmo baseado em RNAs foi possível reconhecer vocalizações relacionadas com padrões indicativos de bem-estar e o algoritmo foi capaz de reconhecer, por meio da intensidade do ruído, a situação inerente ao risco de redução do bem-estar dos leitões.

Aplicação de RNAs para classificação automática de dados de sensoriamento com objetivo de identificar e mapear o uso e ocupação das terras. A ênfase era a identificação de áreas cafeeiras no sul de Minas. A metodologia de RNAs apresentou um bom resultado para realizar a identificação das áreas em imagens de satélite (ANDRADE, 2011).

Desenvolvimento de um sistema especialista com utilização da RNA e lógica difusa (*fuzzy*) para controlar o acionamento do sistema de climatização de instalações bovinas de leiteiros a partir da modelagem de dados fisiológicos dos animais em função dos dados climáticos do interior das instalações. O Sistema inteligente aplicado ao acionamento dos sistemas de climatização permitiu estabelecer alguns parâmetros ideais de conforto para os bovinos em lactação (PERISSINOTO, 2007).

Identificação dos sintomas de ferrugem em áreas cultivadas com cana-de-açúcar utilizando RNA realizando a classificação dos níveis de infecção da ferrugem por meio da análise de imagens aéreas de canaviais pela RNA usando características baseadas nas cores. Os resultados foram promissores e indicaram que o aprofundamento da técnica seria de grande valia para o setor sucroalcooleiro apontando para redução de custo e tempo no diagnóstico (DIAS, 2004).

Angelico (2005) comparou a estimativa da variabilidade espacial de atributos do solo utilizando os métodos estatísticos da krigagem e da co-krigagem, com a estimativa da variabilidade utilizando RNA. Os resultados comparados gerais indicaram melhores índices com a utilização das RNAs.

3. MATERIAL E MÉTODOS

3.1. Origem dos dados experimentais

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



FIGURA 10. (a) Imagem da área experimental; (b) Grade de amostragem.
Fonte: REIS (2011).

Para cada ponto amostral foram coletados os seguintes atributos do solo (REIS, 2011):

- Químicos: Potencial Hidrogeniônico (pH), Potássio (K), Fósforo (P), Cálcio (Ca), Magnésio (Mg), Alumínio trocável (Al), Acidez Potencial (H+Al), Matéria Orgânica (MO) e Saturação por Alumínio (m%);
- De fertilidade: Capacidade de Troca Catiônica (CTC) e Saturação por Bases (V%);
- Físicos: Argila, Areia e Silte.

3.2. Análise descritiva e exploratória

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

TABELA 1. Atributos de solo utilizados para entrada de dados da RNA.

Atributo	Unidade medida	Tipo de Atributo
pH (CaCl ₂)	-	Químico
Cálcio (Ca)	cmolc dm ⁻³	Químico
Magnésio (Mg)	cmolc dm ⁻³	Químico
Cálcio+Magnésio (Ca+Mg)	cmolc dm ⁻³	Químico
Alumínio trocável (Al)	cmolc dm ⁻³	Químico
Acidez potencial (H + Al)	cmolc dm ⁻³	Químico
Capacidade Troca Catiônica (CTC)	cmolc dm ⁻³	Químico
Potássio (K)	cmolc dm ⁻³	Químico
Fósforo (P)	mg dm ⁻³	Químico
Saturação por Alumínio (m%)	%	Químico
Saturação por Bases (V%)	%	Químico
Matéria Orgânica (MO)	g dm ⁻³	Químico
Argila	g Kg ⁻¹	Físico
Silte	g Kg ⁻¹	Físico
Areia	g Kg ⁻¹	Físico

Para cada um dos atributos de solo considerados foi utilizada a técnica das janelas móveis (ISAAKS e SRIVASTAVA, 1989). Para as janelas móveis foram geradas 32 médias contendo quatro pontos amostrais vizinhos que representaram aproximadamente 2500 m² da área sob estudo, no caso de janelas não quadriláteras foi feita sobreposição de pontos amostrais utilizados em outra janela, conforme indicam os autores. Posteriormente, as médias geradas foram comparadas por meio gráfico com valor do respectivo atributo para cada um dos 120 pontos amostrais. O objetivo foi realizar a identificação visual de possíveis tendências e a percepção da distribuição regionalizada dos valores dos respectivos atributos da área sob estudo utilizando por critério a verificação do posicionamento das linhas traçadas, porém esse procedimento possui elevado grau de subjetividade (GONÇALVES et al., 2001).

3.3 Aplicação da Rede Neural Artificial

O treinamento da RNA foi realizado utilizando o software trial Matlab ® 2012 com pacote *Neural Network ToolBox* em topologia do tipo MLP alimentada para frente *feedforward* com algoritmo de aprendizado de retropropagação do erro *Back-propagation* (Figura 11). A metodologia utilizada para preparação, treinamento e aplicação da rede neural artificial foi a proposta pelos autores Braga et al., (2012) que corroboram com Russel e Norvig (2013).




FIGURA 11. Topologia da RNA MLP utilizada.

Para cada um dos quinze atributos de solo considerados (Tabela 1) foram treinadas 168 redes neurais artificiais. A alternância na topologia das redes usadas no treinamento ocorreu em função de alterações em três fatores:

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

Ao considerar o procedimento de treinamento de RNAs para cada um dos 15 atributos de solo considerados, 2520 redes foram avaliadas no processo de treinamento.

3.3.1. Definição das variáveis de entrada

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

1ª Parte: Ponto amostral referencial – é a amostra de solo que terá o valor de cada atributo de solo estimado pela RNA. No processo de treinamento esse valor é conhecido e também informado, porém após a rede estar treinada, esse valor será a resposta apresentada pela rede para a coordenada informada;

- Localização geo-referenciada X do ponto amostral referencial;
- Localização geo-referenciada Y do ponto amostral referencial;

2ª Parte: Pontos amostrais relativos – são as amostras de solo conhecidas. No processo de treinamento foram utilizadas combinações não repetitivas de pontos amostrais entre si e diferentes do ponto amostral referencial. As variáveis de entrada aumentaram de acordo com a quantidade de pontos amostrais combinadas, a combinação com um ponto amostral relativo gerou 20 variáveis, a combinação usando dois pontos amostrais relativos gerou 38 variáveis, a combinação com três pontos amostrais relativos gerou 56 variáveis e com quatro gerou 74 variáveis. Para cada ponto amostral relativo acrescentado, 18 variáveis foram incluídas. São elas:

- Localização geo-referenciada X do ponto amostral relativo possibilitando o cálculo da distância absoluta até a coordenada geográfica X do ponto amostral referencial = ΔX_{ponto} ;
- Localização geo-referenciada Y do ponto amostral relativo possibilitando o cálculo da distância absoluta até a coordenada geográfica Y do ponto amostral referencial = ΔY_{ponto} ;
- Altitude em metros do ponto amostral relativo;
- 15 Atributos do solo indicados na Tabela 1.

3.3.2. Normalização dos dados

Foi feita normalização dos valores das variáveis com o objetivo de nivelar a ordem de grandeza proporcional para uso pela RNA. Os dados foram normalizados para faixa de valor entre -1 a 1 (Equação 4). Os limites superiores e inferiores utilizados (Tabela 2) foram estabelecidos utilizando dois critérios: os valores máximos e mínimos encontrados na análise descritiva e exploratória e, para os atributos de solo, zero para o limite inferior e valores máximos possíveis ou números primos que ultrapassassem os limites de toxicidade do atributo de solo consultados em Ribeiro et al. (1999) para os limites superiores. O uso de números primos nos limites superiores objetivou evitar resultados da normalização iguais a zero. O aumento na faixa de valores da normalização para o treinamento da rede visa possibilitar que a RNA após treinada possa ser usada em situações onde os valores das variáveis venham a extrapolar a faixa de valores do treinamento (HAYKIN, 2001).

$$y = \frac{(x-x_{min})(d2-d1)}{x_{max}-x_{min}} + d1 \quad (4)$$

em que : y = resultado da normalização;
 x = valor a ser normalizado;
 x_{min} = valor mínimo de X ;
 x_{max} = valor máximo de X ;
 $d1$ = limite inferior do resultado da normalização;
 $d2$ = limite superior do resultado da normalização.

TABELA 2. Limites para normalização das variáveis de entrada da RNA.

Atributo	Unidade	Mínimo da amostra	Máximo da amostra	Limite Inferior Normalização	Limite Superior Normalização
X	UTM	702352,20	703316,35	Mínimo -10%	Máximo +10%
Y	UTM	8047686,17	8047974,14	Mínimo -10%	Máximo +10%
Altitude	metros	789,36	830,46	Mínimo -10%	Máximo +10%
pH (CaCl ₂)	-	4,70	6,20	0	11
Ca	cmolc dm ⁻³	2,20	8,10	0	19
Mg	cmolc dm ⁻³	0,60	2,10	0	19
Ca+Mg	cmolc dm ⁻³	3,00	9,70	0	29
Al	cmolc dm ⁻³	0,00	0,20	0	19
H + Al	cmolc dm ⁻³	0,80	3,70	0	29
CTC	cmolc dm ⁻³	5,70	11,80	0	29
K	cmolc dm ⁻³	0,26	61,00	0	29
P	mg dm ⁻³	10,00	290,00	0	499
m%	%	0,00	6,00	0	100
V%	%	8,90	92,00	0	100
MO	g dm ⁻³	16,00	39,00	0	1000
Argila	g Kg ⁻¹	200,00	420,00	0	1000
Silte	g Kg ⁻¹	80,00	230,00	0	1000
Areia	g Kg ⁻¹	400,00	690,00	0	1000

pH-Potencial Hidrogeniônico; Ca – Cálcio (cmolc dm⁻³); Mg - Magnésio (cmolc dm⁻³); Al – Alumínio (cmolc dm⁻³); H+AL – Acidez Potencial (cmolc dm⁻³); CTC – Capacidade de Troca Catiônica; P – Fósforo (mg dm⁻³); K – Potássio (cmolc dm⁻³); m % - Saturação por Alumínio (%); V% - Saturação por Bases (%); MO- Matéria Orgânica (g dm⁻³); Argila (g Kg⁻¹); Silte (g Kg⁻¹); Areia (g Kg⁻¹).

3.3.3. Separação dos conjuntos de dados

A partir dos dados experimentais, foram separados quatro conjuntos de dados (Figura 12). Inicialmente foi escolhido de forma aleatória o conjunto nominado teste final, este conjunto não entrou no processo de treinamento da rede, foi utilizado somente na validação e teste final das redes neurais escolhidas (etapa 3.5.). Posteriormente, os conjuntos utilizados para o treinamento da RNA nominados: Treinamento, validação e teste foram escolhidos de forma aleatória. A quantidade de amostras de cada um desses conjuntos foi feita mediante adaptação da proporção

indicada por Braga et al. (2012) e Russel e Norvig (2013) devido a quantidade de amostras e a necessidade de se obter valores inteiros (Tabela 3).




FIGURA 12. Separação dos conjuntos de dados.

- Teste final = 10 amostras de solo, aproximadamente 8,33% do total;
- Treinamento = 82 amostras de solo, aproximadamente 75% das 110 amostras restantes, 68,33% do total;
- Validação = 17 amostras de solo, aproximadamente 15% das 110 amostras restantes, 14,17% do total;
- Teste = 11 amostras de solo, aproximadamente 10% das 110 amostras restantes, 9,17% do total.

TABELA 3. Definição dos conjuntos de dados para RNA.

Conjunto	Porcentagem do total	Quantidade amostras	QOMST 1 amostra solo relativa	QOMST 2 ou mais amostras de solo relativas
Teste Final	8,33%	10	1090	5000
Treinamento	68,33%	82	8938	41000
Validação	14,17%	17	1853	8500
Teste	9,17%	11	1199	5500
Total do treinamento	91,67%	110	11990	55000

QOMST – Quantidade ocorrências nas matrizes *source* e *target* usadas no Matlab ® para treinamento da RNA.

3.3.4. Geração das matrizes de dados para o treinamento

O Matlab ® realiza o treinamento de RNAs utilizando duas matrizes de dados. A matriz que possui os dados de entrada é nominada *source* e a matriz com as respostas é nominada *target*. Foram geradas 15 matrizes *targets* com os respectivos valores de cada atributo de solo considerado e quatro diferentes matrizes *source* também para cada atributo de solo considerado.

As matrizes *source* com um ponto amostral relativo continham 11990 ocorrências a partir da combinação de cada um dos 110 pontos amostrais referenciais utilizados no treinamento com os 109 relativos restantes (Tabela 3).

As matrizes *source* geradas para 2, 3 ou 4 pontos amostrais relativos totalizaram 55000 ocorrências (Tabela 3), foram geradas para cada um dos 110 pontos amostrais referenciais 500 combinações não repetitivas entre os 109 restantes. A não repetição foi verificada tanto entre pontos da mesma combinação quanto para diferentes combinações com possível ocorrência apenas de mudança na ordem.

Os programas criados usados para geração das matrizes constam no Apêndice B.

3.3.5. Treinamento das redes neurais artificiais

Esta etapa foi realizada usando programa computacional iterativo escrito aproveitando exemplo gerado pela *toolbox Neural Network* do *Matlab* ®. Este programa consta no Apêndice C. No programa são realizados os seguintes passos.

- Carregamento das matrizes de dados *Target* e *Source*;
- Indicação dos parâmetros para operacionalizar o treinamento da rede:
 - Quantidade de ciclos máximo de treinamento = 1000;
 - Erro mínimo esperado = 0;
 - Número de ciclos máximo falhos = 6;
 - Gradiente mínimo de performance = $1e-15$.
- Criação da estrutura da rede neural indicando a quantidade de camadas e número de neurônios;
- Inicialização dos pesos e *Bias* da RNA, mediante sorteio;
- Realização do treinamento iterativo com objetivo de obter o menor erro global para os conjuntos de dados (matrizes *source* e *target*);
- Interrupção do treinamento da rede ao atingir determinado critério de parada. Observar concomitantemente os seguintes valores:
 - Número máximo de ciclos de aprendizado;
 - Número de ciclos máximo falhos: ocorrência de especialização (*overfitting*);
 - Gradiente mínimo de performance.
- Arquivar a rede treinada, sua topologia, *Bias*, pesos finais, valores estimados, valores comparados e gráficos de performance em unidade de armazenamento.

3.4. Escolha das redes neurais artificiais

A partir dos dados do treinamento arquivados foi realizada a seleção de 4 RNAs para cada atributo de solo sob estudo. O critério de escolha utilizado foi a performance da RNA em acertar a estimativa dos valores do atributo no ponto amostral. O objetivo foi selecionar a hipótese que tornasse mínimo o erro do mapeamento entrada-saída. O cálculo da performance foi feito pelo índice de acerto de previsão obtido pelo erro médio quadrático (EMQ) (Equação 5), quanto menor o valor do EMQ, melhor a performance da RNA (HAYKIN, 2010).

$$EMQ = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (5)$$

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

Para cada um dos 15 atributos de solo considerados foram escolhidas quatro RNAs dentre as respectivas redes treinadas, uma RNA para cada quantidade de pontos amostrais relativos: um, dois, três e quatro.

3.5. Teste e validação das redes neurais artificiais selecionadas

Com objetivo de verificar o índice de acerto de cada uma das RNAs escolhidas foi feito a comparação dos resultados entre os valores estimados pelas redes e os valores observados nas amostras de solo. Para tal, foi calculado o valor do erro médio quadrático (EMQ) (Equação 4) e o valor do erro médio relativo (P) (Equação 6) considerando dois conjuntos de dados: conjunto C e conjunto C2. No conjunto de dados C está contido os valores de todas as 120 amostras de solo. No conjunto C2 está contido os valores das amostras de solo do conjunto teste final, as amostras do conjunto de validação e as amostras do conjunto de teste que foram utilizadas no treinamento da rede. O Conjunto C2 representa valores não mapeados no treinamento das RNAs.

$$P = \frac{100}{n} \sum \frac{|Y - \hat{Y}|}{Y} \quad (6)$$

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

Os resultados estimados pelas RNAs foram desnormalizados (Equação 7) para realizar esta comparação. Os programas usados para geração das matrizes de dados para esta comparação e para realizar o teste da RNAs constam no Apêndice D.

$$x = \frac{(x_{max}-x_{min})*(y-d1)}{(d2-d1)} + x_{min} \quad (7)$$

em que: x = resultado da desnormalização,
 y = valor normalizado;
 x_{min} = valor mínimo de X ;
 x_{max} = valor máximo de X ;
 $d1$ = limite inferior do resultado da normalização;
 $d2$ = limite superior do resultado da normalização.

Para análise de estimativa individual de cada atributo de solo considerado foi selecionada uma RNA dentre as quatro redes escolhidas. O critério de seleção foi o menor valor do EMQ apresentado no teste das RNAs selecionadas.

3.6. Análise geoestatística

A identificação da estrutura de dependência espacial dos atributos físicos e químicos do solo foi feita por meio da análise geoestatística utilizando o programa GS+ versão demo 10.0 Gamma Design Software ® (*Geostatistics for the Environmental Sciences*). Para cada atributo do solo considerado foi verificado, entre os modelos de semivariogramas o que apresentou melhor ajuste ao modelo experimental (ISAACS e SRIVASTAVA, 1989). Para a escolha do melhor modelo utilizou-se como critério a menor soma dos quadrados dos resíduos (SQR) e o maior coeficiente de determinação (R^2).

Foram testados e ajustados os modelos de semivariogramas esférico, exponencial, linear e gaussiano, conforme Figura 12.

Para análise do semivariograma foi considerado o modelo teórico e o modelo experimental (Figura 1), foi feita a avaliação do efeito pepita (C_0), do alcance (A_0) e do patamar ($C_0 + C_1$).




FIGURA 13. Modelos matemáticos para ajuste do semivariograma experimental.
Fonte: DIAS (2013).

Para a análise da dependência espacial foi calculado o índice de dependência espacial (IDE) conforme sugestões de Cambardella et al. (1994), modificada pelos GS+ (2004). A dependência espacial foi considerada fraca quando o IDE foi maior ou igual a 75%; foi considerada moderada quando o resultado ficou entre 25% a 75% e forte quando o resultado foi menor ou igual a 25 % (Equação 7).

$$IDE = \frac{c_0}{(c_0 + C)} \times 100 \quad (7)$$

em que: IDE = Índice de Dependência Espacial;
 C_0 = Efeito pepita;
 $(C_0 + C)$ = Patamar.

Para cada atributo que apresentou dependência espacial foi realizada a krigagem ordinária como técnica de interpolação. Foi considerada a dependência espacial isotrópica, ou seja, que a dependência espacial é a mesma em todas direções. A dependência espacial anisotrópica foi também verificada, porém não foi relevante.

3.7. Comparação com resultados da análise geoestatística

Os valores aferidos nos pontos amostrais dos atributos de solo que apresentaram dependência espacial foram comparados aos valores estimados pelas RNAs selecionadas e aos valores estimados utilizando a Krigagem ordinária (Apêndice E). A comparação foi feita com objetivo de verificar o índice de assertividade das RNAs selecionadas com índice de assertividade da krigagem realizada na análise geoestatística. Os valores do respectivo atributo nos 120 pontos amostrais foram comparados pelo P (Equação 6) em relação aos:

Valores estimados pela Krigagem ordinária;

Valores estimados pela RNA com 1 ponto amostral relativo;

Valores estimados pela RNA com 2 pontos amostrais relativos;

Valores estimados pela RNA com 3 pontos amostrais relativos;

Valores estimados pela RNA com 4 pontos amostrais relativos.

Com objetivo de testar se há indícios de diferenças em relação aos valores originais e os valores estimados por meio de krigagem e RNA foi realizado Teste-t.

4 RESULTADOS E DISCUSSÃO

4.1. Análise descritiva e exploratória

Os resultados das análises descritivas para os atributos físicos e químicos do solo avaliados foram (Tabela 4).

TABELA 4. Análise descritiva dos atributos do solo.

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

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

Os atributos Potencial Hidrogeniônico (pH), Potássio (K), Saturação por Bases (V%) e Areia apresentaram assimetria negativa com a média e a mediana menores que a moda, os demais atributos assimetria positiva. Exceto para o Fósforo (P), os demais atributos não apresentaram variação substancial entre os valores da média, mediana e moda. Essa é uma característica favorável para indicar que os valores amostrados provavelmente pertencem a uma distribuição espacial com variação de valores em distribuições regionalizadas.

Valores semelhantes para o Potencial Hidrogeniônico (pH), foram encontrados no estado de Goiás, em experimentos realizados em latossolos por Alcântara (2010): média, mediana e CV foram respectivamente: 5,689; 5,7 e 8,31% e em Dias (2013) os

valores foram 5,46 para média do atributo, 5,50 para mediana e CV de 3,72%. O CV do Potássio (K) e Saturação por Bases (V%) dos referidos trabalhos também foram compatíveis, porém média, mediana, máximo e mínimo foram diferentes.

Comportamento semelhante aos apresentados neste estudo para o Cálcio (Ca), Magnésio (Mg) e Cálcio+Magnésio (Ca+Mg) foram verificados por Alcântara (2010), Dias (2013), em Valente (2010) o CV do Ca foi maior, 44,66% e o CV do Mg foi igual à 39,52%.

O Potencial Hidrogeniônico (pH), Saturação por Bases (V%) e Areia apresentaram CV baixo e os demais atributos apresentaram CV médio conforme classificação adotada por Warrick e Nielsen (1980) para experimentos em campos que autores consideram valores do coeficiente de variação entre 12% a 60% como de média variabilidade, valores abaixo desta faixa como de baixa variabilidade e acima, como de alta variabilidade.

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

O valor da curtose para o Potássio (K) foi menor que zero indicando distribuição de dados platicúrtica. A curtose dos demais atributos analisados foi positiva indicando curva de dados leptocúrtica, distribuição dos valores apresentou frequência mais fechada que a curva normal.

Os coeficientes de variação do Alumínio (Al) e Saturação por Alumínio (m%) foram altos, acima de 200%. Dias (2013) também verificou CV alto para o Al assim como valores para média e mediana iguais a zero. Resultados semelhantes aos de Alcântara (2010) onde o CV foi 367%, a média foi próxima de zero e a mediana igual à zero.

Os outros atributos físicos: Argila e Silte tiveram variação baixa, de acordo com a classificação de Warrick e Nielsen (1980), valores semelhantes foram notados para região em Alcântara (2010), Couto (2010) e Dias (2013).

O valor médio da Capacidade de Troca Catiônica (CTC) foi $7,96 \text{ cmolc dm}^{-3}$, sendo assim, o solo foi classificado como de fertilidade média considerando a Capacidade de Troca Catiônica (RIBEIRO et al., 1999). Dias (2013) observou classificação semelhante para o solo onde realizou experimento, com média igual à 5,63

cmolc dm⁻³. Alcântara (2010) obteve resultado semelhante, a média observada foi igual 6,62 cmolc dm⁻³, a mediana próxima à média e CV baixo com valor de 11,65%.

O percentual encontrado para Saturação por Bases (V%) de 77,79% e respectivo CV menor de 9,07% permitiu classificar o solo da região sob estudo como de boas condições para o cultivo considerando este atributo (RIBEIRO et al., 1999).

A normalidade da distribuição dos valores da amostra foi confirmada apenas para o atributo Cálcio (Ca). Muitas variáveis do sistema solo-planta-atmosfera seguem distribuição normal, esta é uma característica importante para determinadas análises (REICHARDT e TIMM, 2012), porém, neste trabalho a característica de normalidade não é fundamental para aplicação em RNAs. O teste de normalidade também não é considerado uma premissa para realizar a análise geoestatística, entretanto foi realizada verificação sobre a adequação dos dados à uma distribuição regionalizada (OLIVEIRA et al., 2015). Para essa análise foi utilizada a técnica da análise gráfica das janelas móveis de Isaaks e Srivastava (1989) dos atributos sob estudo.

4.2. Análise geoestatística

4.2.1. Análise das janelas móveis

Os resultados gráficos das janelas móveis (ISAAKS e SRIVASTAVA, 1989) foram utilizados (Figuras 14 a 17) para realizar a identificação das tendências da distribuição dos dados dos atributos de solo na região em estudo. O eixo x identifica o ponto mostral e eixo Y o valor do atributo.




FIGURA 14. Janela móvel dos atributos: (a) Al; (b) m%.

Os atributos químicos Alumínio (Al) e Saturação por Alumínio (m%) apresentaram os maiores coeficientes de variação dentre todos os atributos de solo considerados, apresentaram valores acima de 200% (Tabela 4). Essa variação, considerada alta (Warrick e Nielsen, 1980) foi refletida, principalmente no gráfico da janela móvel do Alumínio (Figura 14 a) e concluiu-se que existe baixa probabilidade

deste atributo pertencer a uma distribuição do tipo regionalizada. A janela móvel da Saturação por Alumínio (Figura 14 b) indica tendência de estabilidade na relação entre o valor aferido no ponto amostral e a média calculada utilizando a média da janela móvel, logo, concluiu-se que os valores deste atributo estejam em uma distribuição regionalizada na área sob estudo.

Foi verificado CV baixo para o Potencial Hidrogeniônico (pH) e Matéria Orgânica. CV médio para os demais atributos químicos considerados (Warrick e Nielsen, 1980) (Tabela 4). As janelas móveis destes atributos são apresentadas na Figura 15.




FIGURA 15. Janela móvel dos atributos: (a) pH; (b) K; (c) P; (d) Ca; (e) Mg; (f) Ca+Mg; (g) H+Al; (h) MO.

A análise gráfica das janelas móveis pela observação da proporcionalidade entre as linhas que representam os valores de cada atributo nos pontos amostrais e a média calculada das janelas móveis do Potencial Hidrogeniônico (pH) (Figura 15 a); Potássio (K) (Figura 15 b); Fósforo (P) (Figura 15 c); Cálcio (Ca) (Figura 15 d); Magnésio (Mg) (Figura 15 e); Cálcio+Magnésio (Ca+Mg) (Figura 15 f); Acidez Potencial H+Al (Figura 15 g) e Matéria Orgânica MO (Figura 15 h), assim como a verificação de proximidade entre os valores da média, mediana e moda (Tabela 4) de cada um desses atributos, permitiu concluir que suas distribuições de valores podem ser caracterizadas como uma distribuição regionalizada na área sob estudo.

Os CV dos atributos de fertilidade: Capacidade de Troca Catiônica (CTC) e V% (Tabela 4) foram respectivamente médio e baixo (Warrick e Nielsen, 1980). Na análise da janela móvel da CTC (Figura 16 a) verificou-se que ocorre a manutenção da relação de proporcionalidade entre os valores do atributo no ponto amostral e a média calculada da janela caracterizando uma distribuição regionalizada na área sob estudo para o atributo. A mesma tendência não ocorre para Saturação por Bases (V%).




FIGURA 16. Janela móvel dos atributos: (a) CTC e (b) V%.

Os atributos físicos do solo Argila, Silte apresentaram médio CV e a areia CV baixo. A proximidade dos respectivos valores da média, mediana e moda (Tabela 4), bem como a análise gráfica das janelas móveis desses atributos com a verificação da proporcionalidade entre as linhas representativas dos valores nos pontos amostrais e a média calculada das janelas móveis permitiu concluir que ocorre distribuição regionalizada dos respectivos valores na área sob estudo (Figura 17).




FIGURA 17. Janela móvel dos atributos físicos: (a) Argila; (b) Silte; (c) Areia.

4.2.2. Análise dos semivariogramas

Os Modelos teóricos de semivariância ajustados para os atributos de solo da área sob estudo estão apresentados na Tabela 5

TABELA 5. Modelos teóricos de semivariância ajustados para os atributos de solo.

Atributo	Semivariograma	A ₀	C ₀	C ₀ +C	IDE	RSS	R ²
pH	EPP*	-	-	-	-	-	-
Ca	EPP*	-	-	-	-	-	-
Mg	Exponencial	76,50	0,02	0,09	0,829	0,00014	0,46900
Ca+Mg	EPP*	-	-	-	-	-	-
Al	EPP*	-	-	-	-	-	-
H + Al	EPP*	-	-	-	-	-	-
CTC	Exponencial	70,20	0,20	1,30	0,847	0,04930	0,23900
K	EPP*	-	-	-	-	-	-
P	EPP*	-	-	-	-	-	-
m%	Exponencial	204,90	0,31	0,61	0,501	0,08960	0,15400
V%	EPP*	-	-	-	-	-	-
MO	Esférico	69,30	0,09	17,11	0,995	6,14000	0,49400
Argila	Exponencial	57,30	177,00	1625,00	0,891	37175,00000	0,27400
Silte	EPP*	-	-	-	-	-	-
Areia	EPP*	-	-	-	-	-	-

A₀ - Alcance; C₀ - Efeito Pepita; C₀+C - Patamar, IDE = Índice Dependência Espacial; RSS - Soma do quadrado do resíduo; R² - Coeficiente de regressão, EPP* - Efeito Pepita Puro; pH-Potencial Hidrogeniônico; Ca - Cálcio; Mg - Magnésio; Al - Alumínio; H+AL - Acidez Potencial; CTC - Capacidade de Troca Catiônica; P - Fósforo; K - Potássio; m % - Saturação por Alumínio; V% - Saturação por Bases; MO- Matéria Orgânica.

A análise dos semivariogramas e possível dependência espacial dos atributos de solo considerados (Apêndice A) indicou efeito pepita puro para o Potencial Hidrogeniônico (pH), Cálcio (Ca), Cálcio+Magnésio (Ca+Mg), Alumínio (Al), Acidez potencial (H+Al), Potássio (K), Fósforo (P), Saturação por Bases (V%), Silte e Areia (Tabela 5). A ocorrência do efeito pepita puro indica ausência de dependência espacial, isto é, a distribuição dos dados ocorre de forma totalmente aleatória. Pode ser referente a uma variabilidade não explicada ou variações não detectadas em função da distância de amostragem utilizada (CAMBARDELLA et. al., 1994).

O modelo de semivariograma exponencial foi o que melhor se ajustou ao Magnésio (Mg), Capacidade de Troca Catiônica (CTC), Saturação por Alumínio (m%) e Argila. O modelo esférico foi o que melhor se ajustou à Matéria Orgânica (MO) (Tabela 5). Nos estudos sobre variabilidade espacial de características químicas do solo, é comum o ajuste dos modelos esférico e exponencial (CARVALHO et al., 2002; SILVA et al., 2003).

Foi verificado grau de dependência espacial moderada para Saturação por Alumínio (m%). O Magnésio (Mg), Capacidade de Troca Catiônica (CTC), Matéria Orgânica (MO) e Argila apresentaram dependência espacial fraca na área sob estudo conforme classificação proposta por Cambardella et al. (1994).

O alcance da dependência espacial da Saturação por Alumínio (m%) foi 204,90m, o Magnésio atingiu 76,50m, a Capacidade de Troca Catiônica (CTC) 20,20m, a Matéria Orgânica (MO) 69,30m e a Argila 57,30m (Tabela 5).

Os pontos localizados em uma área cujo raio seja o alcance, apresentam mais semelhanças entre si do que os separados por distâncias maiores. Quando não for possível identificar estrutura da variância, como ocorreu com os atributos: Potencial Hidrogeniônico (pH), Cálcio (Ca), Cálcio+Magnésio (Ca+Mg), Alumínio (Al), Acidez potencial (H+Al), Potássio (K), Fósforo (P), Saturação por Bases (V%), Silte e Areia diz-se que os semivariogramas apresentaram efeito pepita puro (EPP), pode-se assumir que a distribuição é completamente ao acaso, há independência entre amostras e os métodos da estatística clássica podem ser aplicados, sendo a média aritmética um valor que representa bem o conjunto de dados (CARVALHO et al., 2002).

4.3. Análise do treinamento das redes neurais artificiais

Após o processo de treinamento foram escolhidas quatro RNAs para cada um dos 15 atributos de solo considerados (Tabela 6), sendo: Uma rede com um ponto amostral relativo: nominada 1AR. Uma rede com dois pontos amostrais relativos: nominada 2AR. Uma rede com três pontos amostrais relativos: nominada 3AR e uma rede com quatro pontos amostrais relativos: nominada 4AR.

TABELA 6. Resultados das RNAs Selecionadas no treinamento.

Atributo	QAR	QNCE	EMQ	Atributo	QAR	QNCE	EMQ
pH	4AR	13	0,00126	K	2AR	13	0,00004
pH	1AR	21	0,00138	K	1AR	13	0,00004
pH	3AR	13	0,00147	P	1AR	21	0,02048
pH	2AR	5	0,00151	P	3AR	21	0,03807
Ca	1AR	21	0,00587	P	2AR	7	0,03848
Ca	3AR	7	0,00789	P	4AR	9	0,03862
Ca	4AR	5	0,00818	m%	3AR	13	0,02383
Ca	2AR	3	0,00823	m%	4AR	17	0,02876
Mg	1AR	5	0,00046	m%	2AR	9	0,02995
Mg	4AR	5	0,00079	m%	1AR	17	0,03246
Mg	2AR	13	0,00080	V%	2AR	5	0,00015
Mg	3AR	17	0,00081	V%	1AR	21	0,00017
Ca+Mg	1AR	21	0,00448	V%	4AR	21	0,00017
Ca+Mg	3AR	7	0,00569	V%	3AR	7	0,00018
Ca+Mg	4AR	3	0,00569	MO	1AR	13	0,00004
Ca+Mg	2AR	5	0,00581	MO	3AR	17	0,00006
Al	4AR	17	0,00000	MO	2AR	7	0,00006
Al	2AR	17	0,00000	MO	4AR	21	0,00006
Al	3AR	21	0,00001	Argila	1AR	13	0,00298
Al	1AR	7	0,00001	Argila	3AR	3	0,00582
H+Al	1AR	9	0,00056	Argila	2AR	7	0,00601
H+Al	2AR	3	0,00066	Argila	4AR	13	0,00607
H+Al	3AR	17	0,00069	Silte	1AR	7	0,0020131
H+Al	4AR	7	0,00074	Silte	2AR	5	0,0028454
CTC	4AR	7	0,00425	Silte	3AR	5	0,0030076
CTC	2AR	5	0,00431	Silte	4AR	13	0,0030136
CTC	1AR	7	0,00438	Areia	1AR	9	0,00590
CTC	3AR	21	0,00446	Areia	2AR	3	0,01414
K	3AR	13	0,00004	Areia	4AR	5	0,01432
K	4AR	21	0,00004	Areia	3AR	13	0,01470

QAR - Quantidade pontos amostrais relativas; QNCE - Quantidade de Neurônios na Camada escondida; EMQ - Erro médio quadrático; pH-Potencial Hidrogeniônico; Ca-Cálcio; Mg-Magnésio; Al-Alumínio; H+AL- Acidez Potencial; CTC-Capacidade de Troca Catiônica; P-Fósforo; K-Potássio; m % - Saturação por Alumínio; V% - Saturação por Bases.

Sobre as redes selecionadas (Tabela 6), considerando a quantidade de pontos amostrais relativos (QAR) verificou-se que:

- Não houve relação direta de melhora na performance das redes aumentando a quantidade de pontos amostrais relativos.
- Três atributos: Potencial Hidrogeniônico (pH), Alumínio (Al), Capacidade de Troca Catiônica (CTC) apresentaram a melhor performance geral após o treinamento utilizando 4 pontos amostrais relativos.
- Dois atributos: Potássio (K) e Saturação por Bases (V%) apresentaram a melhor performance geral após o treinamento utilizando 3 pontos amostrais relativos.
- Um atributo: Saturação por Alumínio (m%) apresentou a melhor performance geral após o treinamento utilizando 1 ponto amostral relativo.
- Nove atributos: Cálcio (Ca), Magnésio (Mg), Cálcio+Magnésio (Ca+Mg), Acidez Potencial (H+Al), Fósforo (P), Matéria Orgânica (MO), Argila, Silte e Areia apresentaram a melhor performance geral após o treinamento utilizando 1 ponto amostral relativo.

Sobre as redes selecionadas (Tabela 6), considerando a quantidade de neurônios na camada escondida (QNCE), foi possível verificar que:

- Cinco RNAs foram selecionadas com três neurônios na camada escondida: Ca 2AR, Ca+Mg 4AR, H+Al 2AR, Argila 3AR e Areia 2AR.
- Dez RNAs foram selecionadas com cinco neurônios na camada escondida: pH 2AR, Ca 4AR, Mg 1AR, Mg 4AR, Ca+Mg 2AR, CTC 2AR, m% 2AR, Silte 3AR, Silte 2AR e Areia 4AR.
- 11 RNAs foram selecionadas com sete neurônios na camada escondida: Ca 3AR, Ca+Mg 3AR, Al 1AR, H+Al 4AR, CTC 1AR, CTC 4AR, P 2AR, m% 3AR, MO 2AR, Argila 2AR e Silte 1AR.
- Quatro RNAs foram selecionadas com nove neurônios na camada escondida: H+Al 1AR, P 4AR, V% 2AR e Areia 1AR.
- 12 RNAs foram selecionadas com treze neurônios na camada escondida: pH 3AR, pH 4AR, Mg 2AR, K 1AR, K 3AR, K 2AR, V% 3AR, MO 1AR, Argila 1AR, Argila 4AR, Silte 4AR e Areia 3AR.
- Sete RNAs foram selecionadas com 17 neurônios na camada escondida: Mg 3AR, Al 4AR, Al 2AR, H+Al 3AR, V% 1AR, V% 4AR e MO 3AR.

- 11 RNAs foram selecionadas com 21 neurônios na camada escondida: pH 1AR, Ca 1AR, Ca+Mg 1AR, AL 3AR, CTC 3AR, K 4AR, P 1AR, P 3AR, m% 1AR, m% 4AR e MO 4AR,

4.4 Análise das estimativas das redes neurais artificiais selecionadas

A cada uma das redes selecionadas (Tabela 6) foram apresentadas dois conjuntos de valores para teste: conjunto C onde constam os 120 pontos amostrais e o conjunto C2 com os valores não mapeados no treinamento das RNAs. Com objetivo de analisar o índice de acerto das estimativas das RNAs selecionadas foi feito o cálculo de três indicadores: erro médio quadrático (EMQ) (Equação 5), erro médio relativo (P) (Equação 6) para o conjunto C e P do conjunto C2 (Tabela 7).

A Saturação por Alumínio (m%) atingiu o melhor índice de acerto com a RNA selecionada utilizando 4 pontos amostrais relativos. A Capacidade de Troca Catiônica (CTC), Saturação por Bases (V%) obtiveram o melhor índice de acerto de estimativa com as respectivas RNA selecionadas utilizando 3 pontos amostrais relativos. Os demais atributos de solo apresentaram os melhores resultados com 1 ponto amostral relativo. Possivelmente esse fato advém da quantidade de combinações que foram utilizadas para o treinamento. Conforme descrito na metodologia deste trabalho, a matriz de treinamento com 1 ponto amostral relativo foi combinada com todas as outras 109 amostras, enquanto que, para o treinamento com 2, 3 e 4 amostras foi realizado 550 combinações sorteadas dentre as amostras restantes de forma a não haver repetição. A quantidade de dados para treinamento com 2, 3 e 4 amostras relativas foi maior, mas não esgotou a possibilidade de combinações possíveis devido à limitação da quantidade de dados para o treinamento. Essa limitação ocorreu devido ao hardware e software não suportarem a matriz de dados e respectivo treinamento da RNA.

Cinco atributos de solo: Potencial Hidrogeniônico (pH), Alumínio (Al), Saturação por Alumínio (m%), Argila e Areia foram estimados pelas respectivas redes selecionadas apresentando P(C) menor que 8% e P(C2) menor que 9% (Tabela 7).

Seis atributos de solo: Cálcio (Ca), Cálcio+Magnésio (Ca+Mg), Capacidade de Troca Catiônica (CTC), Saturação por Bases (V%), Matéria Orgânica (MO) e Silte foram estimados pelas respectivas redes selecionadas apresentando P(C) entre 9% a 15% e P(C2) entre 10% a 20% (Tabela 7).

Três atributos de solo: Magnésio (Mg), Acidez Potencial (H+Al) e Potássio (K) foram estimados pelas respectivas redes selecionadas apresentando P(C) entre 15% a 18% e P(C2) entre 20% a 24% (Tabela 7).

O atributo Fósforo (P) foi estimado pela respectiva RNA selecionada com P(C) de 30,26% e P(C2) igual a 41,49%, sendo esta a pior performance de estimativa realizada para um atributo de solo utilizando RNA na área sob estudo (Tabela 7).

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

4.4.1 Análise individual: atributo de solo *versus* estimativa RNA selecionada

A Figura 18 apresenta o gráfico comparativo entre os valores estimados pela RNA e os verificados nas amostras de solo para o Potencial Hidrogeniônico (pH). A RNA selecionada pelo melhor resultado de estimativa para o atributo utilizou uma amostra de solo relativa (Tabela 7).




FIGURA 18. Gráfico Comparativo Valores estimados RNA x aferidos pH: (a) 120 PA; (b) C2.

Na Figura 18 verifica-se a proximidade entre as linhas para os valores estimados pela RNA e aferidos nas amostras de solo. A RNA escolhida para realizar a estimativa do pH atingiu a melhor performance dentre todos atributos, obteve valor do erro médio relativo para todas amostras igual a 3,13% e para o conjunto C2 de 5,62%. O CV de 4,86% para o pH indica sua baixa variação na área sob estudo. Os valores da média,

TABELA 7. Resultados dos testes das RNAs selecionadas.

Atributo	1 Amostra relativa			2 amostras relativas			3 amostras relativas			4 amostras relativas		
	EMQ	P(C)	P(C2)	EMQ	P(C)	P(C2)	EMQ	P(C)	P(C2)	EMQ	P(C)	P(C2)
pH	0,05	3,13	5,62	0,14	5,30	7,63	0,15	5,62	7,82	0,1488	5,34	7,88
Ca	0,61	14,15	18,49	0,94	17,37	22,12	1,10	19,00	22,96	1,02	17,73	22,74
Mg	0,04	16,25	20,58	0,09	24,63	25,73	0,10	26,56	25,47	0,09	25,60	26,67
Ca+Mg	1,04	14,69	18,53	1,51	17,63	21,54	1,72	19,22	22,38	1,66	18,69	22,33
Al	0,00	4,44	6,09	0,00	7,23	10,66	0,00	7,15	10,56	0,00	7,14	10,45
H+Al	0,11	15,65	21,48	0,41	31,22	37,93	0,35	29,95	36,58	0,35	29,19	35,50
CTC	1,05	9,89	13,89	1,26	10,91	14,87	1,04	9,94	13,73	1,17	10,51	14,07
K	0,01	17,78	23,91	0,02	29,48	40,42	0,02	28,43	39,03	0,02	28,44	40,00
P	1291,48	30,26	41,49	3016,79	48,54	69,19	2864,73	45,89	65,43	2684,17	46,03	66,20
m%	0,71	16,51	19,53	0,79	15,06	18,13	0,71	21,65	20,84	0,39	11,44	9,94
V%	123,79	15,80	12,10	131,99	15,86	13,88	76,05	12,71	9,85	125,90	15,49	12,78
MO	12,85	11,32	14,46	21,11	15,89	20,65	20,34	15,41	20,11	22,79	16,74	21,81
Argila	815,03	7,77	8,91	1830,74	11,56	11,70	1944,41	13,07	12,82	1816,98	11,58	10,85
Silte	502,55	12,88	13,24	1140,70	19,85	19,87	1170,40	19,21	19,78	1166,40	18,87	19,35
Areia	1783,10	5,44	7,25	4852,55	10,09	10,68	4829,61	9,36	9,02	5431,27	10,56	11,27

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

Seguindo critérios de interpretação de Ribeiro et al. (1999) pode-se afirmar que o Potencial Hidrogeniônico ($\text{pH}_{\text{CaCl}_2}$) é bom com acidez média. Resultados semelhantes foram encontrados por Alcântara (2010), Dias (2013) e Carvalho et al. (2002).

A curva de distribuição dos dados se aproxima de uma distribuição normal (Figura 19 c), semelhantes aos resultados de Alcântara (2010) e Dias (2013). Não foi possível estabelecer dependência espacial para o atributo, indicando efeito pepita puro para o pH (Tabela 5).




FIGURA 19. (a) Boxplot; (b) Histograma e (c) Gráfico Densidade: pH.

Na Figura 20 é apresentado o gráfico comparativo entre os valores estimados pela RNA escolhida para o atributo Ca e os valores que foram verificados nas amostras de solo. A melhor estimativa por RNA para o Cálcio utilizou uma amostra de solo relativa (Tabela 7)



FIGURA 20. Gráfico Comparativo Valores estimados RNA x aferidos Ca: (a) 120 PA; (b) C2.

A estimativa realizada pela RNA para o Cálcio (Ca) obteve valor do erro médio relativo para todas amostras igual a 14,15% e 18,49% para o conjunto C2. A divergência é relativa entre as linhas para os valores estimados pela RNA e os valores aferidos nas amostras de solo e ocorreu o acompanhamento da tendência para os valores da plotagem (Figura 20).

O Cálcio (Ca) apresentou CV de 20,51%, média, mediana e moda apresentaram valores próximos. Média foi $4,77 \text{ cmolc dm}^{-3}$, moda e mediana são iguais a $4,80 \text{ cmolc}$

dm^{-3} . O solo da área sob estudo pode ser classificado como muito bom considerando o Ca (RIBEIRO et al., 1999). A assimetria é ligeiramente positiva indicando tendência da distribuição dos dados à esquerda (Tabela 4). A curva de distribuição dos dados se aproxima de uma distribuição normal (Figura 21 c). A análise geoestatística não estabeleceu dependência espacial indicando efeito pepita puro para o atributo (Tabela 5).

A distribuição dos dados do Cálcio (Ca) se ajusta a uma curva normal e foi confirmada utilizando o teste de Shapiro Wilk à 5%, este foi o único atributo de solo considerado na área sob estudo onde a normalidade foi aceita. Dias (2013) verificou distribuição normal para o atributo na área onde realizou seu experimento, verificou CV de 28,07% para o atributo e média de $2,34 \text{ cmolc dm}^{-3}$. Carvalho et al. (2002) constatou CV compatível. Alcântara (2010) CV de 26,83% e media igual a $2,998 \text{ cmolc dm}^{-3}$.




FIGURA 21. (a) Boxplot; (b) Histograma e (c) Gráfico Densidade: Ca.

A Figura 22 apresenta o gráfico comparativo entre os valores estimados pela RNA para o Magnésio (Mg) e os valores obtidos nas amostras de solo. A RNA que obteve melhor índice de acerto para o Magnésio utilizou uma amostra de solo relativa (Tabela 7).




FIGURA 22. Gráfico Comparativo Valores estimados RNA x aferidos Mg: (a) 120 PA; (b) C2.

A análise da RNA para do Magnésio (Mg) obteve valor do P(C) igual a 16,25% e 20,48% para o conjunto C2. Foi nos valores de fronteira onde ocorreu o maior distanciamento entre as linhas de comparação para a estimativa realizada pela RNA selecionada (Figura 22).

O CV calculado para o Mg, 29,49% indicou a variação média deste atributo na área sob estudo, valores semelhantes foram encontrados por Dias (2013), Alcântara (2010) e Carvalho et al. (2002). A mediana e a moda do Mg foram 0,90 enquanto que média calculada foi 0,99 cmolc dm^{-3} (Tabela 4), este valor médio classifica a fertilidade do solo como bom na classe de interpretação de fertilidade para matéria orgânica e para o complexo de troca catiônica (RIBEIRO et al., 1999). A assimetria é positiva indicando tendência da distribuição dos dados à esquerda (Figura 23 c). A análise geoestatística indicou dependência espacial fraca (CAMBARDELLA et al., 1994) com alcance igual a 76,50 metros (Tabela 5).




FIGURA 23. (a) Boxplot; (b) Histograma e (c) Gráfico Densidade: Mg.

O gráfico comparativo apresentado na Figura 24 exibe os valores estimados pela RNA para o Cálcio + Magnésio (Ca+Mg) e os respectivos valores obtidos nas amostras de solo. A melhor assertividade para estimativa do Ca+Mg foi obtida por RNA utilizando uma amostra de solo relativa.




FIGURA 24. Gráfico Comparativo Valores estimados RNA x aferidos Ca+Mg: (a) 120 PA; (b) C2.

Ao analisar os valores estimados pela RNA escolhida para estimar a Ca+Mg pode-se verificar observou-se o P(C) igual a 14,69% e 18,53% para P(C2). A tendência da estimativa da RNA foi mantida, em algumas amostras ocorreu relativo distanciamento entre os valores (Figura 24).

O coeficiente de variação calculado para as amostras foi igual a 21,38%, a média, mediana e moda apresentam valores próximos, a média e mediana diferem entre si menos de 2% (Tabela 4). A distribuição dos dados é próxima à uma distribuição normal (Figura 25 c). Não foi detectada dependência espacial para este atributo (Tabela 5).




FIGURA 25. (a) Boxplot; (b) Histograma e (c) Gráfico Densidade: Ca+Mg.

A Figura 26 mostra o gráfico comparativo dos valores pela RNA escolhida para estimar os valores do Alumínio (Al) em comparação com os valores das amostras de solo coletadas. A estimativa do Alumínio foi feita pela RNA utilizando uma amostra de solo relativa, sendo esta a que obteve maior acurácia (Tabela 7).




FIGURA 26. Gráfico Comparativo Valores estimados RNA x aferidos Al: (a) 120 PA; (b) C2.

O Alumínio apresentou poucas amostras com valores diferentes de zero (Figura 27). O Alumínio trocável apresenta prejuízo ao desenvolvimento de um grande número de culturas (ALCÂNTARA, 2010). Na área sob estudo, foi classificado como muito baixo (RIBEIRO et al., 1999). A precisão analítica para detectar teores de Al no solo

poderia explicar a grande quantidade de amostras com valor igual à zero (ALCÂNTARA, 2010). Semelhanças foram observadas por Castro (2004) e Valente (2010).

A estimativa da RNA escolhida conseguiu realizar essa previsão dessas ocorrências (Figura 26). O CV do Alumínio foi alto, valor superior a 392% apesar da mediana ser igual a moda (0,00) e próxima da média (0,01) (Tabela 4). Os valores do P(C) e P(C2) foram respectivamente iguais a 4,09% e 5,87%. Foi detectada dependência espacial fraca para o Al, IDE 84,4%. O alcance calculado foi igual 84,6 metros (Tabela 5).

O Alumínio apresentou efeito pepita puro na área sob estudo. Resultado semelhante foi encontrado por REIS (2011) e DIAS (2013).




FIGURA 27. (a) Boxplot e (b) Histograma: Al.

A análise comparativa da Acidez potencial (H+Al) nos pontos amostrais e os aferidos pela RNA selecionada pode ser verificada na Figura 28. A RNA selecionada para estimativa do atributo foi a que utilizou uma amostra relativa.



FIGURA 28. Gráfico Comparativo Valores estimados RNA x aferidos H+Al: (a) 120 PA; (b) C2.

A análise apresentada pelos valores da RNA escolhida para estimar a Acidez Potencial (H+Al) resultou em P(C) igual a 15,65% e 21,48% consecutivamente para todas amostras e conjunto C2. A tendência das linhas estimadas e aferidas foram mantidas. Os valores estimados pela RNA selecionada acompanharam as variações dos valores aferidos (Figura 28).

O CV calculado do atributo foi igual a 27,05%, mediana e moda apresentaram o valor de 1,60 cmolc dm^{-3} . A média foi 1,73 cmolc dm^{-3} , valor que atribui ao solo sob estudo a classificação de baixa Acidez Potencial (RIBEIRO et al., 1999). Valores médios classificação de solo semelhante foi observada por Alcântara (2010) e Dias (2013). A distribuição dos dados apresentou curva leptocúrtica, assimetria positiva com variação tendendo à esquerda (Figura 29 c). Houve ocorrência de valores *outlier* que não foram retirados para análise geoestatística e/ou treinamento das RNAs.

A Acidez Potencial apresentou efeito pepita puro (Tabela 5), mesmo resultado de Reis (2011). Alcântara (2010) verificou ocorrência de dependência espacial em seu experimento. Dias (2013) não observou dependência espacial para Acidez Potencial no estudo por ele realizado.




FIGURA 29. (a) Boxplot; (b) Histograma e (c) Gráfico Densidade: H+Al.

A Figura 30 apresenta o gráfico comparativo entre os valores estimados pela RNA para a Capacidade de Troca Catiônica (CTC) e os valores nos respectivos pontos amostrais. Este atributo foi, dentro os atributos considerados, o único que apresentou melhor estimativa da RNA utilizando três pontos amostrais relativos.




FIGURA 30. Gráfico Comparativo Valores estimados RNA x aferidos CTC: (a) 120 PA; (b) C2.

A estimativa realizada pela RNA escolhida para o atributo CTC apresentou P(C) igual a 10,51% e P(C2) igual a 14,07% com tendência de manutenção da estimativa da RNA (Figura 30).

A média $7,96 \text{ cmolc dm}^{-3}$ foi menor que a mediana $8,00 \text{ cmolc dm}^{-3}$ e menor que a moda $8,20 \text{ cmolc dm}^{-3}$. Por esse valor, o solo sob estudo pode ser classificado como de média Capacidade de Troca Catiônica (RIBEIRO et al., 1999).

O CV foi igual à 13,92% (Tabela 4) indicando variação média (WARRICK E NIELSEN, 1980). O atributo apresentou dados *outlier* que foram mantidos nas análises e procedimentos realizados. A distribuição de dados se aproxima de uma distribuição normal (Figura 31 c), com a tendência dos valores à esquerda da curva de assimetria positiva 0,7643 e distribuição leptocúrtica (Figura 31).




FIGURA 31. (a) Boxplot; (b) Histograma e (C) Gráfico Densidade: CTC.

Foi verificada dependência espacial fraca para o Capacidade de Troca Catiônica (CTC) conforme classificação proposta por Cambardella et al. (1994) e alcance de 70,20m (Tabela 5).

A comparação entre os valores obtidos utilizando a RNA treinada para o atributo K e os valores verificados nas amostras de solo pode ser visualizada na Figura 32.




FIGURA 32 - Gráfico Comparativo Valores estimados RNA x aferidos K: (a) 120 PA; (b) C2.

A rede neural escolhida para estimar a variabilidade espacial do atributo K obteve a melhor performance utilizando um ponto amostral relativo. A RNA apresentou a segunda maior taxa de erro média percentual, sendo 17,78% para o conjunto de todas amostras e 23,91% para o conjunto C2. A tendência da estimativa da RNA escolhida é

mantida para os pontos analisados, entretanto a análise do gráfico (Figura 32) é verificada a relativa diferença dos valores.

O CV do atributo foi igual a 24,69%, média variação conforme Warrick e Nielsen (1980). A média foi de 0,48 cmolc dm⁻³ menor que mediana 0,51 cmolc dm⁻³ e menor que moda 0,61 cmolc dm⁻³ (Tabela 4) e assimetria na distribuição dos dados negativa (Figura 33 c). Não foi detectada dependência espacial para o Potássio (K) (Tabela 5).

O cultivo intensivo e uso incorreto, ou mesmo indiscriminado de fertilizantes levam a acentuadas variações nos teores de nutrientes encontrados no solo em uma determinada área (WERNER, 2004). Os valores de P e K são os de variabilidade mais elevada (PONTELLI, 2006; MACHADO et al., 2007).




FIGURA 33. (a) Boxplot; (b) Histograma e (c) gráfico densidade K.

O Erro médio relativo da RNA escolhida para realizar a estimativa do Fósforo (P) apresentou a pior performance dentre os atributos considerados. O menor erro de estimativa foi obtido utilizando uma amostra relativa (Figura 34).




FIGURA 34. Gráfico Comparativo Valores estimados RNA x aferidos P: (a) 120 PA; (b) C2.

O valor do P(C) para o P foi igual a 30,26% e 41,49% para o conjunto de dados C2. É possível verificar que os valores estimados pela RNA e aferidos das amostras de

solo seguem a mesma tendência indicada, porém, os valores aferidos distam dos valores estimados (Figura 34).

O coeficiente de variação foi calculado em 46,15%, o terceiro maior CV dentre os atributos considerados. A média 105,83 foi maior que a mediana 90 e maior que a moda 70 (Tabela 4), indicando assimetria positiva. A tendência da curva de distribuição de dados foi leptocúrtica (Figura 35). Este atributo, na área sob estudo, apresentou efeito pepita puro (Tabela 5) não indicando ocorrência de dependência espacial.




FIGURA 35. (a) Boxplot; (b) Histograma e (c) Gráfico densidade: P.

Assim como aconteceu com o Alumínio, apenas algumas ocorrências de valores para o Saturação por Alumínio (m%) foram diferentes de zero (Figura 37). O P(C) na estimativa da RNA escolhida para o referido atributo foi igual a 3,60% e 5,15% respectivamente para o conjunto de todas amostras e conjunto C2. A RNA conseguiu estimar as ocorrências de valores diferentes de zero (Figura 36). A maior assertividade para estimativa da Saturação por Alumínio (m%) foi obtida com 4 amostras de solo relativas.




FIGURA 36. Gráfico Comparativo Valores estimados RNA x aferidos m%: (a) 120 PA; (b) C2.

O atributo Saturação por Alumínio (m%) foi o que apresentou o maior CV, foi verificado uma variação de 423%, alta variabilidade conforme classificação adotada por Warrick e Nielsen (1980). A mediana e a moda foram iguais 0,00 cmolc dm^{-3} , a média

0,19 cmolc dm⁻³ e assimetria positiva 5,38 (Tabela 4). Valores semelhantes foram encontradas por Castro (2004). Não foi possível gerar gráfico densidade para o atributo (Figura 37).

O modelo de semivariograma que melhor se ajustou ao estudo da variabilidade espacial do atributo foi exponencial, foi detectada dependência espacial média para este atributo conforme classificação proposta por Cambardella et al. (1994), IDE de 50% e alcance de 204,90 metros (Tabela 5).




FIGURA 37. (a) Boxplot e (b) Histograma: m%.

A Figura 38 apresenta o gráfico comparativo dos valores estimados pela RNA Seleccionada *versus* os valores da Saturação por Bases (V%) nos pontos amostrais. A melhor acurácia foi atingida com a RNA utilizando 3 pontos amostrais relativos, apresentou P(C) igual à 12,70% considerando todas amostras e 9,85% para o conjunto de amostras C2.

Foi verificado existência de valores *outliers* para Saturação por Bases (V%) (Figura 39). A estimativa da RNA selecionada divergiu com maior intensidade para esses valores, fato pelo qual o erro médio relativo foi menor para o conjunto de dados C2 (Figura 38).




FIGURA 38. Gráfico Comparativo Valores estimados RNA x aferidos V%: (a) 120 PA; (b) C2.

A Saturação por Bases é um indicador de fertilidade do solo, o percentual médio calculado na área sob estudo foi de 77,79 %, valor próximo a mediana e pouco menor que a moda. Solos que apresentam média de Saturação por Bases entre 60,1% a 80,0% são solos férteis (RIBEIRO et al.,1999).

O CV foi igual a 9,07%, a distribuição dos valores apresentou assimetria negativa com tendência dos dados a direita (Tabela 4). O resultado compatível do CV foi apresentado por Alcântara (2010) com média igual a 65,113%. Dias (2013) indicou CV igual a 56,46% para o atributo. A curva de distribuição é próxima a uma curva normal (Figura 39 c). Não foi detectada dependência espacial para o atributo na área sob estudo (Tabela 5).




FIGURA 39. (a) Boxplot; (b) Histograma e (c) Gráfico Densidade: V%.

A tendência dos valores estimados pela RNA selecionada *versus* os aferidos nas amostras de solo para Matéria Orgânica é mantida, contudo as amostras com valores mais altos apresentam erro maior na estimativa da rede (Figura 40).




FIGURA 40. Gráfico Comparativo Valores estimados RNA x aferidos MO: (a) 120 PA; (b) C2.

A RNA selecionada para estimar MO obteve melhor performance com uma amostra de solo relativa, obteve valores de P(C) iguais a 11,32% considerando os 120 pontos amostrais e 14,46% para as amostras do conjunto C2.

O coeficiente de variação deste atributo foi 17,54%, mediana e moda iguais a 23 e média com valor próximo 23,883 apresentando assimetria positiva 0,9928 (Tabela 4;

Figura 41). Valores próximos foram encontrados por Dias (2013). Alcântara (2010) verificou valores mais altos assim como Castro (2004) enquanto que em Valente (2010) os valores foram menores.

O semivariograma esférico foi o que melhor se ajustou ao atributo, a dependência espacial verificada foi fraca, IDE calculado de 99% e alcance de 69,30m (Tabela 5)




FIGURA 41. (a) Boxplot; (b) Histograma e (c) Gráfico Densidade: MO.

A Argila atingiu, dentre os atributos considerados, um dos melhores resultados para estimativa realizadas por RNA (Tabela 7). A maior assertividade dentre as redes treinadas para estimar a Argila foi obtida utilizando uma amostra de solo relativa. Apresentou os seguintes resultados: P(C) igual à 7,77% e P(C2) igual à 8,91%. O gráfico comparativo dos valores (Figura 42) confirma a proximidade entre os valores aferidos e os estimados pela RNA.




FIGURA 42. Gráfico Comparativo Valores estimados RNA x aferidos Argila: (a) 120 PA; (b) C2.

O CV da Argila foi médio (WARRICK E NIELSEN, 1980), o valor calculado foi igual a 14,94%. A moda e mediana tiveram o mesmo valor, 250 g kg⁻¹, enquanto que a média foi maior, 268,42 g kg⁻¹ (Tabela 4), indicando assimetria positiva na distribuição dos dados (Figura 43 c). Valores semelhantes foram encontrados por Dias (2013) e Alcântara (2010).

A variabilidade espacial dos atributos físicos do solo: areia, silte e argila, têm sido citadas dentre as características físicas do solo, como as de menor variação (AMARO et al., 2007).

Na análise geoestatística realizada o modelo de semivariograma exponencial foi o melhor se ajustou para o semivariograma do atributo. A dependência espacial detectada foi fraca conforme sugestões de Cambardella et al. (1994), IDE de 89% com alcance de 57,30 metros (Tabela 5).




FIGURA 43. (a) Boxplot; (b) Histograma e (c) Gráfico Densidade: Argila.

A RNA Selecionada que realizou a melhor estimativa para o Silte obteve o melhor resultado com uma amostra de solo relativa. O erro médio relativo foi igual à 12,88% em relação aos 120 pontos amostrais e 13,24% para o conjunto C2. Em algumas amostras ocorre variação, porém a tendência dos resultados se mantém (Figura 44).




FIGURA 44. Gráfico Comparativo Valores estimados RNA x aferidos Silte: (a) 120 PA; (b) C2.

O CV para Silte foi 20,24%, variação média segundo classificação proposta por Warrick e Nielsen (1980). A mediana e moda foram iguais 150 g kg^{-1} , a média calculada de $147,42 \text{ g kg}^{-1}$ e a assimetria positiva 0,2897 conforme (Tabela 4).

A análise do *boxplot* e histograma indica possível tendência a distribuição normal (Figura 45). Não foi verificada dependência espacial para o Silte (Tabela 5 b).




FIGURA 45. (a) Boxplot, (b) Histograma e (c) Gráfico Densidade: Silte.

A RNA selecionada para realizar a estimativa da variabilidade espacial da Areia apresentou a segunda melhor performance geral entre os atributos analisados, ao comparar as linhas de valores estimados pela RNA e aferidos nas amostras (Figura 46) pode-se verificar essa tendência de acerto. A rede neural artificial selecionada para realizar a estimativa da Areia que atingiu o melhor índice de acerto utilizou uma amostra de solo relativa. O P(C) foi 5,44% considerando os 120 pontos amostrais e 7,25% considerando as amostras do conjunto C2.




FIGURA 46. Gráfico Comparativo Valores estimados RNA x aferidos Areia: (a) 120 PA; (b) C2.

O CV de 10,83% da Areia foi um dos mais baixos dentre os atributos analisados. Indicando variação baixa para este atributo segundo classificação proposta por Warrick e Nielsen (1980). A moda e mediana iguais a 600 g kg^{-1} , a média verificada foi igual à $584,17 \text{ g kg}^{-1}$ (Tabela 4). A distribuição de dados apresentou assimetria negativa (Figura 47 c) com ocorrência de valores *outlier* que foram mantidos na execução dos procedimentos realizados neste trabalho. Dias (2013) relata valores semelhantes em seu trabalho.

Não foi verificada dependência espacial para Areia (Tabela 5).




FIGURA 47. (a) Boxplot; (b) Histograma e (c) Gráfico Densidade: Areia.

4.5. Comparação das estimativas RNAs versus da geoestatística

Foram estimados os valores dos 120 pontos amostrais utilizando a Krigagem ordinária na geoestatística e as 4 RNAs selecionadas para cada atributo de solo que apresentou dependência espacial dentre os atributos considerados. O objetivo foi comparar os valores verificados nas amostras de solo e os estimados. A Tabela 8 apresenta o resumo do erro médio calculado (Figura 48) e as tabelas de 9 até 13 a análise individual do erro calculado para cada ponto amostral (Apêndice E).

TABELA 8. Resumo do erro médio relativo (%) entre valores aferidos e estimados pela Krigagem ordinária e redes neurais artificiais.

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

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

Somente a Capacidade de Troca Catiônica (CTC) foi melhor estimada pela Krigagem ordinária onde obteve erro médio igual a 9,29%, mas a estimativa realizada pela RNA utilizando um ponto amostral atingiu erro médio próximo, igual à 9,89%. É importante reforçar que para realizar a Krigagem foram utilizadas 120 amostras de solo e a RNA após o treinamento e seleção utilizou apenas uma.

As estimativas do Magnésio (Mg), Matéria orgânica (MO) Saturação por Alumínio (m%) e Argila foram melhores com o uso das respectivas redes neurais

artificiais selecionadas. As estimativas do Mg, MO e Argila tiveram menor erro médio relativo utilizando RNAs com um ponto amostral relativo. A Saturação por Alumínio (m%) atingiu o melhor resultado de estimativa com RNA utilizando quatro pontos amostrais relativos.

O valor do erro médio das estimativas efetuadas pelas redes neurais foi mais baixo em 4 atributos de solo dentre os 5 comparados (Figura 48).




FIGURA 48. Gráfico comparativo dos valores do erro médio das estimativas por krigagem e RNAs selecionadas.

Os resultados do teste-t realizado entre os valores de cada atributo que apresentou dependência espacial nos 120 pontos amostrais e os valores estimados pela Krigagem ordinária e pelas quatro redes neurais artificiais selecionadas indicaram que ocorre diferença somente para estimativa da Matéria Orgânica realizada pela RNA selecionada que utilizou 4 pontos amostrais relativos, as demais estimativas não apresentaram diferença (Tabela 9).

TABELA 9. Teste-t para comparação de cada média estimada com a média dos dados originais considerando os valores dos 120 pontos amostrais.

Atributo	Média	Média KO	Média RNA 1AR	Média RNA 2AR	Média RNA 3AR	Média RNA 4AR
Mg	0,991	0,992 (t = - 0,0451; p-value = 0,9641)	1,000 (t = - 0,2758; p-value = 0,7829)	1,018 (t = - 0,9598; p-value = 0,3381)	1,043 (t = - 1,7401; p-value = 0,0831)	1,045 (t = - 1,8787; p-value = 0,0615)
CTC	7,963	7,966 (t = - 0,0177; p-value = 0,9859)	7,941 (t = 0,2104; p-value = 0,8336)	8,006 (t = - 0,3966; p-value = 0,6920)	7,976 (t = - 0,1140; p-value = 0,9093)	8,013 (t = - 0,4509; p-value = 0,6525)
m%	0,175	0,171 (t = 0,0496; p-value = 0,9605)	0,098 (t = 1,0235; p-value = 0,3071)	0,084 (t = 1,3030; p-value = 0,1938)	0,150 (t = - 0,3177; p-value = 0,7510)	0,149 (t = 0,3393; p-value = 0,7347)
MO	23,883	23,880 (t = 0,0057; p-value = 0,9954)	24,097 (t = - 0,4291; p-value = 0,6682)	24,651 (t = - 1,7584; p-value = 0,0800)	24,315 (t = - 1,0158; p-value = 0,3107)	24,804 (t = - 2,0708; p-value = 0,0395)
Argila	268,42	268,29 (t = 0,0271; p-value = 0,9784)	268,18 (t = 0,0519; p-value = 0,9587)	266,30 (t = 0,5645; p-value = 0,5729)	266,34 (t = 0,5357; p-value = 0,5926)	268,23 (t = 0,0498; p-value = 0,9603)

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

5. CONCLUSÕES

Com base nos resultados pode-se concluir que:

- Foi possível gerar os programas e a modelagem de informações necessária para o treinamento de redes neurais artificiais e posterior utilização destas para realizar a estimativa da variabilidade espacial dos atributos de solo na área sob estudo.

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

- Considerando as comparações entre os valores estimados pelas RNAs selecionadas e os valores de cada atributo sob estudo nos 120 pontos amostrais, cinco atributos de solo foram estimados com erro menor que 8%, seis atributos com erro entre 9% a 15%, três atributos com erro entre 15% a 18% e um atributo com erro igual à 30,26%.

- Cinco atributos apresentaram dependência espacial na análise geoestatística. Quatro: Magnésio (Mg), Matéria orgânica (MO) Saturação por Alumínio (m%) e Argila foram melhores estimados com o uso das respectivas redes neurais artificiais selecionadas do que utilizando Krigagem ordinária.

- As estimativas do Mg, MO e Argila tiveram menor erro médio em relação às RNAs com um ponto amostral relativo. A Saturação por Alumínio (m%) atingiu o melhor resultado de estimativa com RNA utilizando quatro pontos amostrais relativos enquanto que para realizar Krigagem ordinária foram utilizados os 120 pontos amostrais.

- A estimativa da Capacidade de Troca Catiônica (CTC) apresentou melhor resultado utilizando Krigagem ordinária, entretanto a diferença no percentual de erro foi de 0,5% desfavorável à RNA selecionada empregando somente um ponto amostral.

6. SUGESTÕES PARA TRABALHOS FUTUROS

- I. Aplicar as redes que foram selecionadas para realizar estimativa dos atributos de solo em outro local com objetivo de validar ou não os resultados encontrados nesta pesquisa e a capacidade de generalização das redes treinadas.
- II. Buscar determinar alcance de área para as redes selecionadas com objetivo de indicar distância máxima e distâncias ideais para obter os dados das amostras de solo relativas.
- III. Obter dados de outra área amostral para realizar novo treinamento e análise de resultados. O treinamento pode ser feito somente com o(s) novo(s) conjunto(s) de dados, assim como utilizar informações de diferentes áreas amostrais em apenas um conjunto de dados.
- IV. Realizar treinamento e análise de resultados empregando funções de ativação diferentes assim como outros algoritmos de aprendizado.
- V. Utilizar outras topologias de redes neurais, como por exemplo: aumentar número de neurônios e/ou camadas escondidas.
- VI. Treinar e avaliar redes neurais empregando diferentes arquiteturas como as RNAs recorrentes, RNAs de Hopfield e RNAs *Deep Learning*, RNAs *Quantum weightless*.
- VII. Empregar coordenadas polares e verificar se há alteração na qualidade dos resultados estimados.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- ALCÂNTARA, G. R. **Variabilidade espacial de características físico-químicas e condutividade elétrica aparente do solo sob plantio**. 2010. 89 p. Dissertação Mestrado em Engenharia Agrícola - Universidade Estadual de Goiás. Anápolis, 2013. Disponível em: <http://www.unucet.ueg.br/biblioteca/arquivos/DISSERTAAfO_GRACIELLY.pdf>. Acesso em: 15 Fev 2016.
- AMARO, J. F.; NEGREIROS, R. F. D. D.; ASSIS JÚNIOR, R. N. Amostragem e variabilidade espacial de atributos físicos de um Latossolo vermelho em Mossoró, RN. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 31, p. 415-422, 2007.
- ANDRADE, A. G. D. **Estatística espacial e redes neurais aplicadas no estudo de epidemias de huanglongbing e mancha preta na cultura dos citros**. 2008. 94 p. Tese Doutorado em Agronomia, Universidade Estadual Paulista. Jaboticabal, 2008. Disponível em: <<http://www.fcav.unesp.br/download/pgtrabs/pv/d/2265.pdf>>. Acesso em 04 Abr 2015.
- ANDRADE, L. N. **Redes Neurais Artificiais (RNA) para Identificação De Áreas Cafeeiras Em Imagens De Satélite: Treinamento e Definição De Arquiteturas**. 2011. 87 p. Dissertação de mestrado em Ciência da Computação - Universidade Federal de Minas Gerais, 2011. Belo Horizonte. Disponível em: <<http://www.dcc.ufmg.br/pos/cursos/defesas/1361M.PDF>>. Acesso em: 04 Abr 2015.
- ANGELICO, J. C. **Desempenho Das Redes Neurais Artificiais Na Estimativa das Variáveis Físicas e Químicas do Solo**. 2005. 160 f. Tese Doutorado em Agronomia - Faculdade de Ciências Agrônomicas da UNESP, 2005. Botucatu. Disponível em : <<http://hdl.handle.net/11449/101867>>. Acesso em 30 Nov 2014.
- ANGELICO, J. C.; SILVA, I.N. Redes neurais artificiais aplicadas na estimativa da variabilidade de atributos do solo, SP. **Revista Científica FACOL/ISEOL**, São Paulo, v. 1, p. 9-20, 2014. ISSN on line 2359-0645. Disponível em <http://www.facol.br/integrada/ed001_2014/v1_n1_2014-art01_ANGELICO.pdf>. Acesso em 05 Jan 2015.
- BERVEGLIERI, A.; MENEGUETTE Junior, M.; PITERI, M. A. **Aplicação do interpolador krigagem em modelos digitais de terrenos comparando-se os casos de isotropia e anisotropia**. In: Anais Simpósio Brasileiro de Sensoriamento Remoto, 15. SBSR, Curitiba: INPE, 2011, p.7222-7229
- BOLFE, E. L.; GOMES, J. B. V.; FONTES, H. R. **Variabilidade espacial de atributos do solo como subsídio para para produção integrada de frutas em perímetro irrigado no nordeste do Brasil**. INPE. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13. Anais.. . Florianópolis: INPE, 2007. p. 67-74. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.03.13.55/doc/67-74.pdf>>. Acesso em 29 Mar 2015.

BRAGA, A. D. P.; CARVALHO, A. P. D. L. F. D.; LUDERMIR, T. B. **Redes Neurais Artificiais - Teoria e Aplicações**. 2ª. ed. Rio de Janeiro: LTC, 2012. 226p.

CAMBARDELLA, C.A.; MOORMAN, T.B.; NOVAK, J.M.; PARKIN, T.B.; KARLEN, D. L.; TURCO, R.F.; KONOPKA, A.E. Field-scale variability of soil properties in central Iowa soils. **Soils Science Society of America Journal**, v.58, p. 1501-11, 1994.

CANTARUTTI, R.B.; ALVAREZ V., V.H.; RIBEIRO, A.C. **Amostragem do solo**. In: RIBEIRO, A. C.; GUIMARÃES, P. T. G.; ALVAREZ V., V. H. (Ed.). **Recomendação para o uso de corretivos e fertilizantes em Minas Gerais: 5. Aproximação**. Viçosa: Comissão de Fertilidade do Solo do Estado de Minas Gerais, 1999. p.13-24.

CARVALHO, J. R. P., SILVEIRA, P. M. VIEIRA, S.R. Geoestatística na determinação da variabilidade espacial de características químicas do solo sob diferentes preparos. **Pesquisa Agropecuária Brasileira**, Brasília, v. 37, n. 8, p. 1151-1159, 2002. ISSN on-line 1678-3921.

CARVALHO, L. C. C.; SILVA, F. M.; FERRAZ, G. A. e S.; SILVA F. C. Análise Espacial do Teor de Argila e Umidade Gravimétrica, em Diferentes Camadas de Profundidade, em um Latossolo Vermelho Distrófica. **Nucleus**, Ituverava, v. 11, p. 379-384, 2014. ISSN 1982-2278. Disponível em: <<http://www.nucleus.feituverava.com.br/index.php/nucleus/article/view/1036/1632>>. Acesso em: 18 Abr 2015.

CASTRO, C. N. **Definição de unidades de gerenciamento do solo por meio da sua condutividade elétrica e variáveis físico-químicas**. Piracicaba. 2004. 131p. Dissertação de Mestrado em Máquinas Agrícolas – Escola Superior de Agricultura Luiz de Queiroz. 2004. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/11/11148/tde-27092004-155540/>>. Acesso em: 15 Fev 16.

CAVALCANTE, E. G. S.; ALVES, M. C.; SOUZA, Z. M.; PEREIRA, G. T. Variabilidade espacial de atributos químicos do solo sob diferentes usos e manejos. **Revista Brasileira de Ciência do Solo**. v.31, p.1329-1339, 2007.

COELHO, A. M. **Agricultura de Precisão: manejo da variabilidade espacial e temporal dos solos e culturas**. 1ª. ed. Sete Lagoas: Embrapa Milho e Sorgo, 2005. ISBN 1518-4277. Disponível em: <http://ainfo.cnptia.embrapa.br/digital/bitstream/CNPMS/18887/1/Doc_46.pdf>. Acesso em: 22 Jan 2015.

COUTO, R.F. **Variabilidade espacial de atributos físicos de um solo sob Sistema de Plantio Direto**. 2010. 49p. Monografia (Bacharel em Engenharia Agrícola) - universidade Estadual de Goiás, Anápolis-GO, 2010.

CRESSIE, N. **Statistics for spatial data**. New York, John Willey & Sons Inc, 1991. 887p.

- CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics of Control, Signals, and Systems**. New York. Springer-Verlag. 1989. 303-314p.
- DIAS, D. N. **Identificação dos sintomas de ferrugem em áreas cultivadas com cana-de-açúcar**. 2004. 110 p. Dissertação Mestrado em Ciências (computação e matemática aplicada) - Universidade de São Paulo. São Carlos, 2004. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/55/55134/tde-19052004-134621/publico/TDE-19052004-134621.pdf>>. Acesso em: 05 Abr 2015.
- DIAS, J. M. S. **Distribuição espacial das características físicas e químicas do solo de cerrado utilizando krigagem indicativa**. 2013. 80 p. Dissertação Mestrado em Engenharia Agrícola - Universidade Estadual de Goiás. Anápolis, 2013. Disponível em: <http://www.unucet.ueg.br/biblioteca/arquivos/MARCIO_JOSE_DIAS.pdf>. Acesso em: 30 Nov 2014.
- FACELLI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. L. F. C.. **Inteligência Artificial: Uma abordagem de Aprendizado de Máquina**. Rio de Janeiro: LTC, 2011. 378 p. ISBN 978-85-216-1880-5.
- FILHO, J. A.; DELMIRO DE NEGREIROS, R. F.; ASSIS JUNIOR, R.N. MOTA, J. C. Amostragem e variabilidade espacial de atributos físicos de um latossolo vermelho em mossoró, RN. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 31, p. 215-422, 2007.
- FILHO, R. S. **Diagnóstico da agricultura de precisão no sudoeste do estado de Goiás**. 2014. 110 p. Tese Doutorado em Agronomia - Universidade Federal de Uberlândia, Uberlândia, 2014. Disponível em: <<http://repositorio.ufu.br/bitstream/123456789/4116/1/DiagnosticoAgriculturaPrecisao.pdf>>. Acesso em: 25 Abr 2015.
- GALO, M. D. L. B. T.; FERREIRA, M. S.; UTSUMI, A. G. **Utilização da Geoestatística e Redes Neurais Artificiais na inferência espacial de fitoplâncton em estágios iniciais de floração**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, 16. Anais.. . Foz do Iguaçu - PR: INPE. 2013. p. 6799-6806.
- GENÚ, A. M. **GEOESTATÍSTICA MULTIVARIADA**. ESCOLA SUPERIOR DE AGRICULTURA “LUIZ DE QUEIROZ”. Piracicaba, p. 0-17. 2004. Disponível em : <<http://www.lce.esalq.usp.br/tadeu/aline.pdf>>. Acesso em 29/11/2014.
- GONÇALVES, A.C.; FOLEGATTI, M. V; VIANA DA MATA, J. D. Análises exploratória e geoestatística da variabilidade de propriedades físicas de um Argissolo Vermelho. **Acta Scientiarum**, Maringá, v. 23, n. 5, p. 1149-1157, 2001.
- GREGO, C. R.; VIEIRA, S. R. Variabilidade Espacial de Propriedades Físicas do Solo em uma Parcela Exeperimental. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 29, p. 169-177, 2005.
- HAYKIN, S. S. **Redes Neurais – Princípios e Práticas**. 2ª. ed. Porto Alegre: Bookman, 2001. 900 p.

ISAAKS, E.H.; SRIVASTAVA, R.M. **An introduction to applied geoestatistic**. New York, Oxford University Press, 1989. 561p.

KOVÁCS Z. L. **Redes Neurais Artificiais Fundamentos e Aplicações**. 4ªed. São Paulo: Livraria da Física, 2006. 174p.

LANDIM, P. M. B. **Análise estatística de dados geológicos**. 2ª. ed. São Paulo: UNESP, 2003. 215 p.

LIMA I. L.; SANTOS F. A. O; PINHEIRO C. A. M. . **Inteligência Artificial**. 1ª. ed. Rio de Janeiro: Elsevier, 2014. 173 p.

MACHADO, L. O.; LANA, A. M. Q.; LANA, R. M. Q.; GUIMARÃES, E. C.; FERREIRA, C. V. Variabilidade espacial de atributos químicos do solo em áreas sob sistema plantio convencional. **Revista Brasileira de Ciência do Solo**. v.31, p.591-599, 2007.

MOLIM J.P.; CASTRO C.N.; Establishing management zones using soil electrical conductivity and other soil properties by the fuzzy clustering technique. **Revista Scientia Agricola**, Piracicaba, v.65, n.6,. p.567-573. 2008. ISSN 1678-992X (on-line). Disponível em < <http://www.scielo.br/pdf/sa/v65n6/01.pdf>>. Acesso em: 13 Dez 2015.

NÄÄS, I. D. A.; CAMPOS, L. S. L. ; BARACHO, M. S.; TOLON, Y. B. Uso De Redes Neurais Artificiais Na Identificação De Vocalização De Suínos. **Revista Engenharia Agrícola**, Jaboticabal, v. 28, n.2., p. 204-216. 2008. ISSN 1809-4430 (on-line). Disponível em: <<http://www.scielo.br/pdf/eagri/v28n2/a01v28n2.pdf>>. Acesso em: 04 Abr 2015.

NOROUZI, M.; YOUNI, S. A; JALALIAN A., KHADEMI, H.; DEHGNANI & A.A. Predição da qualidade e quantidade do trigo de sequeiro utilizando rede neural artificial usando características de terreno e solo. **Acta Agriculturae Scandinavica. Section B. Soil and Plant Science**. v.60, n.4., p.341-353. 2010. ISSN1651-1913 (on-line). Disponível em: <<http://www.tandfonline.com/doi/full/10.1080/09064710903005682#abstract>>. Acesso em: 15 Set 2015.

PADILHA, F. R. R.; KHATCHATOURIAN, O. Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. **Revista Engenharia Agrícola**, Jaboticabal, v. 28, p. 759-769, 2008. ISSN 1809-4430 (on-line). Disponível em: <http://www.scielo.br/scielo.php?pid=S0100-69162008000400016&script=sci_arttext>. Acesso em: 04 Abr 2015.

PATERNIANI, E. Agricultura sustentável nos trópicos. **Estudos Avançados**, São Paulo, v. 15, n. 43, p. 303-326, 2001. ISSN 1806-9592 (on-line). Disponível em: <<http://dx.doi.org/10.1590/S0103-40142001000300023>>. Acesso em: 30 Jan 2016.

PERISSINOTO, M. **Sistema inteligente aplicado ao acionamento do sistemas de climatização em instalações para bovinos leiteiros**. 2007. 167 p. Tese Doutorado em Agronomia - Universidade de São Paulo - Escola Superior de Agricultura Luiz de Queiroz. Piracicaba. Disponível em :

<<http://www.teses.usp.br/teses/disponiveis/11/11131/tde-04032008-181236/publico/mauricioperissinotto.pdf>>. Acesso em: 03 Feb 2015.

PONTELLI, C. B. **Caracterização da variabilidade espacial das características químicas do solo e da produtividade das culturas utilizando as ferramentas da agricultura de precisão**. Santa Maria, 2006. 110p. Dissertação de Mestrado em Engenharia Agrícola - Universidade Federal de Santa Maria. 2006.

REICHARDT, K; TIMM L.C. **Solo, planta e atmosfera - conceitos, processos e aplicações**. 2ª. ed. Barueri, SP: Manole, 2012. 524 p.

REIS, J. D. S. **Determinação de zonas de manejo para adubação nitrogenada em lavoura de tomate industrial**. 2011. 67 p. Dissertação Mestrado em Engenharia Agrícola - Universidade Estadual de Goiás. Anápolis, 2011. Disponível em: <http://www.unucet.ueg.br/biblioteca/arquivos/DISSERTAA%C2%87A%C2%83O__JACQUELINE.pdf>. Acesso em: 30 Nov 2014.

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.

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

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.

SÁRKÖZY, F. **Gis functions - Interpolation**. *Periodica Polytechnica Ser. Civ. Eng.*, 43: 63-86, 1999.

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. ISSN 1982-2170 (on-line). Disponível em: <<http://dx.doi.org/10.1590/S1982-21702014000400043>>. Acesso em 31 Jan 16

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, F. M.; SOUZA, Z. M.; FIGUEIREDO, C. A. P.; VIEIRA, L. H. S.; OLIVEIRA, E. Variabilidade espacial de atributos químicos e produtividade da cultura do café em duas safras agrícolas. **Ciência Agrotecnologia**, Lavras, v. 32, n.1, p.231-241, 2008.

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

SILVA, S.A.; QUARTEZANI W.Z.; ZIMBACK C.R.; LANDIM P.M. **Aplicação da Geoestatística em Ciências Agrárias: parte I**. Botucatu, v. 1, 2011.

SIQUEIRA, G.M.; VIEIRA S. R.; CEDDIA, M. B. Solo e Nutrição de Plantas. Variabilidade de atributos físicos do solo determinados por métodos diversos. **Bragantia**, Campinas v.67, n.1, p. 203-211, 2008.

<<http://www.scielo.br/pdf/brag/v67n1/a25v67n1.pdf>>. Acesso em: 27 Dez 2015.

SILVA, V. R.; REICHERT, J. M.; STORCK, L.; FEIJÓ, S. Variabilidade espacial das características químicas do solo e produtividade de milho em um Argissolo Vermelho-Amarelo distrófico arênico. **Revista Brasileira de Ciência do Solo**. v.27, p.1013-1020, 2003.

TUKEY, J. **Exploratory Data Analysis**, Addison-Wesley, 1977, p. 43-44.

VALENTE, D. S. M. **Desenvolvimento de um sistema de apoio à decisão para definir zonas de manejo em cafeicultura de precisão**. Viçosa, 2010, 104p. Tese de Doutorado em Engenharia Agrícola. Universidade Federal de Viçosa. 2010. Disponível em

<http://www.tede.ufv.br/tedesimplificado/tde_busca/arquivo.php?codArquivo=2661>. Acesso em: 27 Abr 2015.

VAN LIER, Q. D. J. (Org.). **Física do solo**. 1ª. ed. Viçosa: Sociedade Brasileira de Ciência do Solo, 2010. 298 p.

VIEIRA, S.R. **Geoestatística em estudos de variabilidade espacial de solo**. In: NOVAIS, R.F.; ALVAREZ, V.H.; SCHAEFER, C.R.G.R. (eds). Tópicos em ciência do solo Viçosa: Sociedade Brasileira de Ciência do Solo, 2000. v.1, p.1-53

WANDERLEY, H. S.; AMORIM, R. S. C. D.; CARVALHO, F. D. O. **Interpolação Espacial De Dados Com Redes Neurais**. In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, 17. Anais.. .Guarapari: Sociedade Brasileira de Agrometeorologia, 2011. 5 p. Disponível em: <http://www.sbagro.org.br/anais_congresso_2011/cba2011/trabalhos/04/cba04_72_189.pdf>. Acesso em: 25 Abr 2015.

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.

WERNER, V. **Utilização de recursos de agricultura de precisão na geração de mapas de atributos, mapas de produtividade e aplicação de insumos à taxas variáveis**. Santa Maria, 2004. 125p. Dissertação de Mestrado em Engenharia Agrícola – Universidade Federal de Santa Maria. 2004.

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

APÊNDICE A

6.1 Gráficos semivariogramas para os atributos de solo considerados.




FIGURA 48. Semivariogramas para os atributos químicos: Potencial Hidrogeniônico (pH) (a); Potássio (K) (b); Fósforo (P) (c); Cálcio (Ca) (d); Magnésio (Mg) (e) e Alumínio (Al) (f).




FIGURA 50. Semivariogramas dos atributos químicos: Acidez Potencial (H+Al) (a); Matéria Orgânica (MO) (b) e Saturação por Alumínio (m%).




FIGURA 51. Semivariogramas para os atributos de fertilidade: Capacidade de Troca Catiônica (CTC) e Saturação por Bases (V%).




FIGURA 52. Semivariograma para os atributos físicos: Argila, Silte, Areia

APÊNDICE B

7.1 Programa criado e utilizado na geração das matrizes de dados para treinamento das RNAs – Combinação com 1 ponto amostral relativo.

```
% Montar matrizes de dados para treinameno das RNAs com 1 ponto amostral relativo
% Escrito por ROberto Dib Bittar - rdbittar@yahoo.com.br
% 2015 - Outubro
%Apagar as variaveis
clear;
% Limpar o Workspace
clc;

% Carrega Matriz Base de Dados
% Esses dados foram normalizados no Excel. Originalmente são 120 amostras,
% 10 foram sorteadas usando ran no excel. Depois gerou nova planilha no
% excel excluindo os valores desses 10 pontos sorteados.
% Esse planilha foi nomeada MatrizOrigem e depois importada no matlab
% usando o recurso ImportData. Criou-se no Matlab uma matriz nomeada
% MatOrigem.
load('c:\rna\MatOrigem.mat')
% Desta foi criada MatrizOrigemLocal que possui apenas os atributos X,Y,
% Altitude dos 110 elementos
load('c:\rna\MatOrigemLocal.mat')
% Esta possui localizacao Geografica sem normalizaca
load('c:\rna\MatOrigemLocalXY.mat')

% A Matriz Amostras é proveniente de sorteio inical usando
% [AmostrasTreino,AmostrasValidacao,AmostrasTeste] = dividerand(110,0.75,0.15,0.10)
% Depois juntei os resultados nesta Matriz Amostra
% de 1 a 82 treino
% 83 a 99 validação
% 100 a 110 = teste
load('c:\rna\Amostras.mat')

% Agora sera gerado matriz para treinamento com 1 ponto amostral relativo
% Os tres primeiros valores são x,y,z que será testado depois vem os outros
% 18 atributos de cada amostra, quando repetir o ponto com ele mesmo, este
% deverá ser excluído (orientação Prof. Francisco)

% X (UTM) - USAR NORMALIZADO DE DELTA X , OU SEJA DISTANCIA X
% y(UTM) - USAR NORMALIZADO DE DELTA Y, OU SEJA DISTANCIA Y
% altitude (m)
% pH (CaCl2) (cmolc dm-3)
% Ca (cmolc dm-3)
% Mg(cmolc dm-3)
% Ca+Mg(cmolc dm-3)
% Al(cmolc dm-3)
% H + Al(cmolc dm-3)
% CTC(cmolc dm-3)
% K(cmolc dm-3)
% P (mg dm-3)
% Sat.Al.(%)
% Sat. Base(%)
% Mat. Org. (g kg-1)
% Argila(t/hc)
% Silte(t/hc)
% Areia(t/hc)

% Valores utilizados para normalização
xmin = 0;
xmax = 10000;
ymin = 0;
ymax = 10000;
d2=1;
d1=-1;

Arranjo1Ponto = zeros (1190,20);
contador = 0;
for contOrigem = 1:110
    for ContPonto1 = 1:110
        % calcular os delta = distancia entre pontos
        xreferencial = MatOrigemLocalXY(Amostras(contOrigem),1);
```

```

yreferencial = MatOrigemLocalXY(Amostras(contOrigem),2);

xrelativo = MatOrigemLocalXY(Amostras(ContPonto1),1);
yrelativo = MatOrigemLocalXY(Amostras(ContPonto1),2);

if xreferencial > xrelativo
    deltax = xreferencial-xrelativo;
else
    deltax = xrelativo-xreferencial;
end

if yreferencial > yrelativo
    deltay = yreferencial-yrelativo;
else
    deltay = yrelativo-yreferencial;
end
%Normalizando os valores de delta
deltaxnorm = (((deltax-xmin)*(d2-d1))/(xmax-xmin))+d1;
deltaynorm = (((deltay-ymin)*(d2-d1))/(ymax-ymin))+d1;

% ~= Significa diferente
if contOrigem ~= ContPonto1
%     Função cat , concatena diferentes matriz, a matriz resposta
%     terá a soma dos elementos indicados pela dimensão que foi
%     considerada, onde 1=linha, 2 = coluna e 3 seria uma terceira
%     dimensão como resposta
    Linha = cat (2, MatOrigemLocal(Amostras(contOrigem),1:2)...
        ,deltaxnorm,deltaynorm,MatOrigem(ContPonto1,3:18));
    contador = contador+1;
    Arranjo1Ponto(contador,:) = Linha;
end
end
end
h = msgbox ('Encerrado');

```

7.2 Programa criado e utilizado na geração das matrizes de dados para treinamento das RNAs – Combinação com 2 amostras relativas.

```

% Montar matrizes de dados para treinameno das RNAs com 2 amostras relativa
% Escrito por ROberto Dib Bittar - rdbittar@yahoo.com.br
% 2015 - Outubro
%Apagar as variaveis
clear;
% Limpar o Workspace
clc;

% Carrega Matriz Base de Dados
% Esses dados foram normalizados no Excel. Originalmente são 120 amostras,
% 10 foram sorteadas usando ran no excel. Depois gerou nova planilha no
% excel excluindo os valores desses 10 pontos sorteados.
% Esse planilha foi nomeada MatrizOrigem e depois importada no matlab
% usando o recurso ImportData. Criou-se no Matlab uma matriz nomeada
% MatOrigem.
load ('c:\rma\MatOrigem.mat')
% Desta foi criada MatrizOrigemLocal que possui apenas os atributos X,Y,
% Altitude dos 110 elementos
load ('c:\rma\MatOrigemLocal.mat')
% Esta possui localizacao Geografica sem normalizaca
load ('c:\rma\MatOrigemLocalXY.mat')

% A Matriz Amostras é proveniente de sorteio inical usando
% [AmostrasTreino,AmostrasValidacao,AmostrasTeste] = dividerand(110,0.75,0.15,0.10)
% Depois juntei os resultados na Matriz Amostra
% de 1 a 82 treino
% 83 a 99 validação
% 100 a 110 = teste
load ('c:\rma\Amostras.mat')

% Agora sera gerado matriz para treinamento com 2 pontos de referencia
% Os tres primeiros valores são x,y,z que será testado depois vem os outros
% 18 atributos de cada amostra, quando repetir o ponto com ele mesmo, este
% deverá ser excluído (orientação Prof. Francisco)

```



```

% X (UTM) - USAR NORMALIZADO DE DELTA X , OU SEJA DISTANCIA X
% y(UTM) - USAR NORMALIZADO DE DELTA Y, OU SEJA DISTANCIA Y
% altitude (m)
% pH (CaCl2) (cmolc dm-3)
% Ca (cmolc dm-3)
% Mg(cmolc dm-3)
% Ca+Mg(cmolc dm-3)
% Al(cmolc dm-3)
% H + Al(cmolc dm-3)
% CTC(cmolc dm-3)
% K(cmolc dm-3)
% P (mg dm-3)
% Sat.Al.(%)
% Sat. Base(%)
% Mat. Org. (g kg-1)
% Argila(t/hc)
% Silte(t/hc)
% Areia(t/hc)

% 2 + 18 + 18 = 38 (agora tem 2 pontos amostrais relativos que devem ser distintos)

% Valores utilizados para normalização
xmin = 0;
xmax = 10000;
ymin = 0;
ymax = 10000;
d2=1;
d1=-1;

Quantidade = 0;
Inclui = false;
QuantidadeCombina = 0;
Arranjo2Ponto = zeros (5500,38);
% Para cada ponto de referencia serão sorteadas 500 combinações
% 110 * 500 = 55000

AmostrasArranjo2 = zeros(55000,3);
EscolheElementos = zeros (1,2);
Teste1 = zeros (1,2);
Teste2 = zeros (1,2);
for contOrigem = 1:110
    QuantidadeCombina = 0;
    ElementosEscolhidos = zeros (500,2);
    AmostraReferencial = Amostras(contOrigem);

    while (QuantidadeCombina < 500)
        % função randperm (n,k) faz um combinação dos n valores com k elementos
        EscolheElementos = randperm(110,2);
        % Para ter certeza que não houve repetição das três amostras de
        % solo que irão compor a nova linha da matriz de treinamento com o
        % ponto de origem referencial. Não precisa comparar entre
        % amostras porque a randperm não gera valores iguais
        Inclui = false;
        if (EscolheElementos(1)~= AmostraReferencial) && (EscolheElementos(2)~= AmostraReferencial)
            if QuantidadeCombina == 0
                ElementosEscolhidos (1,:) = EscolheElementos;
                QuantidadeCombina = QuantidadeCombina +1;
                Inclui = true;
            else
                % Fazendo as possiveis combinacoes com os três elementos
                % sorteados para posteriormente testar se já não foram
                % incluídos na matriz de treinamento em qualquer ordem

                Teste1 = [EscolheElementos(1) EscolheElementos(2)];
                Teste2 = [EscolheElementos(2) EscolheElementos(1)];
                % || significa or
                if not ( (ismember(Teste1,ElementosEscolhidos,'rows')) ||...
                    (ismember(Teste2,ElementosEscolhidos,'rows')) )
                    ElementosEscolhidos (QuantidadeCombina,:) = EscolheElementos;
                    QuantidadeCombina = QuantidadeCombina +1;
                    Inclui = true;
                end
            end
        end
    end
end
if Inclui

```

```

% calcular os delta = distancia entre pontos
xreferencial = MatOrigemLocalXY(Amostras(AmostraReferencial),1);
yreferencial = MatOrigemLocalXY(Amostras(AmostraReferencial),2);

% Calculo para delta do ponto 1
xrelativo1 = MatOrigemLocalXY(Amostras(EscolheElementos(1)),1);
yrelativo1 = MatOrigemLocalXY(Amostras(EscolheElementos(1)),2);
if xreferencial > xrelativo1
    deltax1 = xreferencial-xrelativo1;
else
    deltax1 = xrelativo1-xreferencial;
end
if yreferencial > yrelativo1
    deltay1 = yreferencial-yrelativo1;
else
    deltay1 = yrelativo1-yreferencial;
end
%Normalizando os valores de delta
deltax1norm = (((deltax1-xmin)*(d2-d1))/(xmax-xmin))+d1;
deltay1norm = (((deltay1-ymin)*(d2-d1))/(ymax-ymin))+d1;
% Fim Calculo Delta Ponto Relativo 1 _____

% Calculo para delta do ponto 2
xrelativo2 = MatOrigemLocalXY(Amostras(EscolheElementos(2)),1);
yrelativo2 = MatOrigemLocalXY(Amostras(EscolheElementos(2)),2);
if xreferencial > xrelativo2
    deltax2 = xreferencial-xrelativo2;
else
    deltax2 = xrelativo2-xreferencial;
end
if yreferencial > yrelativo2
    deltay2 = yreferencial-yrelativo2;
else
    deltay2 = yrelativo1-yreferencial;
end
%Normalizando os valores de delta
deltax2norm = (((deltax2-xmin)*(d2-d1))/(xmax-xmin))+d1;
deltay2norm = (((deltay2-ymin)*(d2-d1))/(ymax-ymin))+d1;
% Fim Calculo Delta Ponto Relativo 2 _____

Linha = cat (2, MatOrigemLocal(Amostras(AmostraReferencial),1:2),...
    deltax1norm,deltay1norm,MatOrigem(EscolheElementos(1),3:18),...
    deltax2norm,deltay2norm,MatOrigem(EscolheElementos(2),3:18));

Quantidade = Quantidade +1;
Arranjo2Ponto (Quantidade,:) = Linha;

AmostrasArranjo2(Quantidade,:) = cat (2,AmostraReferencial, EscolheElementos(1), EscolheElementos(2));
% Esta Matriz esta sendo gerada para depois eu saber quais
% foram as amostras combinadas.

end
end
end
display(AmostraReferencial);
end
save('c:\rna\Arranjo2Ponto', 'Arranjo2Ponto');
save('c:\rna\AmostrasArranjo2', 'AmostrasArranjo2');

```

7.3 Programa criado e utilizado na geração das matrizes de dados para treinamento das RNAs – Combinação com 3 amostras relativas.

```

% Montar matrizes de dados para treinameno das RNAs com 3 amostras relativa
% Escrito por ROberto Dib Bittar - rdbittar@yahoo.com.br
% 2015 - Outubro
%Apagar as variaveis
clear;
% Limpar o Workspace
clc;

% Carrega Matriz Base de Dados
% Esses dados foram normalizados no Excel. Originalmente são 120 amostras,
% 10 foram sorteadas usando ran no excel. Depois gerou nova planilha no
% excel excluindo os valores desses 10 pontos sorteados.

```

```

% Esse planilha foi nomeada MatrizOrigem e depois importada no matlab
% usando o recurso ImportData. Criou-se no Matlab uma matriz nomeada
% MatOrigem.
load('c:\rma\MatOrigem.mat')
% Desta foi criada MatrizOrigemLocal que possui apenas os atributos X,Y,
% Altitude dos 110 elementos
load('c:\rma\MatOrigemLocal.mat')
% Esta possui localizacao Geografica sem normalizaca
load('c:\rma\MatOrigemLocalXY.mat')

% A Matriz Amostras é proveniente de sorteio inicial usando
% [AmostrasTreino,AmostrasValidacao,AmostrasTeste] = dividerand(110,0.75,0.15,0.10)
% Depois juntei os resultados na Matriz Amostra
% de 1 a 82 treino
% 83 a 99 validação
% 100 a 110 = teste
load('c:\rma\Amostras.mat')

% Agora sera gerado matriz para treinamento com 2 pontos de referencia
% Os tres primeiros valores são x,y,z que será testado depois vem os outros
% 18 atributos de cada amostra, quando repetir o ponto com ele mesmo, este
% deverá ser excluído (orientação Prof. Francisco)

% X (UTM) - USAR NORMALIZADO DE DELTA X , OU SEJA DISTANCIA X
% y(UTM) - USAR NORMALIZADO DE DELTA Y, OU SEJA DISTANCIA Y
% altitude (m)
% pH (CaCl2) (cmolc dm-3)
% Ca (cmolc dm-3)
% Mg(cmolc dm-3)
% Ca+Mg(cmolc dm-3)
% Al(cmolc dm-3)
% H + Al(cmolc dm-3)
% CTC(cmolc dm-3)
% K(cmolc dm-3)
% P (mg dm-3)
% Sat.Al.(%)
% Sat. Base(%)
% Mat. Org. (g kg-1)
% Argila(t/hc)
% Silte(t/hc)
% Areia(t/hc)

% 2 + 18 + 18 + 18 = 56 (agora tem 3 pontos de referência que devem ser distintos)

% Valores utilizados para normalização
xmin = 0;
xmax = 10000;
ymin = 0;
ymax = 10000;
d2=1;
d1=-1;

Quantidade = 0;
Inclui = false;
QuantidadeCombina = 0;
Arranjo3Ponto = zeros(5500,56);
% Para cada ponto de referencia serão sorteadas 500 combinações
% 110 * 500 = 55000

AmostrasArranjo3 = zeros(55000,4);
EscolheElementos = zeros(1,3);
Teste1 = zeros(1,3);
Teste2 = zeros(1,3);
Teste3 = zeros(1,3);
Teste4 = zeros(1,3);
Teste5 = zeros(1,3);
Teste6 = zeros(1,3);

for contOrigem = 1:110
    QuantidadeCombina = 0;
    ElementosEscolhidos = zeros(500,3);
    AmostraReferencial = Amostras(contOrigem);

    while (QuantidadeCombina < 500)
        % função randperm (n,k) faz um combinação dos n valores com k elementos

```

```

EscolheElementos = randperm(110,3);
% Para ter certeza que não houve repetição das três amostras de
% solo que irão compor a nova linha da matriz de treinamento com o
% ponto de origem referencial. Não precisa comparar entre
% amostras porque a randperm não gera valores iguais
Inclui = false;
if (EscolheElementos(1)~= AmostraReferencial) && ...
(EscolheElementos(2)~= AmostraReferencial) && ...
(EscolheElementos(3)~= AmostraReferencial)

if QuantidadeCombina == 0
    ElementosEscolhidos (1,:) = EscolheElementos;
    QuantidadeCombina = QuantidadeCombina +1;
    Inclui = true;
else
    % Fazendo as possiveis combinacoes com os três elementos
    % sorteados para posteriormente testar se já não foram
    % incluídos na matriz de treinamento em qualquer ordem

    Teste1 = [EscolheElementos(1) EscolheElementos(2) EscolheElementos(3)];
    Teste2 = [EscolheElementos(1) EscolheElementos(3) EscolheElementos(2)];
    Teste3 = [EscolheElementos(2) EscolheElementos(1) EscolheElementos(3)];
    Teste4 = [EscolheElementos(2) EscolheElementos(3) EscolheElementos(1)];
    Teste5 = [EscolheElementos(3) EscolheElementos(1) EscolheElementos(2)];
    Teste6 = [EscolheElementos(3) EscolheElementos(2) EscolheElementos(1)];
    % || significa or
    if not ( (ismember(Teste1,ElementosEscolhidos,'rows')) ||...
        (ismember(Teste2,ElementosEscolhidos,'rows')) ||...
        (ismember(Teste3,ElementosEscolhidos,'rows')) ||...
        (ismember(Teste4,ElementosEscolhidos,'rows')) ||...
        (ismember(Teste5,ElementosEscolhidos,'rows')) ||...
        (ismember(Teste6,ElementosEscolhidos,'rows')))
        ElementosEscolhidos (QuantidadeCombina,:) = EscolheElementos;
        QuantidadeCombina = QuantidadeCombina +1;
        Inclui = true;
    end
end
if Inclui

    % calcular os delta = distancia entre pontos
    xreferencial = MatOrigemLocalXY(Amostras(AmostraReferencial),1);
    yreferencial = MatOrigemLocalXY(Amostras(AmostraReferencial),2);

    % Calculo para delta do ponto 1
    xrelativo1 = MatOrigemLocalXY(Amostras(EscolheElementos(1)),1);
    yrelativo1 = MatOrigemLocalXY(Amostras(EscolheElementos(1)),2);
    if xreferencial >xrelativo1
        deltax1 = xreferencial-xrelativo1;
    else
        deltax1 = xrelativo1-xreferencial;
    end
    if yreferencial >yrelativo1
        deltax1 = yreferencial-yrelativo1;
    else
        deltax1 = yrelativo1-yreferencial;
    end
    %Normalizando os valores de delta
    deltax1norm = (((deltax1-xmin)*(d2-d1))/(xmax-xmin))+d1;
    deltax1norm = (((deltax1-ymin)*(d2-d1))/(ymax-ymin))+d1;
    % Fim Calculo Delta Ponto Relativo 1 _____

    % Calculo para delta do ponto 2
    xrelativo2 = MatOrigemLocalXY(Amostras(EscolheElementos(2)),1);
    yrelativo2 = MatOrigemLocalXY(Amostras(EscolheElementos(2)),2);
    if xreferencial >xrelativo2
        deltax2 = xreferencial-xrelativo2;
    else
        deltax2 = xrelativo2-xreferencial;
    end
    if yreferencial >yrelativo2
        deltax2 = yreferencial-yrelativo2;
    else
        deltax2 = yrelativo2-yreferencial;
    end
    %Normalizando os valores de delta

```

```

deltax2norm = (((deltax2-xmin)*(d2-d1))/(xmax-xmin))+d1;
deltay2norm = (((deltay2-ymin)*(d2-d1))/(ymax-ymin))+d1;
% Fim Calculo Delta Ponto Relativo 2 _____

% Calculo para delta do ponto 3
xrelativo3 = MatOrigemLocalXY(Amostras(EscolheElementos(3)),1);
yrelativo3 = MatOrigemLocalXY(Amostras(EscolheElementos(3)),2);
if xreferencial > xrelativo3
    deltax3 = xreferencial-xrelativo3;
else
    deltax3 = xrelativo3-xreferencial;
end
if yreferencial > yrelativo3
    deltay3 = yreferencial-yrelativo3;
else
    deltay3 = yrelativo3-yreferencial;
end
%Normalizando os valores de delta
deltax3norm = (((deltax3-xmin)*(d2-d1))/(xmax-xmin))+d1;
deltay3norm = (((deltay3-ymin)*(d2-d1))/(ymax-ymin))+d1;
% Fim Calculo Delta Ponto Relativo 3 _____

Linha = cat (2, MatOrigemLocal(Amostras(AmostraReferencial),1:2),...
    deltax1norm,deltay1norm,MatOrigem(EscolheElementos(1),3:18),...
    deltax2norm,deltay2norm,MatOrigem(EscolheElementos(2),3:18),...
    deltax3norm,deltay3norm,MatOrigem(EscolheElementos(3),3:18));
Quantidade = Quantidade +1;
Arranjo3Ponto (Quantidade,:) = Linha;

AmostrasArranjo3(Quantidade,:) = cat (2,AmostraReferencial, EscolheElementos(1), EscolheElementos(2),
EscolheElementos(3));
% Esta Matriz esta sendo gerada para depois eu saber quais
% foram as amostras combinadas.

end
end
end
display(AmostraReferencial);
end
save('c:\rna\Arranjo3Ponto', 'Arranjo3Ponto');
save('c:\rna\AmostrasArranjo3', 'AmostrasArranjo3');

```

7.4 Programa criado e utilizado na geração das matrizes de dados para treinamento das RNAs – Combinação com 4 amostras relativas.

```

% Montar matrizes de dados para treinameno das RNAs com 3 amostras relativa
% Escrito por ROberto Dib Bittar - rdbittar@yahoo.com.br
% 2015 - Outubro
%Apagar as variaveis
clear;
% Limpar o Workspace
clc;

% Carrega Matriz Base de Dados
% Esses dados foram normalizados no Excel. Originalmente são 120 amostras,
% 10 foram sorteadas usando ran no excel. Depois gerou nova planilha no
% excel excluindo os valores desses 10 pontos sorteados.
% Esse planilha foi nomeada MatrizOrigem e depois importada no matlab
% usando o recurso ImportData. Criou-se no Matlab uma matriz nomeada
% MatOrigem.
load ('c:\rna\MatOrigem.mat')
% Desta foi criada MatrizOrigemLocal que possui apenas os atributos X,Y,
% Altitude dos 110 elementos
load ('c:\rna\MatOrigemLocal.mat')
% Esta possui localizacao Geografica sem normalizacao
load ('c:\rna\MatOrigemLocalXY.mat')

% A Matriz Amostras é proveniente de sorteio inicial usando
% [AmostrasTreino,AmostrasValidacao,AmostrasTeste] = dividerand(110,0.75,0.15,0.10)
% Depois juntei os resultados na Matriz Amostra
% de 1 a 82 treino
% 83 a 99 validação

```

```

% 100 a 110 = teste
load ('c:\rma\Amostras.mat')

% Agora sera gerado matriz para treinamento com 2 pontos de referencia
% Os tres primeiros valores são x,y,z que será testado depois vem os outros
% 18 atributos de cada amostra, quando repetir o ponto com ele mesmo, este
% deverá ser excluído (orientação Prof. Francisco)

% X (UTM) - USAR NORMALIZADO DE DELTA X , OU SEJA DISTANCIA X
% y(UTM) - USAR NORMALIZADO DE DELTA Y, OU SEJA DISTANCIA Y
% altitude (m)
% pH (CaCl2) (cmolc dm-3)
% Ca (cmolc dm-3)
% Mg(cmolc dm-3)
% Ca+Mg(cmolc dm-3)
% Al(cmolc dm-3)
% H + Al(cmolc dm-3)
% CTC(cmolc dm-3)
% K(cmolc dm-3)
% P (mg dm-3)
% Sat.Al.(%)
% Sat. Base(%)
% Mat. Org. (g kg-1)
% Argila(t/hc)
% Silte(t/hc)
% Areia(t/hc)

% 2 + 18 + 18 + 18 + 18 = 74 (agora tem 4 pontos de referencia que devem ser distintos)

% Valores utilizados para normalização
xmin = 0;
xmax = 10000;
ymin = 0;
ymax = 10000;
d2=1;
d1=-1;

Quantidade = 0;
Inclui = false;
QuantidadeCombina = 0;
Arranjo4Ponto = zeros (5500,74);
% Para cada ponto de referencia serão sorteadas 500 combinações
% 110 * 500 = 55000

AmostrasArranjo4 = zeros(55000,5);
EscolheElementos = zeros (1,4);
Teste1 = zeros (1,4);
Teste2 = zeros (1,4);
Teste3 = zeros (1,4);
Teste4 = zeros (1,4);
Teste5 = zeros (1,4);
Teste6 = zeros (1,4);
Teste7 = zeros (1,4);
Teste8 = zeros (1,4);
Teste9 = zeros (1,4);
Teste10 = zeros (1,4);
Teste11 = zeros (1,4);
Teste12 = zeros (1,4);
Teste13 = zeros (1,4);
Teste14 = zeros (1,4);
Teste15 = zeros (1,4);
Teste16 = zeros (1,4);
Teste17 = zeros (1,4);
Teste18 = zeros (1,4);
Teste19 = zeros (1,4);
Teste20 = zeros (1,4);
Teste21 = zeros (1,4);
Teste22 = zeros (1,4);
Teste23 = zeros (1,4);
Teste24 = zeros (1,4);

for contOrigem = 1:110
    QuantidadeCombina = 0;
    ElementosEscolhidos = zeros (500,4);
    AmostraReferencial = Amostras(contOrigem);

```

```

while (QuantidadeCombina < 500)
    % função randperm (n,k) faz um combinação dos n valores com k elementos
    EscolheElementos = randperm(110,4);
    % Para ter certeza que não houve repetição das três amostras de
    % solo que irão compor a nova linha da matriz de treinamento com o
    % ponto de origem referencial. Não precisa comparar entre
    % amostras porque a randperm não gera valores iguais
    Inclui = false;
    if (EscolheElementos(1)~= AmostraReferencial) && ...
        (EscolheElementos(2)~= AmostraReferencial) && ...
        (EscolheElementos(3)~= AmostraReferencial) && ...
        (EscolheElementos(4)~= AmostraReferencial)

        if QuantidadeCombina == 0
            ElementosEscolhidos (1,:) = EscolheElementos;
            QuantidadeCombina = QuantidadeCombina +1;
            Inclui = true;
        else
            % Fazendo as possiveis combinacoes com os três elementos
            % sorteados para posteriormente testar se já não foram
            % incluídos na matriz de treinamento em qualquer ordem

            % Fazendo as possiveis combinacoes com os quatro elementos
            % sorteados para posteriormente testar se já não foi
            % incluído na matriz de treinamento em qualquer ordem

            Teste1 = [EscolheElementos(1) EscolheElementos(2) EscolheElementos(3) EscolheElementos(4)];
            Teste2 = [EscolheElementos(1) EscolheElementos(2) EscolheElementos(4) EscolheElementos(3)];
            Teste3 = [EscolheElementos(1) EscolheElementos(3) EscolheElementos(2) EscolheElementos(4)];
            Teste4 = [EscolheElementos(1) EscolheElementos(3) EscolheElementos(4) EscolheElementos(2)];
            Teste5 = [EscolheElementos(1) EscolheElementos(4) EscolheElementos(2) EscolheElementos(3)];
            Teste6 = [EscolheElementos(1) EscolheElementos(4) EscolheElementos(3) EscolheElementos(2)];

            Teste7 = [EscolheElementos(2) EscolheElementos(1) EscolheElementos(3) EscolheElementos(4)];
            Teste8 = [EscolheElementos(2) EscolheElementos(1) EscolheElementos(4) EscolheElementos(3)];
            Teste9 = [EscolheElementos(2) EscolheElementos(3) EscolheElementos(1) EscolheElementos(4)];
            Teste10 = [EscolheElementos(2) EscolheElementos(3) EscolheElementos(4) EscolheElementos(1)];
            Teste11 = [EscolheElementos(2) EscolheElementos(4) EscolheElementos(1) EscolheElementos(3)];
            Teste12 = [EscolheElementos(2) EscolheElementos(4) EscolheElementos(3) EscolheElementos(1)];

            Teste13 = [EscolheElementos(3) EscolheElementos(1) EscolheElementos(2) EscolheElementos(4)];
            Teste14 = [EscolheElementos(3) EscolheElementos(1) EscolheElementos(4) EscolheElementos(2)];
            Teste15 = [EscolheElementos(3) EscolheElementos(2) EscolheElementos(1) EscolheElementos(4)];
            Teste16 = [EscolheElementos(3) EscolheElementos(2) EscolheElementos(4) EscolheElementos(1)];
            Teste17 = [EscolheElementos(3) EscolheElementos(4) EscolheElementos(1) EscolheElementos(2)];
            Teste18 = [EscolheElementos(3) EscolheElementos(4) EscolheElementos(2) EscolheElementos(1)];

            Teste19 = [EscolheElementos(4) EscolheElementos(1) EscolheElementos(2) EscolheElementos(3)];
            Teste20 = [EscolheElementos(4) EscolheElementos(1) EscolheElementos(3) EscolheElementos(2)];
            Teste21 = [EscolheElementos(4) EscolheElementos(2) EscolheElementos(1) EscolheElementos(3)];
            Teste22 = [EscolheElementos(4) EscolheElementos(2) EscolheElementos(3) EscolheElementos(1)];
            Teste23 = [EscolheElementos(4) EscolheElementos(3) EscolheElementos(1) EscolheElementos(2)];
            Teste24 = [EscolheElementos(4) EscolheElementos(3) EscolheElementos(2) EscolheElementos(1)];

            % || significa or
            if not ( (ismember(Teste1,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste2,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste3,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste4,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste5,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste6,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste7,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste8,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste9,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste10,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste11,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste12,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste13,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste14,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste15,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste16,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste17,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste18,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste19,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste20,ElementosEscolhidos,'rows')) ||...
                (ismember(Teste21,ElementosEscolhidos,'rows')) ||...
            )

```

```

        (ismember(Teste22,ElementosEscolhidos,'rows')) ||...
        (ismember(Teste23,ElementosEscolhidos,'rows')) ||...
        (ismember(Teste24,ElementosEscolhidos,'rows'))))
    ElementosEscolhidos (QuantidadeCombina,:) = EscolheElementos;
    QuantidadeCombina = QuantidadeCombina +1;
    Inclui = true;
end
end
if Inclui

    % calcular os delta = distancia entre pontos
    xreferencial = MatOrigemLocalXY(Amostras(AmostraReferencial),1);
    yreferencial = MatOrigemLocalXY(Amostras(AmostraReferencial),2);

    % Calculo para delta do ponto 1
    xrelativo1 = MatOrigemLocalXY(Amostras(EscolheElementos(1)),1);
    yrelativo1 = MatOrigemLocalXY(Amostras(EscolheElementos(1)),2);
    if xreferencial >xrelativo1
        deltax1 = xreferencial-xrelativo1;
    else
        deltax1 = xrelativo1-xreferencial;
    end
    if yreferencial >yrelativo1
        deltax1 = yreferencial-yrelativo1;
    else
        deltax1 = yrelativo1-yreferencial;
    end
    %Normalizando os valores de delta
    deltax1norm = (((deltax1-xmin)*(d2-d1))/(xmax-xmin))+d1;
    deltax1norm = (((deltax1-ymin)*(d2-d1))/(ymax-ymin))+d1;
    % Fim Calculo Delta Ponto Relativo 1 _____

    % Calculo para delta do ponto 2
    xrelativo2 = MatOrigemLocalXY(Amostras(EscolheElementos(2)),1);
    yrelativo2 = MatOrigemLocalXY(Amostras(EscolheElementos(2)),2);
    if xreferencial >xrelativo2
        deltax2 = xreferencial-xrelativo2;
    else
        deltax2 = xrelativo2-xreferencial;
    end
    if yreferencial >yrelativo2
        deltax2 = yreferencial-yrelativo2;
    else
        deltax2 = yrelativo2-yreferencial;
    end
    %Normalizando os valores de delta
    deltax2norm = (((deltax2-xmin)*(d2-d1))/(xmax-xmin))+d1;
    deltax2norm = (((deltax2-ymin)*(d2-d1))/(ymax-ymin))+d1;
    % Fim Calculo Delta Ponto Relativo 2 _____

    % Calculo para delta do ponto 3
    xrelativo3 = MatOrigemLocalXY(Amostras(EscolheElementos(3)),1);
    yrelativo3 = MatOrigemLocalXY(Amostras(EscolheElementos(3)),2);
    if xreferencial >xrelativo3
        deltax3 = xreferencial-xrelativo3;
    else
        deltax3 = xrelativo3-xreferencial;
    end
    if yreferencial >yrelativo3
        deltax3 = yreferencial-yrelativo3;
    else
        deltax3 = yrelativo3-yreferencial;
    end
    %Normalizando os valores de delta
    deltax3norm = (((deltax3-xmin)*(d2-d1))/(xmax-xmin))+d1;
    deltax3norm = (((deltax3-ymin)*(d2-d1))/(ymax-ymin))+d1;
    % Fim Calculo Delta Ponto Relativo 3 _____

    % Calculo para delta do ponto 4
    xrelativo4 = MatOrigemLocalXY(Amostras(EscolheElementos(4)),1);
    yrelativo4 = MatOrigemLocalXY(Amostras(EscolheElementos(4)),2);
    if xreferencial >xrelativo4
        deltax4 = xreferencial-xrelativo4;
    else
        deltax4 = xrelativo4-xreferencial;
    end

```



```

end
if yreferencial > yrelativo4
    deltax4 = yreferencial - yrelativo4;
else
    deltax4 = yrelativo1 - yreferencial;
end
%Normalizando os valores de delta
deltax4norm = (((deltax4 - xmin)*(d2 - d1))/(xmax - xmin)) + d1;
deltay4norm = (((deltay4 - ymin)*(d2 - d1))/(ymax - ymin)) + d1;
% Fim Calculo Delta Ponto Relativo 3

Linha = cat(2, MatOrigemLocal(Amostras(AmostraReferencial), 1:2), ...
    deltax1norm, deltax1norm, MatOrigem(EscolheElementos(1), 3:18), ...
    deltax2norm, deltax2norm, MatOrigem(EscolheElementos(2), 3:18), ...
    deltax3norm, deltax3norm, MatOrigem(EscolheElementos(3), 3:18), ...
    deltax4norm, deltax4norm, MatOrigem(EscolheElementos(4), 3:18));
Quantidade = Quantidade + 1;
Arranjo4Ponto(Quantidade,:) = Linha;

AmostrasArranjo4(Quantidade,:) = cat(2, AmostraReferencial, ...
    EscolheElementos(1), EscolheElementos(2), ...
    EscolheElementos(3), EscolheElementos(4));
% Esta Matriz esta sendo gerada para depois eu saber quais
% foram as amostras combinadas.

end
end
end
display(AmostraReferencial);
end
save('c:\rna\Arranjo4Ponto', 'Arranjo4Ponto');
save('c:\rna\AmostrasArranjo4', 'AmostrasArranjo4');

```

7.5 Programa criado e utilizado na geração das matrizes de resultados de todos atributos para treinamento das RNAs – Resultados para 1 ponto amostral relativo.

```

% Montar as Matrizes Alvo com 11990 elementos
% Montar matrizes resposta treinamento das RNAs com 1 ponto amostral relativo
% Escrito por Roberto Dib Bittar - rdbittar@yahoo.com.br
% 2015 - Outubro
% Apagar as variaveis
clear;
% Limpar o Workspace
clc;

load('c:\rna\Amostras.mat')
Tgt = zeros(110,1);
Tgt_1 = zeros(11990,1);
quantidade = 0;
for alvo = 1:15
    switch alvo
        case 1
            load('c:\rna\Tgt_Ph.mat');
            Tgt = Tgt_Ph;
        case 2
            load('c:\rna\Tgt_Ca.mat');
            Tgt = Tgt_Ca;
        case 3
            load('c:\rna\Tgt_Mg.mat');
            Tgt = Tgt_Mg;
        case 4
            load('c:\rna\Tgt_CaMg.mat');
            Tgt = Tgt_CaMg;
        case 5
            load('c:\rna\Tgt_Al.mat');
            Tgt = Tgt_Al;
        case 6
            load('c:\rna\Tgt_HAl.mat');
            Tgt = Tgt_HAl;
        case 7
            load('c:\rna\Tgt_CTC.mat');
            Tgt = Tgt_CTC;
        case 8

```

```

        load('c:\rma\Tgt_K.mat');
        Tgt=Tgt_K;
    case 9
        load('c:\rma\Tgt_P.mat');
        Tgt=Tgt_P;
    case 10
        load('c:\rma\Tgt_SatBase.mat');
        Tgt=Tgt_SatBase;
    case 11
        load('c:\rma\Tgt_SatAl.mat');
        Tgt=Tgt_SatAl;
    case 12
        load('c:\rma\Tgt_MatOrg.mat');
        Tgt=Tgt_MatOrg;
    case 13
        load('c:\rma\Tgt_Argila.mat');
        Tgt=Tgt_Argila;
    case 14
        load('c:\rma\Tgt_Silte.mat');
        Tgt=Tgt_Silte;
    case 15
        load('c:\rma\Tgt_Areia.mat');
        Tgt=Tgt_Areia;
    end
    quantidade = 0;
    for contador = 1:110
        elemento = Amostras(contador);
        for cont = 1:109
            quantidade = quantidade + 1;
            Tgt_1(quantidade,:) = Tgt(elemento);
            display(quantidade);
        end
    end
end

switch alvo
    case 1
        save('c:\rma\Tgt_Ph_1.mat','Tgt_1');
    case 2
        save('c:\rma\Tgt_Ca_1','Tgt_1');
    case 3
        save('c:\rma\Tgt_Mg_1.mat','Tgt_1');
    case 4
        save('c:\rma\Tgt_CaMg_1.mat','Tgt_1');
    case 5
        save('c:\rma\Tgt_Al_1.mat','Tgt_1');
    case 6
        save('c:\rma\Tgt_HAl_1.mat','Tgt_1');
    case 7
        save('c:\rma\Tgt_CTC_1.mat','Tgt_1');
    case 8
        save('c:\rma\Tgt_K_1.mat','Tgt_1');
    case 9
        save('c:\rma\Tgt_P_1.mat','Tgt_1');
    case 10
        save('c:\rma\Tgt_SatBase_1.mat','Tgt_1');
    case 11
        save('c:\rma\Tgt_SatAl_1.mat','Tgt_1');
    case 12
        save('c:\rma\Tgt_MatOrg_1.mat','Tgt_1');
    case 13
        save('c:\rma\Tgt_Argila_1.mat','Tgt_1');
    case 14
        save('c:\rma\Tgt_Silte_1.mat','Tgt_1');
    case 15
        save('c:\rma\Tgt_Areia_1.mat','Tgt_1');
    end
end
end

```

7.6 Programa criado e utilizado na geração das matrizes de resultados de todos atributos para treinamento das RNAs – Resultados para 2 ou mais amostras relativas.

% Montar as Matrizes Alvo com 55000 elementos

```
% MONTar matrizes resposta treinameno das RNAs com 2 ou mais amostras
% relativas
% Escrito por ROberto Dib Bittar - rdbittar@yahoo.com.br
% 2015 - Outubro
```

```
%Apagar as variaveis
```

```
clear;
```

```
% Limpar o Workspace
```

```
clc;
```

```
load('c:\rma\n\Amostras.mat')
```

```
Tgt = zeros(110,1);
```

```
Tgt_N = zeros (55000,1);
```

```
quantidade = 0;
```

```
for alvo = 1:15
```

```
    switch alvo
```

```
        case 1
```

```
            load ('c:\rma\Tgt_Ph.mat');
```

```
            Tgt= Tgt_Ph;
```

```
        case 2
```

```
            load ('c:\rma\Tgt_Ca.mat');
```

```
            Tgt=Tgt_Ca;
```

```
        case 3
```

```
            load ('c:\rma\Tgt_Mg.mat');
```

```
            Tgt=Tgt_Mg;
```

```
        case 4
```

```
            load ('c:\rma\Tgt_CaMg.mat');
```

```
            Tgt=Tgt_CaMg;
```

```
        case 5
```

```
            load ('c:\rma\Tgt_Al.mat');
```

```
            Tgt=Tgt_Al;
```

```
        case 6
```

```
            load ('c:\rma\Tgt_HAl.mat');
```

```
            Tgt=Tgt_HAl;
```

```
        case 7
```

```
            load ('c:\rma\Tgt_CTC.mat');
```

```
            Tgt=Tgt_CTC;
```

```
        case 8
```

```
            load ('c:\rma\Tgt_K.mat');
```

```
            Tgt=Tgt_K;
```

```
        case 9
```

```
            load ('c:\rma\Tgt_P.mat');
```

```
            Tgt=Tgt_P;
```

```
        case 10
```

```
            load ('c:\rma\Tgt_SatBase.mat');
```

```
            Tgt=Tgt_SatBase;
```

```
        case 11
```

```
            load ('c:\rma\Tgt_SatAl.mat');
```

```
            Tgt=Tgt_SatAl;
```

```
        case 12
```

```
            load ('c:\rma\Tgt_MatOrg.mat');
```

```
            Tgt=Tgt_MatOrg;
```

```
        case 13
```

```
            load ('c:\rma\Tgt_Argila.mat');
```

```
            Tgt=Tgt_Argila;
```

```
        case 14
```

```
            load ('c:\rma\Tgt_Silte.mat');
```

```
            Tgt=Tgt_Silte;
```

```
        case 15
```

```
            load ('c:\rma\Tgt_Areia.mat');
```

```
            Tgt=Tgt_Areia;
```

```
    end
```

```
    quantidade = 0;
```

```
    for contador = 1:110
```

```
        elemento = Amostras(contador);
```

```
        for cont = 1:500
```

```
            quantidade = quantidade +1;
```

```
            Tgt_N (quantidade,:) = Tgt (elemento);
```

```
            display(quantidade);
```

```
        end
```

```
    end
```

```
switch alvo
```

```
    case 1
```

```
        save ('c:\rma\Tgt_Ph_N.mat', 'Tgt_N');
```

```
    case 2
```

```
    save('c:\rna\Tgt_Ca_N', 'Tgt_N');  
case 3  
    save('c:\rna\Tgt_Mg_N.mat', 'Tgt_N');  
case 4  
    save('c:\rna\Tgt_CaMg_N.mat', 'Tgt_N');  
case 5  
    save('c:\rna\Tgt_Al_N.mat', 'Tgt_N');  
case 6  
    save('c:\rna\Tgt_HAl_N.mat', 'Tgt_N');  
case 7  
    save('c:\rna\Tgt_CTC_N.mat', 'Tgt_N');  
case 8  
    save('c:\rna\Tgt_K_N.mat', 'Tgt_N');  
case 9  
    save('c:\rna\Tgt_P_N.mat', 'Tgt_N');  
case 10  
    save('c:\rna\Tgt_SatBase_N.mat', 'Tgt_N');  
case 11  
    save('c:\rna\Tgt_SatAl_N.mat', 'Tgt_N');  
case 12  
    save('c:\rna\Tgt_MatOrg_N.mat', 'Tgt_N');  
case 13  
    save('c:\rna\Tgt_Argila_N.mat', 'Tgt_N');  
case 14  
    save('c:\rna\Tgt_Silte_N.mat', 'Tgt_N');  
case 15  
    save('c:\rna\Tgt_Areia_N.mat', 'Tgt_N');  
end  
end
```

APÊNDICE C

8.1 Programa criado e utilizado para treinamento das Redes Neurais Artificiais

```
% Resolução com Rede Neural Artificial (RNA) de um problema do tipo Input-Output
% Script originalmente gerado pelo NFTOOL
% Reescrito Por Roberto Dib Bittar - rdbittar@yahoo.com.br
% Mestrando Engenharia Agrícola - UEG

clear;
%Apagar as variaveis

clc;
% Limpar o Workspace

%Passo 1
% As matrizes foram geradas de com 110 amostras das 120 disponiveis.
% A escolha se deu por sorteio feito no software excel

% Passo 2 foi Executado os programas MontarArranjoTreinamento1 ate
% MontarArranjoTreinamento4 para geracao das matrizes de treinamento
% a partir das matrizes sorteadas = MatOrigem e MatOrigemLocal
% Onde MatOrigem porem possui apenas dados coordenadas X,Y,Z.
% As matrizes geradas e gravadas foram nomeadas como arranjo1ponto
% ate arranjo4ponto usadas comoinput data
% Também foram geradas e gravadas as as matrizes alvo para cada um dos
% 15 atributos analisados nomeadas como Tgt_abreviacaoElemento
% Totalizando entao 15 matrizes com os 110 valores alvo de cada atributo.

%Comando para carregar os dados de entrada para o treinamento
load ('c:\rna\Arranjo1ponto.mat');
inputs1Pt = Arranjo1Ponto';
load ('c:\rna\Arranjo2ponto.mat');
inputs2Pt = Arranjo2Ponto';
load ('c:\rna\Arranjo3ponto.mat');
inputs3Pt = Arranjo3Ponto';
load ('c:\rna\Arranjo4ponto.mat');
inputs4Pt = Arranjo4Ponto';

% Chamando as matrizes alvo
load ('c:\rna\Tgt_Ph_1.mat');
load ('c:\rna\Tgt_Ph_N.mat');
load ('c:\rna\Tgt_Ca_1.mat');
load ('c:\rna\Tgt_Ca_N.mat');
load ('c:\rna\Tgt_Mg_1.mat');
load ('c:\rna\Tgt_Mg_N.mat');
load ('c:\rna\Tgt_CaMg_1.mat');
load ('c:\rna\Tgt_CaMg_N.mat');
load ('c:\rna\Tgt_Al_1.mat');
load ('c:\rna\Tgt_Al_N.mat');
load ('c:\rna\Tgt_HAl_1.mat');
load ('c:\rna\Tgt_HAl_N.mat');
load ('c:\rna\Tgt_CTC_1.mat');
load ('c:\rna\Tgt_CTC_N.mat');
load ('c:\rna\Tgt_K_1.mat');
load ('c:\rna\Tgt_K_N.mat');
load ('c:\rna\Tgt_P_1.mat');
load ('c:\rna\Tgt_P_N.mat');
load ('c:\rna\Tgt_SatAl_1.mat');
load ('c:\rna\Tgt_SatAl_N.mat');
load ('c:\rna\Tgt_SatBase_1.mat');
load ('c:\rna\Tgt_SatBase_N.mat');
load ('c:\rna\Tgt_MatOrg_1.mat');
load ('c:\rna\Tgt_MatOrg_N.mat');
load ('c:\rna\Tgt_Argila_1.mat');
load ('c:\rna\Tgt_Argila_N.mat');
load ('c:\rna\Tgt_Silte_1.mat');
load ('c:\rna\Tgt_Silte_N.mat');
load ('c:\rna\Tgt_Areia_1.mat');
load ('c:\rna\Tgt_Areia_N.mat');
```

```

% Create a Fitting Network
TiposRede = zeros(1,7);
TiposRede (1) = 3;
TiposRede (2) = 5;
TiposRede (3) = 7;
TiposRede (4) = 9;
TiposRede (5) = 13;
TiposRede (6) = 17;
TiposRede (7) = 21;

% Matriz que irá gravar os resultados do treinamento
% Possui 18 colunas sendo elas
%[Alvo ContArranjo hiddenLayerSize Rodada performance valPerformance
% rTra mTra bTra rVal mVal bVal rTst mTst bTst rAll mAll bAll]

for Alvo =1:15
Resultados = zeros(168,18);
ContaResultados=1;
for ContArranjo = 1:4
    switch ContArranjo
    case 1
        inputs = inputs1Pt;
    case 2
        inputs = inputs2Pt;
    case 3
        inputs = inputs3Pt;
    case 4
        inputs = inputs4Pt;
    case 5
        inputs = inputs5Pt;
    end

    %Comando para carregar os dados dos valores a serem obtidos
    switch Alvo
    case 1
        % Ph
        if ContArranjo ==1
            targets = Tgt_Ph_1';
        else
            targets = Tgt_Ph_N';
        end
    case 2
        % Ca
        if ContArranjo ==1
            targets = Tgt_Ca_1';
        else
            targets = Tgt_Ca_N';
        end
    case 3
        % Mg
        if ContArranjo ==1
            targets = Tgt_Mg_1';
        else
            targets = Tgt_Mg_N';
        end
    case 4
        % CaMg
        if ContArranjo ==1
            targets = Tgt_CaMg_1';
        else
            targets = Tgt_CaMg_N';
        end
    case 5
        % Al
        if ContArranjo ==1
            targets = Tgt_Al_1';
        else
            targets = Tgt_Al_N';
        end
    case 6
        % HAl
        if ContArranjo ==1
            targets = Tgt_HAl_1';
        else
            targets = Tgt_HAl_N';
        end
    end
end

```

```

case 7
    % CTC
    if ContArranjo ==1
        targets = Tgt_CTC_1';
    else
        targets = Tgt_CTC_N';
    end
case 8
    % K
    if ContArranjo ==1
        targets = Tgt_K_1';
    else
        targets = Tgt_K_N';
    end
case 9
    % P
    if ContArranjo ==1
        targets = Tgt_P_1';
    else
        targets = Tgt_P_N';
    end
case 10
    % SatBase
    if ContArranjo ==1
        targets = Tgt_SatBase_1';
    else
        targets = Tgt_SatBase_N';
    end
case 11
    % SatAluminio
    if ContArranjo ==1
        targets = Tgt_SatAl_1';
    else
        targets = Tgt_SatAl_N';
    end
case 12
    % Mat. Org. (g kg-1)
    if ContArranjo ==1
        targets = Tgt_MatOrg_1';
    else
        targets = Tgt_MatOrg_N';
    end
case 13
    % Argila
    if ContArranjo ==1
        targets = Tgt_Argila_1';
    else
        targets = Tgt_Argila_N';
    end
case 14
    % Silte
    if ContArranjo ==1
        targets = Tgt_Silte_1';
    else
        targets = Tgt_Silte_N';
    end
case 15
    % Areia
    if ContArranjo ==1
        targets = Tgt_Areia_1';
    else
        targets = Tgt_Areia_N';
    end
end

for ContTiposRede = 1:5
    hiddenLayerSize = TiposRede(ContTiposRede);
    % Indicando quantidade de neurônios na camada escondida

    net = fitnet(hiddenLayerSize);
    % Takes a row vector of N hidden layer sizes,
    % and a back-propagation training function, and returns
    % a feed-forward neural network with N+1 layers.
    % Choose Input and Output Pre/Post-Processing Functions
    % For a list of all processing functions type: help nnprocess

    net.inputs{1}.processFcns = {'removeconstantrows', 'mapminmax'};

```

```

net.outputs{2}.processFcns = {'removeconstantrows','mapminmax'};
% Utilizado para NOrmalizar os dados, porém, já estou trazendo os
% dados normalizados entre -1 e 1.

% Aqui será separado os subconjuntos de dados para treinamento da RNA
% treinamento, validação e teste de acordo com o tamanho da matriz input.
% Lembrar que com arranjo = 1 a matriz possui 11990 linhas e para os
% demais possui 55000 linhas (110 * 500 combinacoes sorteadas)

net.divideFcn = 'divideind';
if ContArranjo == 1
    % 82 * 109 = treino
    net.divideParam.trainInd = 1:8938;
    % 17 * 109 = validacao
    net.divideParam.valInd = 8939:10791;
    % 11 * 109 = teste
    net.divideParam.testInd = 10792:11990;
else
    % 82 * 500 = treino
    net.divideParam.trainInd = 1:41000;
    % 17 * 500 = validacao
    net.divideParam.valInd = 41001:49500;
    % 11 * 500 = teste
    net.divideParam.testInd = 49501:55000;
end
% Todas matrizes utilizadas neste de dados entrada e saída t
% (entradas=inputs ou alvos=targets) foram geradas
% levando em consideração sorteio inicial dos dados na proporção
% 75%, 15% e 10% e numeração das amostras gravadas, posteriormente
% utilizadas para geração das matrizes de todos os treinamentos.
% O que explica a divisão do treinamento por índices e numeração
% fixa para os itens usados. A parte randômica ocorreu antes da
% geração das matrizes.

net.layers{1}.transferFcn = 'tansig';
% For a list of all training functions type: help nntrain
%
% Esse Função de ativação aqui, eu que mudei para as duas camadas
% utilizarem funções de ativação do tipo TanSigmoid
net.layers{2}.transferFcn = 'tansig';
%

net.trainFcn = 'trainlm'; % Levenberg-Marquardt
% Função de treinamento Back Propagation tipo Levenberg-Marquardt
% Para listar todas funções de treinamento digite: help nntrain

net.performFcn = 'mse';
% Mean squared error = erro médio quadrado - será utilizado para
% cálculo de performance
% Para listar todos digite: help nnperformance

net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
    'plotregression','plotfit'};
% Choose Plot Functions
% For a list of all plot functions type: help nnplot

for Rodada = 1:6
    net = init(net);
    % Reinicializando (Pesos e bias) para ter certeza que a
    % próxima rede será iniciada com outros valores.

    %
    % net.trainParam.epochs = 1000;
    % Maximum number of epochs to train. default= 1000

    % net.trainParam.goal = 0;
    % Performance goal. default = 0

    % net.trainParam.showCommandLine false
    % Generate command-line output. default = false

    % net.trainParam.showWindow true
    % Show training GUI. default = true

```



```

% net.trainParam.lr 0.01
% Learning rate . default = 0.01

% net.trainParam.max_fail = 6;
% Maximum validation failures 6 = default

net.trainParam.min_grad = 1e-15;
% Objetivo de Performance mínima default = 1e-6;

% net.trainParam.show 25
% Epochs between displays (NaN for no displays)

% net.trainParam.time inf
% Maximum time to train in seconds

% Parametros Especificos trainlm
% http://www.mathworks.com/help/nnet/ref/trainlm.html
% net.trainParam.mu 0.001 Initial mu
% net.trainParam.mu_dec 0.1 mu decrease factor
% net.trainParam.mu_inc 10 mu increase factor
% net.trainParam.mu_max 1e10 Maximum mu

[net,tr] = train(net,inputs,targets);
% Comando para treinar a rede, retorna a rede = (matriz net) e
% tr (matriz com registro do treinamento)

% Test the Network
outputs = net(inputs);
% Roda a rede treinada com os dados de entrada e gera as
% saídas para outputs

errors = gsubtract(targets,outputs);
% Matriz de erro gerado pela diferença entre os alvos (valor
% correto) e outputs (valor calculado)
% gsubtract(a,b) returns a - b

performance = perform(net,targets,outputs);
% Calcula a performance da rede=net comparando os dados
% targets(valor correto) e outputs(valor calculado)

% Aqui aplica as mascaras para pegar em Separado e calcular
% resultado dos subconjuntos= Training, Validation and Test Performance
trainTargets = targets .* tr.trainMask{1};
valTargets = targets .* tr.valMask{1};
testTargets = targets .* tr.testMask{1};
trainPerformance = perform(net,trainTargets,outputs);
valPerformance = perform(net,valTargets,outputs);
testPerformance = perform(net,testTargets,outputs);

% view(net)
% Caso queira ver o desenho da rede tirar o comentário da linha
% anterior

diretorio = strcat('c:\rna\Prontas\',int2str(Alvo),'\rede_',
    int2str(Rodada),'\a',int2str(ContArranjo),'\_',
    int2str(hiddenLayerSize),'\');

mkdir(diretorio);
% Cria Diretorio para Gravar todos os dados gerados

% _____ Gravacao dos Dados _____
save (strcat(diretorio,'errors'), 'errors');
save (strcat(diretorio,'hiddenLayerSize'),'hiddenLayerSize');
% save ((strcat(diretorio,'inputs'), 'inputs'));
% Inputs não precisa gravar pois é a matriz Arranjo gerada
% variando de 1 a 5 pontos de relativos
save (strcat(diretorio,'net'),'net');
save (strcat(diretorio,'outputs'),'outputs');
save (strcat(diretorio,'performance'),'performance');
% targets não precisa gravar pois é a inputs, variando de 1 a 5
% pontos de referencia e o os alvos
% save (strcat(diretorio,'targets'),'targets');
save (strcat(diretorio,'testPerformance'),'testPerformance');
save (strcat(diretorio,'testTargets'),'testTargets');
save (strcat(diretorio,'tr'),'tr');
save (strcat(diretorio,'trainPerformance'),'trainPerformance');

```

```

save (strcat(diretorio,'trainTargets'), 'trainTargets');
save (strcat(diretorio,'valPerformance'), 'valPerformance');
save (strcat(diretorio,'valTargets'), 'valTargets');

% Grava a imagem da Performance em JPG e FIG=figura=abre no matlab
saveas (plotperform(tr), strcat(diretorio,'performance'),'fig');
saveas (plotperform(tr), strcat(diretorio,'performance'),'jpg');
%Fazendo Calculos para plotar o histograma
trOut = outputs(tr.trainInd);
vOut = outputs(tr.valInd);
tsOut = outputs(tr.testInd);
trTarg = targets(tr.trainInd);
vTarg = targets(tr.valInd);
tsTarg = targets(tr.testInd);
% Gravando histograma também no formato JPG e FIG=figura
saveas (plotregression(trTarg,trOut,'Training',vTarg,vOut,'Validation',...
tsTarg,tsOut,'Test', targets,outputs, 'All'), ...
strcat(diretorio,'regressao'),'fig');
saveas (plotregression(trTarg,trOut,'Training',vTarg,vOut,'Validation',...
tsTarg,tsOut,'Test', targets, outputs,'All'), ...
strcat(diretorio,'regressao'),'jpg');

% Fazendo cálculos da regressão conforme matrizes dos
% subconjuntos
[rTra,mTra,bTra] = regression(trTarg,trOut);
[rVal,mVal,bVal] = regression(vTarg,vOut);
[rTst,mTst,bTst] = regression(tsTarg,tsOut);
[rAll,mAll,bAll] = regression(targets,outputs);

Resultados(ContaResultados,:) = [Alvo ContArranjo hiddenLayerSize Rodada
performance valPerformance rTra mTra bTra rVal mVal bVal rTst mTst bTst rAll mAll bAll];
ContaResultados = ContaResultados + 1;
% Gerando ocorrencia na matriz de resultados para posterior
% Gravação

% Linhas abaixo servem apenas para visualização do usuario no
% matlab
display(ContArranjo);
display(hiddenLayerSize);
display(Rodada);

csvwrite(strcat('c:\rna\Prontas\',int2str(ContArranjo),'_',int2str(Alvo),'result.csv'),
,Resultados);
% Grava os resultados do treinamento a cada rede treinada
% _____ Aqui praticamente termina a parte da gravação _____
% _ Porem ao finalizar a novo comando para gravação dos dados _
% __ Finais de cada Atributo de Solo _____

end
end
end
csvwrite(strcat('c:\rna\Prontas\',int2str(Alvo),'result.csv'),Resultados);
% Comando para Gravar o resultado Final com todas informações do atributo
end

```

APÊNDICE D

9.1 Programa criado e utilizado geração das matrizes de dados para teste e resultados das RNAs escolhidas.

```
% Gerar Arranjos para teste das RNAs
% Escrito por ROberto Dib Bittar - rdbittar@yahoo.com.br
% 2015 - Outubro
%Apagar as variaveis
clear;
% Limpar o Workspace
clc;

% MatOrigemTotal = 120 amostras normalizadas no excel, importadas na opção
% Import Data do Matlab, posteriormente gravada com nome MatAmostrasTotal
load('c:\rma\MatAmostrasTotal.mat')

% MatAmostrasLocalXYTotal = 120 Localizacoes amostras (sem normalizar), importadas na opção
% Import Data do Matlab, posteriormente gravada com nome MatAmostrasLocalXYTotal
load('c:\rma\MatAmostrasLocalXYTotal.mat')

%Amostras Teste - Gerada pelo AmostrasTesteFinalRede
% Matriz com 4 colunas geradas de forma aleatório entre as 10 que
% amostras que não entraram no treinamento da rede
load('c:\rma\teste\AmostrasTesteFinalRede.mat')

% Agora sera gerado matriz para treinamento com 1 ponto referencial
% Os dois primeiros valores são coordenadas geográficas x,y que será testado depois vem os outros
% 18 atributos de cada amostra, quando repetir o ponto com ele mesmo, este
% deverá ser excluído (orientação Prof. Francisco)

% X (UTM) deltax = diferenca absoluta entre x relativo e x referencial
% y(UTM) deltax = diferenca absoluta entre y relativo e y referencial
% altitude (m)
% pH (CaCl2) (cmolc dm-3)
% Ca (cmolc dm-3)
% Mg(cmolc dm-3)
% Ca+Mg(cmolc dm-3)
% Al(cmolc dm-3)
% H + Al(cmolc dm-3)
% CTC(cmolc dm-3)
% K(cmolc dm-3)
% P (mg dm-3)
% Sat.Al.(%)
% Sat. Base(%)
% Mat. Org. (g kg-1)
% Argila(t/hc)
% Silte(t/hc)
% Areia(t/hc)

% Valores utilizados para normalização
xmin = 0;
xmax = 10000;
ymin = 0;
ymax = 10000;
d2=1;
d1=-1;

Teste1Ponto = zeros (120,20);
Teste2Ponto = zeros (120,38);
Teste3Ponto = zeros (120,56);
Teste4Ponto = zeros (120,74);

Contador=0;
for contReferencial = 1:120
    % calcular os delta = distancia entre pontos
    xreferencial = MatAmostrasLocalXYTotal(contReferencial,1);
    yreferencial = MatAmostrasLocalXYTotal(contReferencial,2);

    % Calculando Deltas para ponto 1
    xrelativo1 = MatAmostrasLocalXYTotal(AmostrasTesteFinalRede(1),1);
    yrelativo1 = MatAmostrasLocalXYTotal(AmostrasTesteFinalRede(1),2);
```

```

if xreferencial > xrelativo1
    deltax1 = xreferencial - xrelativo1;
else
    deltax1 = xrelativo1 - xreferencial;
end

if yreferencial > yrelativo1
    deltax1 = yreferencial - yrelativo1;
else
    deltax1 = yrelativo1 - yreferencial;
end
%Normalizando os valores de delta
deltaxnorm1 = (((deltax1 - xmin)*(d2 - d1))/(xmax - xmin)) + d1;
deltaynorm1 = (((deltay1 - ymin)*(d2 - d1))/(ymax - ymin)) + d1;
% Fim Calculo Delta Ponto Relativo 1 _____

% Calculo para delta do ponto 2
xrelativo2 = MatAmostrasLocalXYTotal(AmostrasTesteFinalRede(2),1);
yrelativo2 = MatAmostrasLocalXYTotal(AmostrasTesteFinalRede(2),2);
if xreferencial > xrelativo2
    deltax2 = xreferencial - xrelativo2;
else
    deltax2 = xrelativo2 - xreferencial;
end
if yreferencial > yrelativo2
    deltax2 = yreferencial - yrelativo2;
else
    deltax2 = yrelativo2 - yreferencial;
end
%Normalizando os valores de delta
deltaxnorm2 = (((deltax2 - xmin)*(d2 - d1))/(xmax - xmin)) + d1;
deltaynorm2 = (((deltay2 - ymin)*(d2 - d1))/(ymax - ymin)) + d1;
% Fim Calculo Delta Ponto Relativo 2 _____

% Calculo para delta do ponto 3
xrelativo3 = MatAmostrasLocalXYTotal(AmostrasTesteFinalRede(3),1);
yrelativo3 = MatAmostrasLocalXYTotal(AmostrasTesteFinalRede(3),2);
if xreferencial > xrelativo3
    deltax3 = xreferencial - xrelativo3;
else
    deltax3 = xrelativo3 - xreferencial;
end
if yreferencial > yrelativo3
    deltax3 = yreferencial - yrelativo3;
else
    deltax3 = yrelativo3 - yreferencial;
end
%Normalizando os valores de delta
deltaxnorm3 = (((deltax3 - xmin)*(d2 - d1))/(xmax - xmin)) + d1;
deltaynorm3 = (((deltay3 - ymin)*(d2 - d1))/(ymax - ymin)) + d1;
% Fim Calculo Delta Ponto Relativo 3 _____

% Calculo para delta do ponto 4
xrelativo4 = MatAmostrasLocalXYTotal(AmostrasTesteFinalRede(4),1);
yrelativo4 = MatAmostrasLocalXYTotal(AmostrasTesteFinalRede(4),2);
if xreferencial > xrelativo4
    deltax4 = xreferencial - xrelativo4;
else
    deltax4 = xrelativo4 - xreferencial;
end
if yreferencial > yrelativo4
    deltax4 = yreferencial - yrelativo4;
else
    deltax4 = yrelativo4 - yreferencial;
end
%Normalizando os valores de delta
deltaxnorm4 = (((deltax4 - xmin)*(d2 - d1))/(xmax - xmin)) + d1;
deltaynorm4 = (((deltay4 - ymin)*(d2 - d1))/(ymax - ymin)) + d1;
% Fim Calculo Delta Ponto Relativo 4 _____

% Função cat , concatena diferentes matriz, a matriz resposta
% terá a soma dos elementos indicados pela dimensão que foi
% considerada, onde 1=linha, 2 = coluna e 3 seria uma terceira

```

```

% dimensão como resposta

% MOntando Linha com 1 ponto referencial e 2 pontos relativo_____
Linha1 = cat (2, MatAmostrasTotal(contReferencial,1:2),...
    deltaxnorm1,deltaynorm1,MatAmostrasTotal(AmostrasTesteFinalRede(1),3:18));
% FInalizando calculo 1 x 1

% MOntando Linha com 1 ponto referencial e 2 pontos relativo_____
Linha2 = cat (2, MatAmostrasTotal(contReferencial,1:2),...
    deltaxnorm1,deltaynorm1,MatAmostrasTotal(AmostrasTesteFinalRede(1),3:18),...
    deltaxnorm2,deltaynorm2,MatAmostrasTotal(AmostrasTesteFinalRede(2),3:18));
% FInalizando calculo 1 x 2

% MOntando Linha com 1 ponto referencial e 3 pontos relativo_____
Linha3 = cat (2, MatAmostrasTotal(contReferencial,1:2),...
    deltaxnorm1,deltaynorm1,MatAmostrasTotal(AmostrasTesteFinalRede(1),3:18),...
    deltaxnorm2,deltaynorm2,MatAmostrasTotal(AmostrasTesteFinalRede(2),3:18),...
    deltaxnorm3,deltaynorm3,MatAmostrasTotal(AmostrasTesteFinalRede(3),3:18));
% FInalizando calculo 1 x 3

% MOntando Linha com 1 ponto referencial e 4 pontos relativo_____
Linha4 = cat (2, MatAmostrasTotal(contReferencial,1:2),...
    deltaxnorm1,deltaynorm1,MatAmostrasTotal(AmostrasTesteFinalRede(1),3:18),...
    deltaxnorm2,deltaynorm2,MatAmostrasTotal(AmostrasTesteFinalRede(2),3:18),...
    deltaxnorm3,deltaynorm3,MatAmostrasTotal(AmostrasTesteFinalRede(3),3:18),...
    deltaxnorm4,deltaynorm4,MatAmostrasTotal(AmostrasTesteFinalRede(4),3:18));
% FInalizando calculo 1 x 4

Contador = Contador + 1;
Teste1Ponto(Contador,:) = Linha1 ;
Teste2Ponto(Contador,:) = Linha2 ;
Teste3Ponto(Contador,:) = Linha3 ;
Teste4Ponto(Contador,:) = Linha4 ;
end

save ('c:\rna\teste\Teste1Ponto', 'Teste1Ponto');
save ('c:\rna\teste\Teste2Ponto', 'Teste2Ponto');
save ('c:\rna\teste\Teste3Ponto', 'Teste3Ponto');
save ('c:\rna\teste\Teste4Ponto', 'Teste4Ponto');
h = msgbox ('Encerrado');

```

9.2 Programa criado e utilizado para teste das RNAs escolhidas

```

% Realizar teste das melhores RNAs treinadas
% Escrito por ROberto Dib Bittar - rdbittar@yahoo.com.br
% 2015 - Outubro
%Apagar as variaveis
clear;
% Limpar o Workspace
clc;
load('d:\rna\Prontas\MelhoresRedes.mat')
load('d:\rna\teste\Teste1Ponto.mat')
load('d:\rna\teste\Teste2Ponto.mat')
load('d:\rna\teste\Teste3Ponto.mat')
load('d:\rna\teste\Teste4Ponto.mat')
% Atenção, resultados está usando matriz transposta

MatrizResultados = zeros(120,120);
ContaResultados = 0;

for contador=1:60
    Atributo = MelhoresRedes (contador,1);
    Amostras = MelhoresRedes (contador,2);
    Neuronios = MelhoresRedes (contador,3);
    Rodada = MelhoresRedes (contador,4);
    RedeAlvo =
strcat('d:\rna\Prontas\',int2str(Atributo),'rede_',int2str(Rodada),'a',int2str(Amostras),'_',int2str(Neuronios),'net.mat');
    load(RedeAlvo)

    switch Amostras
        case 1
            transp = Teste1Ponto.';
        case 2

```

```

    transp = Teste2Ponto.';
case 3
    transp = Teste3Ponto.';
case 4
    transp = Teste4Ponto.';
end

switch Atributo
% Cada Target foi gerado e importado (utilizando import)arquivo
% amostras = Todas as 120 amostras para cada atributo de solo com
% valores já normalizados
case 1
    % Ph _____
    load('d:\rna\teste\TgtTest_Ph_120.mat');
    tgttransp = TgtTest_Ph_120.';
case 2
    % Ca _____
    load('d:\rna\teste\TgtTest_Ca_120.mat');
    tgttransp = TgtTest_Ca_120.';
case 3
    % Mg _____
    load('d:\rna\teste\TgtTest_Mg_120.mat');
    tgttransp = TgtTest_Mg_120.';
case 4
    % CaMg _____
    load('d:\rna\teste\TgtTest_CaMg_120.mat');
    tgttransp = TgtTest_CaMg_120.';
case 5
    % Al _____
    load('d:\rna\teste\TgtTest_Al_120.mat');
    tgttransp = TgtTest_Al_120.';
case 6
    % HAl _____
    load('d:\rna\teste\TgtTest_HAl_120.mat');
    tgttransp = TgtTest_HAl_120.';
case 7
    % CTC _____
    load('d:\rna\teste\TgtTest_CTC_120.mat');
    tgttransp = TgtTest_CTC_120.';
case 8
    % K _____
    load('d:\rna\teste\TgtTest_K_120.mat');
    tgttransp = TgtTest_K_120.';
case 9
    % P _____
    load('d:\rna\teste\TgtTest_P_120.mat');
    tgttransp = TgtTest_P_120.';
case 10
    % SatBase _____
    load('d:\rna\teste\TgtTest_SatBase_120.mat');
    tgttransp = TgtTest_SatBase_120.';
case 11
    % SatAluminio _____
    load('d:\rna\teste\TgtTest_SatAl_120.mat');
    tgttransp = TgtTest_SatAl_120.';
case 12
    % Mat. Org. (g kg-1)
    load('d:\rna\teste\TgtTest_MatOrg_120.mat');
    tgttransp = TgtTest_MatOrg_120.';
case 13
    % Argila _____
    load('d:\rna\teste\TgtTest_Argila_120.mat');
    tgttransp = TgtTest_Argila_120.';
case 14
    % Silte _____
    load('d:\rna\teste\TgtTest_Silte_120.mat');
    tgttransp = TgtTest_Silte_120.';
case 15
    % Areia _____
    load('d:\rna\teste\TgtTest_Areia_120.mat');
    tgttransp = TgtTest_Areia_120.';
end

y = net (transp);

ContaResultados=ContaResultados+1;

```

```
MatrizResultados(ContaResultados,:)=y;

ContaResultados=ContaResultados+1;
MatrizResultados(ContaResultados,:)=tgttransp;

display(contador);
% Obtive Resposta ans = mse
% Erro Médio Quadrático
end
csvwrite('d:\rna\teste\ResulFimTeste3.csv',MatrizResultados);
h = msgbox ('Encerrado');
```

APÊNDICE E

TABELA 10. Comparação valores aferidos x valores estimados: Mg

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
1	1,30	1,22	0,98	1,14	1,16	1,18	6,15	24,45	12,18	10,77	9,10
2	0,90	0,87	1,07	1,07	1,10	1,06	3,33	18,97	18,38	22,76	17,45
3	0,90	1,21	0,78	0,96	1,03	0,95	34,44	12,82	6,97	14,68	5,43
4	0,90	0,77	0,78	0,92	0,98	0,92	14,44	13,74	1,86	8,79	2,18
5	1,00	0,91	0,78	0,90	0,95	0,91	9,00	22,25	9,71	4,59	8,75
6	0,90	0,85	0,68	1,23	1,36	1,27	5,56	24,55	36,95	51,07	40,97
7	0,70	0,93	0,79	0,88	0,88	0,89	32,86	13,43	25,92	25,60	27,34
8	0,90	1,06	0,80	0,88	0,87	0,89	17,78	11,31	1,91	3,47	1,22
9	0,70	0,84	0,78	0,88	0,86	0,88	20,00	11,86	26,31	23,19	26,27
10	0,60	0,84	0,75	0,88	0,86	0,87	40,00	25,53	46,74	42,72	45,60
11	0,70	0,91	0,77	0,88	0,85	0,87	30,00	9,67	25,78	21,93	24,00
12	0,80	0,76	0,83	0,88	0,85	0,87	5,00	3,43	10,16	6,55	8,20
13	0,90	0,98	0,87	0,88	0,85	0,86	8,89	3,25	2,28	5,59	4,29
14	0,70	0,99	0,91	0,88	0,85	0,86	41,43	30,45	25,50	21,00	22,75
15	0,80	0,91	0,96	0,90	0,87	0,91	13,75	20,31	12,54	8,98	13,24
16	1,10	0,92	0,96	0,90	0,87	0,90	16,36	12,86	18,11	20,64	17,86
17	1,00	1,05	0,95	0,90	0,87	0,90	5,00	4,82	9,81	12,70	9,72
18	1,20	1,27	0,95	0,91	0,88	0,91	5,83	21,01	24,44	26,90	24,10
19	0,90	0,99	0,92	0,90	0,87	0,91	10,00	2,25	0,43	2,79	0,75
20	0,90	0,99	0,91	0,91	0,88	0,91	10,00	0,74	0,65	2,46	1,41
21	0,60	1,02	0,91	0,90	0,88	0,92	70,00	51,60	50,65	46,98	52,54
22	0,90	1,20	0,93	0,90	0,89	0,91	33,33	3,83	0,05	1,21	1,60
23	0,80	0,85	0,93	0,90	0,90	0,92	6,25	16,05	12,52	12,40	14,49
24	1,00	0,93	0,88	0,90	0,91	0,92	7,00	11,56	9,77	8,69	8,13
25	0,80	1,22	0,84	0,91	0,93	0,92	52,50	4,88	13,17	15,88	15,08
26	0,80	0,93	0,80	0,91	0,95	0,92	16,25	0,03	14,04	18,70	15,50
27	0,80	1,01	0,80	0,92	0,97	0,93	26,25	0,61	15,46	21,45	16,15
28	0,90	1,21	0,84	0,94	1,00	0,94	34,44	7,08	4,42	11,07	3,94
29	0,80	0,88	1,01	0,96	1,03	0,95	10,00	26,37	20,04	28,36	18,26
30	0,80	1,01	1,06	0,99	1,05	0,96	26,25	33,10	23,33	31,67	20,32
31	0,90	1,23	1,02	1,02	1,08	0,99	36,67	13,26	13,53	20,43	9,96
32	1,00	0,78	0,96	1,06	1,11	1,03	22,00	4,40	5,80	11,21	2,51
33	1,00	0,91	0,89	1,09	1,14	1,07	9,00	11,07	9,41	14,03	6,84
34	0,80	1,00	0,85	1,13	1,17	1,12	25,00	5,91	41,26	46,23	40,32
35	0,70	0,99	0,82	1,14	1,19	1,11	41,43	16,80	62,26	70,09	57,90
36	0,90	0,90	0,83	1,10	1,16	1,06	0,00	8,07	22,50	29,30	17,38
37	0,80	0,90	0,85	1,07	1,13	1,02	12,50	6,10	33,44	41,41	27,40
38	0,60	1,29	0,90	1,03	1,10	0,99	115,00	49,85	72,01	82,61	65,25
39	0,90	0,89	1,00	1,00	1,06	0,97	1,11	10,74	11,17	17,75	8,14
40	0,90	0,96	1,16	0,97	1,03	0,96	6,67	28,33	8,27	13,99	6,84
41	2,10	1,45	1,36	0,96	1,00	0,96	30,95	35,02	54,41	52,42	54,42
42	1,20	1,30	1,47	0,94	0,97	0,95	8,33	22,69	21,59	19,04	20,69
43	1,00	0,95	1,33	0,93	0,95	0,95	5,00	33,10	6,72	4,69	4,93
44	0,90	1,44	1,19	0,93	0,94	0,95	60,00	31,77	2,98	3,98	5,39
45	1,00	1,15	1,09	0,93	0,93	0,95	15,00	9,37	7,36	7,46	4,85
46	0,90	1,00	1,01	0,93	0,92	0,95	11,11	11,82	3,03	1,90	5,93
47	0,60	0,73	0,97	0,93	0,91	0,95	21,67	61,77	54,53	51,43	58,57

...continua...

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
48	0,90	1,58	0,96	0,93	0,91	0,96	75,56	6,78	3,85	0,67	6,70
49	0,80	0,93	0,96	0,94	0,91	0,96	16,25	20,25	17,03	13,22	20,45
50	0,90	0,69	0,96	0,93	0,90	0,96	23,33	7,03	3,78	0,49	6,93
51	0,60	0,83	0,96	0,93	0,91	0,97	38,33	60,74	55,66	50,94	60,95
52	0,90	0,84	0,97	0,93	0,91	0,97	6,67	7,27	3,80	0,94	8,09
53	0,90	1,13	0,97	0,93	0,91	0,97	25,56	7,29	3,22	0,71	7,69
54	0,90	0,79	0,97	0,93	0,91	0,98	12,22	7,32	3,32	0,78	8,44
55	1,00	1,28	0,97	0,98	0,95	1,09	28,00	3,39	2,06	4,85	8,74
56	0,90	0,92	0,97	0,98	0,95	1,09	2,22	7,33	8,94	5,86	20,63
57	1,00	0,76	0,97	0,98	0,95	1,08	24,00	3,40	2,23	5,03	7,66
58	1,10	0,82	0,97	0,98	0,95	1,07	25,45	12,21	11,05	13,66	2,56
59	1,30	0,84	0,97	0,98	0,95	1,07	35,38	25,75	24,69	26,90	17,83
60	0,70	0,87	0,96	0,98	0,95	1,06	24,29	37,79	39,53	35,55	51,12
61	1,30	0,94	0,96	0,97	0,95	1,05	27,69	25,94	25,27	26,93	19,52
62	1,20	1,22	0,96	0,96	0,95	1,03	1,67	19,69	19,74	20,77	14,06
63	0,90	0,80	1,02	0,96	0,96	1,02	11,11	13,55	6,44	6,14	13,27
64	1,10	1,02	1,29	0,96	0,96	1,01	7,27	17,48	13,01	12,52	7,93
65	1,20	0,92	1,45	0,96	0,97	1,01	23,33	20,74	19,99	18,78	15,86
66	1,50	0,78	1,55	0,97	0,99	1,00	48,00	3,44	35,58	33,89	33,08
67	1,30	0,95	1,61	0,98	1,01	1,00	26,92	23,77	24,99	22,25	23,35
68	1,30	0,96	1,55	0,99	1,03	1,00	26,15	19,52	23,96	20,48	23,42
69	1,40	1,38	1,41	1,01	1,07	1,00	1,43	0,56	27,72	23,58	28,61
70	1,30	0,89	1,23	1,04	1,11	1,01	31,54	5,76	20,08	14,76	22,40
71	1,20	0,79	1,08	1,07	1,15	1,03	34,17	9,99	10,91	4,34	14,52
72	1,00	0,68	0,98	1,10	1,19	1,05	32,00	1,95	10,39	19,28	5,40
73	1,30	0,82	1,30	1,17	1,30	1,14	36,92	0,14	9,87	0,06	12,64
74	1,70	0,83	1,47	1,14	1,25	1,11	51,18	13,77	32,94	26,21	34,98
75	1,80	1,43	1,54	1,11	1,21	1,09	20,56	14,42	38,28	32,80	39,42
76	1,30	1,25	1,54	1,08	1,16	1,07	3,85	18,74	17,25	11,05	17,67
77	1,60	1,17	1,49	1,05	1,12	1,07	26,88	7,05	34,15	30,00	33,17
78	1,00	0,94	1,36	1,03	1,08	1,07	6,00	35,55	3,20	8,42	6,77
79	1,60	0,93	1,13	1,03	1,07	1,09	41,88	29,31	35,59	33,07	31,56
80	1,00	0,92	1,17	1,01	1,03	1,08	8,00	16,88	0,56	3,20	7,83
81	0,90	0,75	1,17	1,02	1,03	1,11	16,67	30,54	12,91	14,70	23,11
82	1,70	1,26	1,25	1,02	1,03	1,13	25,88	26,30	39,83	39,61	33,77
83	1,40	0,82	1,31	1,02	1,02	1,13	41,43	6,68	27,00	27,35	19,41
84	1,40	1,16	1,14	1,02	1,01	1,13	17,14	18,37	27,00	28,04	19,26
85	0,90	1,02	0,99	1,05	1,02	1,16	13,33	9,64	16,80	13,81	29,34
86	1,00	1,51	0,96	1,05	1,02	1,17	51,00	4,14	5,36	2,18	16,95
87	0,80	0,99	0,96	1,05	1,01	1,16	23,75	20,38	30,84	26,52	45,53
88	1,00	0,97	0,96	1,05	1,01	1,17	3,00	3,53	4,88	1,18	16,56
89	0,90	1,05	0,97	1,06	1,02	1,17	16,67	7,27	17,64	13,12	30,07
90	1,10	0,91	0,97	1,06	1,01	1,16	17,27	12,19	4,04	8,02	5,91
91	1,00	0,83	0,96	1,15	1,11	1,20	17,00	3,62	15,38	11,09	19,90
92	0,90	0,91	0,96	1,14	1,10	1,21	1,11	6,86	26,73	22,34	34,00
93	0,70	0,76	0,96	1,15	1,11	1,22	8,57	36,65	63,93	59,13	73,62
94	1,00	1,06	0,96	1,15	1,12	1,22	6,00	3,70	14,54	11,57	22,29
95	1,60	0,95	1,13	1,15	1,12	1,23	40,63	29,11	28,33	29,90	23,10
96	1,80	1,01	1,27	1,14	1,12	1,23	43,89	29,41	36,82	37,98	31,73
97	1,40	0,95	1,18	1,14	1,13	1,23	32,14	15,97	18,64	19,01	12,02
98	0,80	1,19	1,13	1,11	1,12	1,22	48,75	41,66	39,26	39,65	52,10

...continua...

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
99	1,30	1,86	1,04	1,12	1,14	1,22	43,08	19,78	13,81	12,40	6,17
100	1,20	1,60	0,97	1,11	1,15	1,21	33,33	18,84	7,22	4,48	0,86
101	0,80	0,73	0,86	1,11	1,16	1,20	8,75	7,24	39,32	45,43	50,31
102	0,60	1,13	0,80	1,12	1,18	1,19	88,33	32,76	85,96	96,16	98,49
103	0,60	0,95	0,74	1,14	1,23	1,18	58,33	23,63	89,68	104,31	96,08
104	0,70	0,90	0,88	1,15	1,24	1,10	28,57	25,39	63,79	77,80	57,62
105	0,70	1,16	0,78	1,16	1,27	1,18	65,71	11,48	66,05	80,87	68,57
106	0,70	0,92	1,03	1,10	1,13	1,11	31,43	46,92	57,66	61,76	58,88
107	0,90	0,89	0,90	1,22	1,36	1,22	1,11	0,55	35,89	51,16	35,15
108	0,90	0,74	0,79	1,33	1,48	1,32	17,78	12,09	47,26	64,57	46,89
109	0,80	0,68	0,72	1,30	1,45	1,30	15,00	10,59	62,43	80,96	61,90
110	0,70	0,98	0,69	1,28	1,42	1,28	40,00	1,70	82,82	103,49	83,21
111	0,70	0,85	0,68	1,26	1,40	1,27	21,43	2,69	79,62	99,47	81,86
112	0,70	0,84	0,68	1,24	1,38	1,27	20,00	2,91	77,58	96,65	81,37
113	0,80	0,84	0,78	0,89	0,93	0,91	5,00	2,42	11,72	16,17	13,29
114	1,30	1,51	1,06	1,03	1,08	1,01	16,15	18,69	20,97	16,95	22,31
115	1,20	0,81	0,87	1,00	1,06	0,98	32,50	27,59	16,98	11,88	18,53
116	0,80	0,72	0,78	0,94	1,01	0,93	10,00	3,01	17,41	26,11	16,59
117	0,90	0,75	0,78	0,89	0,91	0,90	16,67	13,20	1,54	1,28	0,10
118	0,80	0,68	0,79	0,88	0,90	0,90	15,00	1,85	10,44	12,24	12,02
119	0,80	1,21	0,73	1,13	1,20	1,18	51,25	8,25	40,98	50,56	47,96
120	0,60	0,93	0,87	1,19	1,31	1,19	55,00	45,03	97,68	117,60	97,65
Erro médio relativo							24,47	16,25	24,63	26,56	25,60

PA- Ponto Amostral; VR- Valor Real; VE KO- Valor Estimado Pela Krigagem Ordinária; VE RNA 1AR- Valor Estimado RNA 1 PA Relativo; VE RNA 2AR- Valor Estimado RNA 2 PA Relativos; VE RNA 3AR- Valor estimado RNA 3 PA Relativos; VE RNA 4AR- Valor estimado RNA 4 PA Relativos; P(K) - Erro Médio Relativo Krigagem; P (1AR)- Erro Médio Relativo RNA 1 PA Relativo; P (2AR)- Erro Médio Relativo RNA 2 PA Relativos; P (3AR)- Erro Médio Relativo RNA 3 PA Relativos; P (4AR)- Erro Médio Relativo RNA 4 PA Relativos.

TABELA 11. Comparação valores aferidos x valores estimados: CTC

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
1	9,40	9,03	8,01	8,58	8,26	8,74	3,94	14,81	8,77	12,14	7,00
2	7,90	7,52	8,00	8,59	8,15	8,81	4,81	1,26	8,79	3,17	11,57
3	7,50	8,49	7,97	7,22	7,91	7,60	13,20	6,32	3,67	5,51	1,34
4	7,40	6,77	7,73	7,28	7,70	7,60	8,51	4,45	1,60	4,10	2,69
5	8,80	8,17	7,47	7,33	7,62	7,60	7,16	15,06	16,67	13,36	13,68
6	7,50	7,70	8,03	8,27	7,79	8,28	2,67	7,01	10,26	3,90	10,42
7	6,20	8,04	7,15	7,46	7,42	7,59	29,68	15,27	20,37	19,63	22,44
8	7,50	7,92	7,15	7,47	7,40	7,58	5,60	4,62	0,33	1,39	1,09
9	7,40	6,87	7,16	7,48	7,37	7,53	7,16	3,19	1,09	0,42	1,80
10	5,80	7,04	7,17	7,48	7,35	7,41	21,38	23,68	29,00	26,74	27,76
11	7,80	7,39	7,19	7,48	7,34	7,27	5,26	7,85	4,16	5,89	6,81
12	6,80	7,49	7,21	7,46	7,34	7,22	10,15	5,97	9,73	7,90	6,12
13	8,00	7,97	7,22	7,43	7,33	7,20	0,38	9,76	7,08	8,34	9,96
14	6,80	8,63	7,24	7,38	7,33	7,20	26,91	6,47	8,57	7,80	5,88
15	6,80	7,49	7,40	7,35	7,35	7,20	10,15	8,86	8,06	8,05	5,88
16	8,30	7,68	7,37	7,41	7,35	7,20	7,47	11,25	10,72	11,43	13,24
17	7,70	8,25	7,34	7,45	7,36	7,21	7,14	4,73	3,26	4,42	6,40
18	8,20	8,52	7,33	7,47	7,38	7,23	3,90	10,57	8,90	9,95	11,78
19	7,10	8,10	7,28	7,48	7,39	7,34	14,08	2,54	5,36	4,15	3,37
20	7,00	8,08	7,26	7,48	7,42	7,49	15,43	3,76	6,91	6,05	6,97
21	6,70	7,57	7,24	7,48	7,47	7,57	12,99	8,09	11,66	11,45	13,05
22	8,10	8,52	7,24	7,47	7,53	7,59	5,19	10,67	7,74	7,09	6,27
23	7,50	6,90	7,28	7,46	7,60	7,60	8,00	2,96	0,51	1,40	1,30
24	8,50	7,97	7,43	7,44	7,71	7,60	6,24	12,60	12,44	9,30	10,56
25	7,50	8,65	7,62	7,42	7,77	7,61	15,33	1,63	1,08	3,61	1,42
26	7,40	8,03	7,85	7,37	7,88	7,61	8,51	6,05	0,34	6,55	2,81
27	7,30	8,31	7,98	7,33	7,97	7,61	13,84	9,35	0,48	9,24	4,22
28	8,80	8,26	8,02	7,28	8,03	7,60	6,14	8,87	17,29	8,71	13,58
29	8,20	7,08	8,03	7,23	8,06	7,60	13,66	2,11	11,85	1,76	7,33
30	8,10	8,41	8,03	7,21	8,17	7,59	3,83	0,82	10,94	0,84	6,32
31	8,10	8,42	8,03	7,74	8,19	7,94	3,95	0,83	4,43	1,08	1,92
32	8,40	7,84	8,03	8,54	8,42	8,78	6,67	4,35	1,71	0,25	4,53
33	8,20	8,54	8,04	8,60	8,37	8,74	4,15	1,92	4,84	2,10	6,53
34	7,30	8,16	8,05	8,59	8,51	8,67	11,78	10,34	17,63	16,64	18,83
35	6,40	7,72	8,12	8,98	8,28	8,61	20,63	26,89	40,36	29,35	34,54
36	7,30	7,38	8,12	9,24	8,06	8,68	1,10	11,23	26,52	10,47	18,89
37	6,60	7,15	8,12	8,40	8,08	8,02	8,33	22,98	27,26	22,44	21,46
38	6,50	8,21	8,12	7,93	8,09	7,62	26,31	24,93	22,06	24,50	17,20
39	7,60	7,54	8,13	7,96	8,24	7,68	0,79	6,91	4,68	8,36	1,08
40	8,00	8,09	8,13	7,98	8,54	7,71	1,13	1,66	0,31	6,73	3,64
41	10,50	10,90	8,15	8,07	8,28	7,92	3,81	22,34	23,17	21,17	24,60

...continua...

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
48	8,20	10,13	7,46	8,02	7,63	8,00	23,54	9,04	2,18	6,97	2,45
49	6,80	7,56	7,47	8,05	7,55	7,82	11,18	9,82	18,40	11,08	15,06
50	8,30	7,63	7,48	7,93	7,49	7,43	8,07	9,83	4,50	9,71	10,45
51	6,30	7,21	7,51	7,95	7,46	7,33	14,44	19,24	26,25	18,46	16,37
52	8,00	8,09	7,55	7,99	7,42	7,28	1,13	5,60	0,09	7,23	9,01
53	8,80	8,23	7,56	7,58	7,40	7,21	6,48	14,04	13,90	15,91	18,11
54	8,20	6,66	7,60	7,61	7,38	7,20	18,78	7,35	7,13	9,96	12,14
55	8,20	9,36	7,77	8,14	7,49	7,91	14,15	5,27	0,77	8,62	3,51
56	7,30	7,30	7,74	8,21	7,55	7,92	0,00	6,07	12,40	3,39	8,46
57	7,80	7,19	7,72	8,24	7,60	7,94	7,82	1,07	5,60	2,58	1,76
58	8,00	7,55	7,71	8,26	7,71	8,05	5,63	3,67	3,24	3,67	0,60
59	8,60	7,97	7,73	8,27	7,80	8,20	7,33	10,17	3,87	9,35	4,68
60	6,20	7,13	7,80	8,27	7,90	8,32	15,00	25,80	33,41	27,36	34,15
61	8,80	8,24	8,04	8,27	8,02	8,36	6,36	8,67	6,01	8,82	4,96
62	8,70	8,30	8,27	8,27	8,15	8,37	4,60	4,97	4,95	6,31	3,74
63	7,30	7,16	8,40	8,26	8,28	8,38	1,92	15,10	13,22	13,43	14,78
64	8,40	7,91	8,43	8,26	8,35	8,38	5,83	0,38	1,69	0,60	0,24
65	8,70	8,14	8,43	8,25	8,31	8,38	6,44	3,12	5,20	4,51	3,71
66	8,60	8,00	8,39	8,23	8,32	8,37	6,98	2,41	4,33	3,24	2,65
67	8,70	8,31	8,34	8,20	8,16	8,36	4,48	4,10	5,80	6,18	3,88
68	8,50	8,07	8,31	8,16	8,14	8,35	5,06	2,21	4,00	4,20	1,78
69	8,90	8,51	8,28	8,10	8,16	8,32	4,38	6,97	8,94	8,30	6,50
70	8,40	7,80	8,26	8,04	8,11	8,29	7,14	1,72	4,25	3,50	1,36
71	8,40	7,77	8,25	7,99	8,02	8,24	7,50	1,82	4,82	4,53	1,88
72	7,00	6,26	8,25	8,08	8,07	8,20	10,57	17,90	15,37	15,35	17,09
73	8,30	7,44	8,41	8,17	8,52	8,24	10,36	1,31	1,55	2,70	0,72
74	10,80	7,72	8,43	8,04	8,24	8,17	28,52	21,92	25,58	23,71	24,37
75	11,10	8,72	8,46	8,10	8,25	8,22	21,44	23,82	27,01	25,66	25,95
76	8,90	8,50	8,46	8,14	8,04	8,26	4,49	4,96	8,51	9,70	7,16
77	9,00	8,59	8,48	8,19	7,97	8,30	4,56	5,77	9,04	11,39	7,78
78	7,60	7,61	8,50	8,22	8,14	8,33	0,13	11,84	8,11	7,05	9,61
79	9,10	8,63	8,54	8,25	8,19	8,35	5,16	6,10	9,38	9,95	8,22
80	5,90	7,27	8,55	8,25	8,22	8,37	23,22	44,99	39,90	39,27	41,82
81	7,00	6,87	8,60	8,27	8,25	8,37	1,86	22,86	18,08	17,88	19,58
82	9,70	9,67	8,63	8,27	8,20	8,37	0,31	11,03	14,73	15,49	13,71
83	8,30	7,68	8,64	8,27	8,27	8,37	7,47	4,04	0,33	0,35	0,83
84	9,90	9,68	8,60	8,27	8,18	8,37	2,22	13,13	16,42	17,41	15,49
85	7,60	7,32	8,54	8,27	8,14	8,36	3,68	12,32	8,88	7,17	9,99
86	8,20	9,22	8,28	8,27	8,13	8,34	12,44	0,99	0,90	0,87	1,65
87	6,60	6,39	7,98	8,27	7,97	8,23	3,18	20,95	25,27	20,72	24,63
88	7,40	8,44	7,88	8,26	7,89	8,05	14,05	6,50	11,59	6,59	8,73
89	7,20	8,12	7,88	8,24	7,83	7,95	12,78	9,39	14,42	8,74	10,40

...continua...

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
84	9,90	9,68	8,60	8,27	8,18	8,37	2,22	13,13	16,42	17,41	15,49
85	7,60	7,32	8,54	8,27	8,14	8,36	3,68	12,32	8,88	7,17	9,99
86	8,20	9,22	8,28	8,27	8,13	8,34	12,44	0,99	0,90	0,87	1,65
87	6,60	6,39	7,98	8,27	7,97	8,23	3,18	20,95	25,27	20,72	24,63
88	7,40	8,44	7,88	8,26	7,89	8,05	14,05	6,50	11,59	6,59	8,73
89	7,20	8,12	7,88	8,24	7,83	7,95	12,78	9,39	14,42	8,74	10,40
90	8,30	7,56	7,89	8,19	7,68	7,91	8,92	4,97	1,30	7,53	4,64
91	8,00	7,43	7,79	8,22	8,08	7,95	7,13	2,61	2,75	0,95	0,57
92	7,40	7,33	7,88	8,25	8,19	8,07	0,95	6,47	11,49	10,65	9,11
93	7,00	6,55	8,00	8,26	8,31	8,24	6,43	14,23	18,05	18,73	17,78
94	8,10	8,10	8,24	8,27	8,37	8,33	0,00	1,69	2,11	3,35	2,86
95	11,80	8,09	8,39	8,28	8,45	8,35	31,44	28,92	29,87	28,37	29,20
96	10,90	7,72	8,45	8,28	8,53	8,36	29,17	22,52	24,07	21,71	23,32
97	8,80	8,35	8,35	8,28	8,69	8,36	5,11	5,13	5,95	1,25	5,05
98	7,00	9,14	8,41	8,28	8,65	8,36	30,57	20,15	18,23	23,57	19,37
99	10,00	10,08	8,30	8,28	8,63	8,35	0,80	17,02	17,25	13,74	16,47
100	10,20	10,34	8,28	8,27	8,39	8,35	1,37	18,87	18,89	17,72	18,12
101	6,70	6,67	8,24	8,27	8,02	8,35	0,45	22,96	23,41	19,69	24,57
102	6,90	8,15	8,24	8,26	7,96	8,33	18,12	19,39	19,73	15,38	20,76
103	7,60	8,25	8,23	8,23	8,02	8,28	8,55	8,31	8,33	5,53	8,95
104	7,60	7,51	8,25	9,24	7,90	9,34	1,18	8,57	21,64	4,00	22,90
105	8,10	8,56	8,21	8,21	7,91	8,25	5,68	1,38	1,32	2,37	1,80
106	7,20	7,04	8,00	8,58	8,33	8,78	2,22	11,18	19,23	15,74	21,97
107	8,30	7,54	8,15	8,13	7,89	8,18	9,16	1,75	2,08	4,91	1,42
108	8,30	7,60	7,99	8,18	8,17	8,18	8,43	3,76	1,42	1,57	1,41
109	7,80	7,14	8,00	8,22	8,08	8,20	8,46	2,60	5,36	3,56	5,15
110	7,30	8,21	8,01	8,24	7,91	8,22	12,47	9,79	12,90	8,36	12,61
111	7,80	7,46	8,02	8,26	7,82	8,24	4,36	2,81	5,85	0,20	5,68
112	8,00	8,15	8,02	8,26	8,24	8,26	1,88	0,27	3,30	3,02	3,28
113	7,70	7,08	7,29	7,38	7,96	7,59	8,05	5,33	4,09	3,36	1,37
114	10,10	10,08	8,00	8,57	8,90	8,83	0,20	20,82	15,16	11,89	12,56
115	8,60	8,16	7,99	8,07	8,70	8,48	5,12	7,09	6,18	1,15	1,40
116	7,40	6,30	7,91	7,22	8,38	7,60	14,86	6,93	2,38	13,28	2,71
117	8,20	7,29	7,17	7,41	8,09	7,59	11,10	12,50	9,58	1,34	7,41
118	7,20	6,93	7,15	7,44	7,68	7,59	3,75	0,65	3,28	6,67	5,45
119	8,20	9,51	8,22	8,25	8,18	8,31	15,98	0,23	0,60	0,29	1,29
120	6,10	7,68	8,22	8,17	8,32	8,21	25,90	34,75	33,87	36,42	34,62
Erro médio relativo							9,29	9,89	10,91	9,94	10,51

PA- Ponto Amostral; VR- Valor Real; VE KO- Valor Estimado Pela Krigagem Ordinária; VE RNA 1AR- Valor Estimado RNA 1 PA Relativo; VE RNA 2AR- Valor Estimado RNA 2 PA Relativos; VE RNA 3AR- Valor estimado RNA 3 PA Relativos; VE RNA 4AR- Valor estimado RNA 4 PA Relativos; P(K) - Erro Médio Relativo Krigagem; P (1AR)- Erro Médio Relativo RNA 1 PA Relativo; P (2AR)- Erro Médio Relativo RNA 2 PA Relativos; P (3AR)- Erro Médio Relativo RNA 3 PA Relativos; P (4AR)- Erro Médio Relativo RNA 4 PA Relativos.

TABELA 12. Comparação valores aferidos x valores estimados: m%

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
1	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,00	0,00	0,00	0,00	0,00
2	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,00	0,00	0,00	0,00	0,00
3	0,0000	0,6600	0,0000	0,0000	0,0000	0,0005	66,00	0,00	0,00	0,00	0,05
4	0,0000	0,5600	0,0020	0,0000	0,0000	0,0000	56,00	0,20	0,00	0,00	0,00
5	0,0000	0,1900	0,0040	0,0000	0,0000	0,0000	19,00	0,40	0,00	0,00	0,00
6	0,0000	0,1100	0,0100	0,0135	0,0000	0,0000	11,00	1,00	1,35	0,00	0,00
7	0,0000	0,2000	0,0015	0,0000	0,0000	0,0000	20,00	0,15	0,00	0,00	0,00
8	0,0000	0,8100	0,0000	0,0000	0,0000	0,0000	81,00	0,00	0,00	0,00	0,00
9	0,0000	0,2200	0,0000	0,0000	0,0000	0,0000	22,00	0,00	0,00	0,00	0,00
10	0,0000	0,0700	0,0000	0,0000	0,0000	0,0000	7,00	0,00	0,00	0,00	0,00
11	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,00	0,00	0,00	0,00	0,00
12	0,0000	0,0900	0,0000	0,0000	0,0000	0,0005	9,00	0,00	0,00	0,00	0,05
13	0,0000	0,2500	0,0000	0,0000	0,0000	0,0005	25,00	0,00	0,00	0,00	0,05
14	0,0000	0,9500	0,0000	0,0000	0,0000	0,0010	95,00	0,00	0,00	0,00	0,10
15	0,0000	0,4800	0,0000	0,0000	0,0000	0,1825	48,00	0,00	0,00	0,00	18,25
16	0,0000	0,2200	0,0000	0,0000	0,0000	0,0655	22,00	0,00	0,00	0,00	6,55
17	0,0000	0,0600	0,0000	0,0000	0,0000	0,0345	6,00	0,00	0,00	0,00	3,45
18	0,0000	0,0000	0,0000	0,0000	0,0000	0,0550	0,00	0,00	0,00	0,00	5,50
19	0,0000	0,0300	0,0000	0,0000	0,0000	0,0150	3,00	0,00	0,00	0,00	1,50
20	0,0000	0,0900	0,0000	0,0000	0,0000	0,0160	9,00	0,00	0,00	0,00	1,60
21	0,0000	0,1900	0,0000	0,0000	0,0000	0,0145	19,00	0,00	0,00	0,00	1,45
22	0,0000	0,1000	0,0005	0,0000	0,0000	0,0115	10,00	0,05	0,00	0,00	1,15
23	0,0000	0,0300	0,0015	0,0000	0,0000	0,0140	3,00	0,15	0,00	0,00	1,40
24	0,0000	0,0000	0,0015	0,0000	0,0000	0,0180	0,00	0,15	0,00	0,00	1,80
25	0,0000	0,0000	0,0010	0,0000	0,0000	0,0155	0,00	0,10	0,00	0,00	1,55
26	0,0000	0,0800	0,0005	0,0000	0,0000	0,0090	8,00	0,05	0,00	0,00	0,90
27	0,0000	0,2400	0,0000	0,0000	0,0000	0,0130	24,00	0,00	0,00	0,00	1,30
28	0,0000	0,6000	0,0000	0,0000	0,0000	0,0060	60,00	0,00	0,00	0,00	0,60
29	0,0000	0,4300	0,0000	0,0000	0,0000	0,0025	43,00	0,00	0,00	0,00	0,25
30	0,0000	0,1300	0,0000	0,0000	0,0000	0,0010	13,00	0,00	0,00	0,00	0,10
31	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,00	0,00	0,00	0,00	0,00
32	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,00	0,00	0,00	0,00	0,00
33	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,00	0,00	0,00	0,00	0,00
34	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,00	0,00	0,00	0,00	0,00
35	0,0000	0,0000	0,0000	0,0000	0,0000	0,0020	0,00	0,00	0,00	0,00	0,20
36	0,0000	0,0000	0,0000	0,0000	0,0000	0,0020	0,00	0,00	0,00	0,00	0,20
37	0,0000	0,0000	0,0000	0,0000	0,0000	0,0020	0,00	0,00	0,00	0,00	0,20
38	0,0000	0,0000	0,0000	0,0000	0,0000	0,0020	0,00	0,00	0,00	0,00	0,20
39	0,0000	0,0000	0,0000	0,0000	0,0000	0,0020	0,00	0,00	0,00	0,00	0,20
40	0,0000	0,1900	0,0000	0,0000	0,0000	0,0025	19,00	0,00	0,00	0,00	0,25
41	0,0000	0,3600	0,0000	0,0000	0,0000	0,0050	36,00	0,00	0,00	0,00	0,50

...continua

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
42	0,0000	0,1600	0,0000	0,0000	0,0000	0,0315	16,00	0,00	0,00	0,00	3,15
43	0,0000	0,1000	0,0000	0,0000	0,0000	0,1380	10,00	0,00	0,00	0,00	13,80
44	0,0000	0,0600	0,0000	0,0000	0,0000	0,4755	6,00	0,00	0,00	0,00	47,55
45	2,0000	0,0000	0,0000	0,0000	0,0000	0,7305	100,00	100,00	100,00	100,00	63,48
46	0,0000	0,0000	0,0000	0,0000	0,0000	0,8570	0,00	0,00	0,00	0,00	85,70
47	6,0000	0,0300	0,0000	0,0000	0,0000	0,7785	99,50	100,00	100,00	100,00	87,03
48	0,0000	0,0400	0,0000	0,0000	0,0000	0,8005	4,00	0,00	0,00	0,00	80,05
49	0,0000	0,0000	0,0000	0,0000	0,0000	0,7700	0,00	0,00	0,00	0,00	77,00
50	0,0000	0,0000	0,0000	0,0000	0,0000	0,7360	0,00	0,00	0,00	0,00	73,60
51	3,0000	0,0000	0,0000	0,0000	0,0000	0,7965	100,00	100,00	100,00	100,00	73,45
52	0,0000	0,0400	0,0000	0,0000	0,0000	1,0160	4,00	0,00	0,00	0,00	101,60
53	2,0000	0,2800	0,0000	0,0000	0,0000	1,4370	86,00	100,00	100,00	100,00	28,15
54	2,0000	0,8800	0,0000	0,0000	0,0000	2,1820	56,00	100,00	100,00	100,00	9,10
55	0,0000	0,2400	0,0000	0,0020	0,0025	1,7650	24,00	0,00	0,20	0,25	176,50
56	2,0000	0,0500	0,0000	0,0030	0,0025	1,1385	97,50	100,00	99,85	99,88	43,08
57	0,0000	0,0000	0,0000	0,0015	0,0020	0,9675	0,00	0,00	0,15	0,20	96,75
58	2,0000	0,0000	0,0000	0,0020	0,0025	0,8270	100,00	100,00	99,90	99,88	58,65
59	0,0000	0,0000	0,0000	0,0040	0,0030	0,7365	0,00	0,00	0,40	0,30	73,65
60	2,0000	0,0000	0,0000	0,0160	0,0055	0,6165	100,00	100,00	99,20	99,72	69,18
61	0,0000	0,0000	0,0605	0,1760	0,0545	0,3075	0,00	6,05	17,60	5,45	30,75
62	0,0000	0,0000	0,0035	0,2620	0,4005	0,1155	0,00	0,35	26,20	40,05	11,55
63	0,0000	0,0600	0,0000	0,2030	0,7090	0,0250	6,00	0,00	20,30	70,90	2,50
64	0,0000	0,1800	0,0000	0,1660	0,6865	0,0065	18,00	0,00	16,60	68,65	0,65
65	0,0000	0,3300	0,0215	0,1910	0,7070	0,0020	33,00	2,15	19,10	70,70	0,20
66	0,0000	0,3900	0,0605	0,1660	0,4560	0,0010	39,00	6,05	16,60	45,60	0,10
67	0,0000	1,0000	0,0000	0,1105	0,1130	0,0010	100,00	0,00	11,05	11,30	0,10
68	0,0000	0,4300	0,0005	0,1170	0,0440	0,0010	43,00	0,05	11,70	4,40	0,10
69	0,0000	0,1100	0,0015	0,1430	0,0190	0,0010	11,00	0,15	14,30	1,90	0,10
70	0,0000	0,0000	0,0005	0,1555	0,0170	0,0010	0,00	0,05	15,55	1,70	0,10
71	0,0000	0,0000	0,0115	0,2235	0,2190	0,0010	0,00	1,15	22,35	21,90	0,10
72	0,0000	0,0000	2,9660	0,4270	2,8950	0,0005	0,00	296,60	42,70	289,50	0,05
73	0,0000	0,0000	0,7530	0,9600	0,8580	0,0000	0,00	75,30	96,00	85,80	0,00
74	0,0000	0,0000	0,5725	0,6515	1,8730	0,0000	0,00	57,25	65,15	187,30	0,00
75	0,0000	0,0000	0,4360	0,4340	1,9875	0,0000	0,00	43,60	43,40	198,75	0,00
76	0,0000	0,0400	0,5480	0,5595	1,8505	0,0000	4,00	54,80	55,95	185,05	0,00
77	0,0000	0,2000	0,4835	0,4755	0,2410	0,0000	20,00	48,35	47,55	24,10	0,00
78	0,0000	0,9800	0,5125	0,5125	0,1700	0,0000	98,00	51,25	51,25	17,00	0,00
79	0,0000	1,0600	0,2900	0,2415	0,0905	0,0000	106,00	29,00	24,15	9,05	0,00
80	0,0000	0,4700	0,6150	0,6270	0,7655	0,0000	47,00	61,50	62,70	76,55	0,00
81	0,0000	1,1600	0,3715	0,3765	0,7545	0,0000	116,00	37,15	37,65	75,45	0,00
82	0,0000	0,2000	0,4165	0,3790	1,0015	0,0000	20,00	41,65	37,90	100,15	0,00
83	0,0000	0,0500	0,7805	0,5820	1,1035	0,0000	5,00	78,05	58,20	110,35	0,00

...continua...

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
84	0,0000	0,0000	1,8770	0,8315	0,6225	0,0000	0,00	187,70	83,15	62,25	0,00
85	0,0000	0,0000	0,0750	0,1035	0,0600	0,0000	0,00	7,50	10,35	6,00	0,00
86	0,0000	0,0000	0,0120	0,0165	0,0065	0,0005	0,00	1,20	1,65	0,65	0,05
87	0,0000	0,0000	0,0145	0,0065	0,0030	0,0075	0,00	1,45	0,65	0,30	0,75
88	0,0000	0,0000	0,0170	0,0075	0,0025	0,0245	0,00	1,70	0,75	0,25	2,45
89	0,0000	0,0000	0,0135	0,0075	0,0025	0,0310	0,00	1,35	0,75	0,25	3,10
90	0,0000	0,0500	0,0160	0,0175	0,0025	0,0905	5,00	1,60	1,75	0,25	9,05
91	0,0000	0,0600	0,0015	0,0000	0,0020	0,0000	6,00	0,15	0,00	0,20	0,00
92	0,0000	0,0000	0,0010	0,0000	0,0020	0,0000	0,00	0,10	0,00	0,20	0,00
93	0,0000	0,0000	0,0000	0,0000	0,0015	0,0000	0,00	0,00	0,00	0,15	0,00
94	0,0000	0,0000	0,0000	0,0000	0,0015	0,0000	0,00	0,00	0,00	0,15	0,00
95	0,0000	0,0000	0,0000	0,0000	0,0020	0,0000	0,00	0,00	0,00	0,20	0,00
96	0,0000	0,0000	0,0000	0,0025	0,0110	0,0000	0,00	0,00	0,25	1,10	0,00
97	0,0000	0,0000	0,0045	0,0070	0,0060	0,0000	0,00	0,45	0,70	0,60	0,00
98	0,0000	0,0600	0,0290	0,0150	0,0095	0,0000	6,00	2,90	1,50	0,95	0,00
99	0,0000	0,1600	0,0325	0,0140	0,0005	0,0000	16,00	3,25	1,40	0,05	0,00
100	0,0000	0,3400	0,0400	0,0175	0,0000	0,0000	34,00	4,00	1,75	0,00	0,00
101	0,0000	0,3100	0,0435	0,0210	0,0000	0,0000	31,00	4,35	2,10	0,00	0,00
102	0,0000	0,3800	0,0505	0,0255	0,0000	0,0000	38,00	5,05	2,55	0,00	0,00
103	0,0000	0,0900	0,0645	0,0390	0,0010	0,0000	9,00	6,45	3,90	0,10	0,00
104	0,0000	0,0000	0,2290	0,4495	0,1830	0,0005	0,00	22,90	44,95	18,30	0,05
105	0,0000	0,0300	0,0690	0,0475	0,0065	0,0000	3,00	6,90	4,75	0,65	0,00
106	0,0000	0,0000	0,0000	0,0000	0,0000	0,0000	0,00	0,00	0,00	0,00	0,00
107	0,0000	0,0000	0,0755	0,0715	0,0085	0,0000	0,00	7,55	7,15	0,85	0,00
108	0,0000	0,0000	0,0180	0,0395	0,0055	0,0000	0,00	1,80	3,95	0,55	0,00
109	0,0000	0,0000	0,0160	0,0305	0,0055	0,0000	0,00	1,60	3,05	0,55	0,00
110	0,0000	0,0000	0,0135	0,0235	0,0050	0,0000	0,00	1,35	2,35	0,50	0,00
111	0,0000	0,0600	0,0120	0,0190	0,0030	0,0000	6,00	1,20	1,90	0,30	0,00
112	0,0000	0,0700	0,0110	0,0160	0,0010	0,0000	7,00	1,10	1,60	0,10	0,00
113	0,0000	0,0000	0,0045	0,0000	0,0000	0,0000	0,00	0,45	0,00	0,00	0,00
114	0,0000	0,1300	0,0000	0,0000	0,0000	0,0000	13,00	0,00	0,00	0,00	0,00
115	0,0000	0,2000	0,0000	0,0000	0,0000	0,0005	20,00	0,00	0,00	0,00	0,05
116	0,0000	2,4100	0,0005	0,0000	0,0000	0,0005	241,00	0,05	0,00	0,00	0,05
117	0,0000	0,0000	0,0055	0,0000	0,0000	0,0000	0,00	0,55	0,00	0,00	0,00
118	0,0000	0,0600	0,0050	0,0000	0,0000	0,0000	6,00	0,50	0,00	0,00	0,00
119	0,0000	0,2700	0,0555	0,0310	0,0000	0,0000	27,00	5,55	3,10	0,00	0,00
120	0,0000	0,0000	0,0815	0,0625	0,0110	0,0000	0,00	8,15	6,25	1,10	0,00
Erro médio relativo							22,26	16,51	15,06	21,65	11,44

PA- Ponto Amostral; VR- Valor Real; VE KO- Valor Estimado Pela Krigagem Ordinária; VE RNA 1AR- Valor Estimado RNA 1 PA Relativo; VE RNA 2AR- Valor Estimado RNA 2 PA Relativos; VE RNA 3AR- Valor estimado RNA 3 PA Relativos; VE RNA 4AR- Valor estimado RNA 4 PA Relativos; P(K) - Erro Médio Relativo Krigagem; P (1AR)- Erro Médio Relativo RNA 1 PA Relativo; P (2AR)- Erro Médio Relativo RNA 2 PA Relativos; P (3AR)- Erro Médio Relativo RNA 3 PA Relativos; P (4AR)- Erro Médio Relativo RNA 4 PA Relativos.

TABELA 13. Comparação valores aferidos x valores estimados: MO

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
1	27,00	26,75	26,15	27,57	26,80	29,71	0,93	3,17	2,11	0,74	10,02
2	23,00	22,97	22,39	27,38	26,67	29,05	0,13	2,65	19,04	15,93	26,28
3	27,00	20,13	24,13	27,43	26,49	28,08	25,44	10,65	1,57	1,91	4,00
4	27,00	26,69	27,27	27,31	26,20	27,39	1,15	1,00	1,15	2,96	1,44
5	27,00	20,27	26,77	27,14	26,04	27,08	24,93	0,85	0,50	3,56	0,28
6	27,00	23,07	22,21	25,75	24,81	25,48	14,56	17,76	4,65	8,13	5,65
7	27,00	23,03	23,47	25,52	25,12	25,70	14,70	13,07	5,50	6,96	4,83
8	27,00	26,89	26,46	25,09	24,88	25,35	0,41	2,02	7,09	7,87	6,13
9	23,00	26,88	27,61	24,79	24,62	25,02	16,87	20,02	7,76	7,04	8,76
10	20,00	26,88	27,06	24,53	24,29	24,64	34,40	35,30	22,63	21,45	23,20
11	23,00	23,13	26,58	24,37	24,04	24,34	0,57	15,57	5,96	4,50	5,83
12	27,00	22,99	26,27	24,28	23,85	24,07	14,85	2,72	10,09	11,69	10,87
13	23,00	20,30	25,56	24,20	23,56	23,75	11,74	11,11	5,22	2,43	3,26
14	27,00	34,33	25,10	24,15	23,30	23,46	27,15	7,06	10,56	13,72	13,13
15	27,00	23,09	29,20	24,20	23,88	23,54	14,48	8,13	10,39	11,57	12,81
16	31,00	22,99	30,27	24,25	24,10	23,85	25,84	2,37	21,79	22,27	23,06
17	31,00	23,05	30,88	24,32	24,33	24,21	25,65	0,40	21,56	21,53	21,90
18	27,00	23,04	28,06	24,44	24,61	24,63	14,67	3,93	9,48	8,87	8,80
19	27,00	26,91	24,46	24,60	24,83	24,97	0,33	9,43	8,91	8,04	7,54
20	27,00	26,90	19,62	24,84	25,11	25,37	0,37	27,33	8,00	7,02	6,04
21	20,00	26,85	18,46	25,18	25,40	25,80	34,25	7,73	25,90	26,98	28,98
22	23,00	20,21	18,83	25,62	25,68	26,20	12,13	18,13	11,37	11,63	13,91
23	23,00	23,05	22,23	26,10	25,95	26,60	0,22	3,37	13,48	12,80	15,65
24	27,00	22,99	30,26	26,63	26,23	27,02	14,85	12,06	1,39	2,85	0,07
25	39,00	23,10	32,63	26,99	26,44	27,33	40,77	16,33	30,79	32,21	29,94
26	27,00	26,70	32,48	27,36	26,69	27,69	1,11	20,30	1,31	1,15	2,54
27	31,00	20,22	30,93	27,61	26,93	28,05	34,77	0,23	10,95	13,15	9,53
28	27,00	20,17	27,51	27,76	27,13	28,36	25,30	1,89	2,80	0,48	5,04
29	27,00	22,92	24,43	27,84	27,30	28,64	15,11	9,52	3,09	1,11	6,07
30	23,00	26,74	22,68	27,97	27,51	28,95	16,26	1,41	21,61	19,59	25,85
31	23,00	16,42	22,43	28,06	27,67	29,19	28,61	2,50	22,00	20,28	26,91
32	20,00	23,04	23,02	28,15	27,77	29,33	15,20	15,08	40,75	38,85	46,65
33	27,00	26,73	24,05	28,25	27,82	29,29	1,00	10,93	4,63	3,04	8,48
34	23,00	23,15	25,48	28,25	27,80	29,11	0,65	10,78	22,83	20,87	26,57
35	27,00	30,51	24,56	23,94	25,81	25,31	13,00	9,04	11,35	4,43	6,26
36	23,00	23,11	23,16	23,92	25,61	25,15	0,48	0,67	4,00	11,35	9,35
37	27,00	26,77	22,23	24,50	25,71	25,38	0,85	17,69	9,28	4,80	6,00
38	23,00	23,06	21,58	25,34	25,83	25,70	0,26	6,20	10,15	12,30	11,74
39	23,00	30,50	21,35	26,54	26,11	26,31	32,61	7,17	15,39	13,50	14,37
40	27,00	16,43	21,70	27,43	26,35	26,91	39,15	19,65	1,59	2,43	0,33
41	20,00	22,99	22,69	27,62	26,32	27,03	14,95	13,43	38,10	31,60	35,15

...continua...

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
42	23,00	20,20	26,55	27,78	26,47	27,50	12,17	15,41	20,78	15,09	19,54
43	27,00	26,80	30,41	27,59	26,40	27,50	0,74	12,63	2,17	2,22	1,83
44	20,00	23,06	32,92	27,19	26,29	27,41	15,30	64,58	35,95	31,43	37,03
45	35,00	23,10	30,48	26,73	26,09	27,13	34,00	12,91	23,64	25,47	22,49
46	23,00	30,53	24,11	26,23	25,90	26,86	32,74	4,83	14,02	12,61	16,78
47	20,00	23,06	21,28	25,72	25,70	26,52	15,30	6,40	28,60	28,50	32,60
48	20,00	23,10	20,33	25,28	25,43	26,11	15,50	1,65	26,40	27,12	30,52
49	20,00	26,85	19,74	24,96	25,18	25,71	34,25	1,32	24,78	25,88	28,52
50	20,00	23,13	19,19	24,69	24,91	25,26	15,65	4,07	23,45	24,55	26,28
51	20,00	20,29	18,97	24,55	24,71	24,92	1,45	5,15	22,72	23,55	24,58
52	16,00	26,83	19,44	24,42	24,46	24,48	67,69	21,47	52,59	52,87	53,00
53	20,00	20,16	25,81	24,31	24,23	24,01	0,80	29,05	21,55	21,15	20,03
54	31,00	16,44	29,03	24,27	24,06	23,75	46,97	6,35	21,71	22,39	23,40
55	27,00	26,87	23,12	24,43	23,96	23,90	0,48	14,39	9,54	11,26	11,50
56	20,00	26,92	23,34	24,54	24,12	24,22	34,60	16,68	22,67	20,60	21,10
57	27,00	23,22	22,52	24,64	24,28	24,50	14,00	16,61	8,76	10,07	9,28
58	27,00	38,12	22,19	24,83	24,43	24,75	41,19	17,81	8,04	9,54	8,35
59	20,00	23,14	21,80	25,00	24,51	24,85	15,70	8,98	25,00	22,55	24,23
60	16,00	20,35	20,60	25,24	24,65	24,99	27,19	28,72	57,75	54,06	56,16
61	20,00	20,15	19,93	25,43	24,64	24,92	0,75	0,37	27,12	23,18	24,58
62	27,00	20,17	19,49	25,61	24,67	24,91	25,30	27,83	5,15	8,65	7,74
63	23,00	26,77	21,62	25,63	24,60	24,74	16,39	6,00	11,43	6,96	7,57
64	23,00	26,82	23,57	25,31	24,45	24,45	16,61	2,48	10,04	6,28	6,28
65	23,00	23,10	21,41	24,36	24,10	23,92	0,43	6,93	5,89	4,78	3,98
66	20,00	23,14	19,18	23,39	23,82	23,53	15,70	4,13	16,93	19,10	17,63
67	20,00	30,48	18,62	22,91	23,74	23,41	52,40	6,90	14,55	18,70	17,05
68	16,00	22,97	18,50	22,45	23,55	23,22	43,56	15,59	40,28	47,19	45,09
69	20,00	20,31	18,64	22,13	23,32	23,03	1,55	6,82	10,65	16,57	15,15
70	20,00	26,74	19,01	22,11	23,19	22,98	33,70	4,95	10,52	15,93	14,88
71	20,00	23,03	19,39	22,23	23,05	22,95	15,15	3,05	11,13	15,22	14,73
72	20,00	20,20	19,79	22,51	22,92	22,98	1,00	1,08	12,53	14,58	14,90
73	20,00	23,02	19,19	24,20	23,06	23,85	15,10	4,05	20,98	15,28	19,25
74	20,00	20,20	20,89	23,80	22,73	23,56	1,00	4,42	19,00	13,63	17,80
75	27,00	22,95	24,32	23,42	22,43	23,28	15,00	9,94	13,26	16,94	13,80
76	23,00	20,26	22,81	22,80	22,09	22,83	11,91	0,85	0,89	3,96	0,76
77	23,00	26,64	24,97	22,43	21,88	22,55	15,83	8,57	2,50	4,87	1,98
78	27,00	20,16	25,58	22,00	21,74	22,24	25,33	5,28	18,52	19,50	17,63
79	23,00	20,36	29,41	21,78	21,50	22,01	11,48	27,85	5,30	6,54	4,33
80	16,00	26,83	28,34	21,34	21,71	21,82	67,69	77,09	33,34	35,69	36,34
81	27,00	20,27	30,78	21,08	21,47	21,57	24,93	14,00	21,93	20,50	20,11
82	35,00	20,15	29,58	20,81	21,44	21,40	42,43	15,49	40,56	38,74	38,87
83	23,00	20,16	27,42	20,80	21,66	21,44	12,35	19,22	9,59	5,85	6,80

...continua...

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
84	27,00	20,12	26,81	21,20	22,04	21,66	25,48	0,70	21,48	18,39	19,80
85	23,00	20,29	25,53	20,87	21,68	21,26	11,78	10,98	9,28	5,76	7,59
86	23,00	34,24	26,13	21,66	21,97	21,48	48,87	13,59	5,85	4,48	6,63
87	23,00	16,69	26,28	22,96	22,33	21,98	27,43	14,26	0,20	2,93	4,43
88	27,00	27,05	25,88	23,58	22,39	22,19	0,19	4,17	12,67	17,09	17,83
89	27,00	30,68	25,41	23,75	22,21	22,09	13,63	5,91	12,04	17,74	18,20
90	27,00	26,97	25,12	24,24	22,46	22,47	0,11	6,98	10,22	16,81	16,80
91	20,00	26,93	25,18	19,84	19,87	19,52	34,65	25,88	0,83	0,67	2,40
92	23,00	27,06	25,14	19,83	20,11	19,75	17,65	9,30	13,80	12,59	14,13
93	23,00	26,94	25,00	19,62	20,05	19,73	17,13	8,70	14,72	12,85	14,22
94	31,00	26,80	24,57	19,70	20,17	19,92	13,55	20,74	36,45	34,95	35,76
95	23,00	23,29	23,42	19,93	20,30	20,17	1,26	1,80	13,37	11,76	12,33
96	23,00	26,68	21,63	20,16	20,42	20,46	16,00	5,96	12,35	11,22	11,07
97	23,00	23,05	19,04	20,63	20,61	20,87	0,22	17,24	10,30	10,41	9,26
98	20,00	22,94	19,39	20,93	20,77	21,15	14,70	3,05	4,63	3,82	5,75
99	20,00	20,22	21,28	21,53	21,06	21,63	1,10	6,40	7,65	5,30	8,15
100	20,00	26,86	22,88	22,10	21,38	22,09	34,30	14,37	10,50	6,87	10,45
101	23,00	38,20	22,93	22,72	21,78	22,62	66,09	0,33	1,22	5,33	1,67
102	27,00	26,87	23,17	23,18	22,09	23,02	0,48	14,19	14,17	18,19	14,76
103	23,00	20,17	24,51	24,16	22,88	23,87	12,30	6,57	5,02	0,54	3,78
104	20,00	23,05	21,12	22,91	23,01	23,16	15,25	5,60	14,53	15,03	15,77
105	23,00	22,97	25,52	24,76	23,42	24,40	0,13	10,96	7,63	1,83	6,09
106	20,00	20,23	24,10	27,51	26,90	29,45	1,15	20,50	37,55	34,48	47,23
107	20,00	26,69	28,16	25,95	24,69	25,51	33,45	40,77	29,73	23,45	27,55
108	23,00	20,26	23,17	28,05	27,51	28,04	11,91	0,74	21,96	19,61	21,89
109	20,00	26,78	22,74	27,66	26,86	27,46	33,90	13,70	38,27	34,28	37,30
110	20,00	26,79	22,48	27,29	26,37	27,02	33,95	12,38	36,43	31,85	35,10
111	23,00	20,12	22,32	26,73	25,74	26,42	12,52	2,96	16,20	11,89	14,87
112	23,00	20,14	22,25	26,25	25,26	25,95	12,43	3,26	14,11	9,83	12,80
113	27,00	26,74	26,30	26,86	25,94	26,79	0,96	2,61	0,54	3,94	0,80
114	20,00	20,14	21,67	27,37	26,56	28,69	0,70	8,32	36,82	32,78	43,45
115	23,00	22,95	21,99	27,35	26,40	28,33	0,22	4,41	18,89	14,76	23,15
116	23,00	20,10	26,07	27,40	26,33	27,75	12,61	13,33	19,11	14,48	20,63
117	23,00	20,21	24,38	26,47	25,58	26,37	12,13	6,00	15,09	11,20	14,65
118	20,00	20,16	22,73	26,14	25,44	26,15	0,80	13,65	30,68	27,17	30,72
119	20,00	20,15	23,63	23,77	22,55	23,54	0,75	18,15	18,82	12,75	17,67
120	39,00	23,11	27,55	25,24	23,90	24,83	40,74	29,37	35,28	38,73	36,35
Erro médio relativo							17,35	11,32	15,89	15,41	16,74

PA- Ponto Amostral; VR- Valor Real; VE KO- Valor Estimado Pela Krigagem Ordinária; VE RNA 1AR- Valor Estimado RNA 1 PA Relativo; VE RNA 2AR- Valor Estimado RNA 2 PA Relativos; VE RNA 3AR- Valor estimado RNA 3 PA Relativos; VE RNA 4AR- Valor estimado RNA 4 PA Relativos; P(K) - Erro Médio Relativo Krigagem; P (1AR)- Erro Médio Relativo RNA 1 PA Relativo; P (2AR)- Erro Médio Relativo RNA 2 PA Relativos; P (3AR)- Erro Médio Relativo RNA 3 PA Relativos; P (4AR)- Erro Médio Relativo RNA 4 PA Relativos.

TABELA 14. Comparação valores aferidos x valores estimados: Argila

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
1	290,00	286,14	321,94	259,64	269,37	262,94	1,33	11,01	10,47	7,11	9,33
2	230,00	236,61	302,32	259,88	269,37	264,29	2,87	31,44	12,99	17,12	14,91
3	230,00	238,49	264,76	260,15	269,37	265,07	3,69	15,11	13,11	17,12	15,25
4	200,00	252,54	256,93	260,32	269,37	264,89	26,27	28,46	30,16	34,69	32,44
5	230,00	268,45	259,57	260,40	269,37	264,69	16,72	12,85	13,22	17,12	15,08
6	230,00	284,76	261,55	253,99	259,88	257,97	23,81	13,72	10,43	12,99	12,16
7	230,00	284,41	284,60	260,70	269,37	262,79	23,66	23,74	13,35	17,12	14,25
8	230,00	267,66	277,10	260,76	269,37	262,33	16,37	20,48	13,37	17,12	14,06
9	230,00	235,34	268,41	260,84	269,37	261,90	2,32	16,70	13,41	17,12	13,87
10	250,00	211,08	261,98	260,56	269,37	261,26	15,57	4,79	4,22	7,75	4,50
11	250,00	279,98	250,04	260,23	269,37	260,68	11,99	0,01	4,09	7,75	4,27
12	230,00	236,00	240,23	259,90	269,37	260,18	2,61	4,45	13,00	17,12	13,12
13	230,00	235,97	233,26	259,49	269,36	259,37	2,60	1,42	12,82	17,11	12,77
14	250,00	283,78	226,53	258,86	269,27	258,55	13,51	9,39	3,54	7,71	3,42
15	200,00	284,00	237,99	257,77	231,60	261,17	42,00	19,00	28,89	15,80	30,59
16	200,00	267,59	246,10	258,91	232,71	261,75	33,80	23,05	29,45	16,36	30,88
17	270,00	236,57	255,34	259,69	236,38	262,37	12,38	5,43	3,82	12,45	2,83
18	290,00	251,08	268,87	260,05	235,96	263,36	13,42	7,29	10,33	18,64	9,19
19	270,00	234,87	273,58	260,49	261,18	263,45	13,01	1,32	3,52	3,27	2,43
20	290,00	234,31	282,41	260,62	266,31	264,04	19,20	2,62	10,13	8,17	8,95
21	270,00	251,41	286,41	260,43	268,54	264,58	6,89	6,08	3,55	0,54	2,01
22	290,00	239,24	284,16	260,46	269,15	265,10	17,50	2,02	10,19	7,19	8,59
23	290,00	253,24	278,30	260,42	269,26	265,74	12,68	4,04	10,20	7,15	8,37
24	270,00	239,67	266,94	260,36	269,31	266,44	11,23	1,14	3,57	0,26	1,32
25	250,00	268,62	254,66	260,35	269,35	266,84	7,45	1,86	4,14	7,74	6,74
26	230,00	284,22	240,52	260,35	269,37	267,18	23,57	4,57	13,19	17,12	16,17
27	230,00	252,47	236,41	260,29	269,37	267,74	9,77	2,79	13,17	17,12	16,41
28	230,00	267,23	231,51	260,26	269,37	267,79	16,19	0,65	13,16	17,12	16,43
29	250,00	298,69	229,60	260,22	269,37	267,75	19,48	8,16	4,09	7,75	7,10
30	230,00	270,42	231,94	260,49	269,37	268,14	17,57	0,84	13,25	17,12	16,58
31	250,00	269,43	233,26	260,98	269,37	268,00	7,77	6,70	4,39	7,75	7,20
32	250,00	251,89	234,99	261,98	269,37	267,65	0,76	6,01	4,79	7,75	7,06
33	230,00	238,11	237,99	264,81	269,35	267,17	3,53	3,47	15,13	17,11	16,16
34	230,00	285,08	240,51	268,72	269,00	266,24	23,95	4,57	16,83	16,96	15,76
35	250,00	271,94	276,97	282,47	255,68	266,73	8,78	10,79	12,99	2,27	6,69
36	290,00	255,18	278,84	282,62	263,02	268,59	12,01	3,85	2,54	9,31	7,38
37	230,00	254,79	276,75	282,75	262,89	270,11	10,78	20,33	22,93	14,30	17,44
38	270,00	255,98	273,39	282,63	256,04	271,34	5,19	1,26	4,68	5,17	0,49
39	270,00	237,89	268,92	282,08	250,67	271,99	11,89	0,40	4,47	7,16	0,74
40	290,00	251,49	264,86	280,43	245,73	272,16	13,28	8,67	3,30	15,27	6,15
41	290,00	265,67	262,96	279,02	246,90	272,35	8,39	9,33	3,79	14,86	6,09

...continua...

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
42	290,00	237,13	263,04	273,24	239,82	271,71	18,23	9,30	5,78	17,30	6,31
43	270,00	237,88	267,09	269,44	238,89	271,30	11,90	1,08	0,21	11,52	0,48
44	270,00	255,68	276,92	264,58	236,80	270,46	5,30	2,56	2,01	12,30	0,17
45	290,00	348,72	287,48	262,92	239,70	270,07	20,25	0,87	9,34	17,35	6,87
46	290,00	255,62	296,08	260,82	239,89	269,40	11,86	2,10	10,06	17,28	7,11
47	250,00	269,53	301,35	258,98	235,62	268,33	7,81	20,54	3,59	5,75	7,33
48	290,00	299,56	295,54	258,28	240,43	267,86	3,30	1,91	10,94	17,09	7,63
49	270,00	214,00	286,23	258,26	242,95	267,42	20,74	6,01	4,35	10,02	0,96
50	270,00	320,76	275,59	258,23	241,32	266,85	18,80	2,07	4,36	10,62	1,17
51	270,00	282,71	264,46	258,00	243,74	266,58	4,71	2,05	4,44	9,73	1,27
52	250,00	251,31	249,72	257,35	248,37	266,27	0,52	0,11	2,94	0,65	6,51
53	230,00	266,97	240,59	256,71	239,63	265,29	16,07	4,60	11,61	4,19	15,34
54	250,00	252,10	231,67	255,83	243,92	265,13	0,84	7,33	2,33	2,43	6,05
55	230,00	266,60	218,94	267,29	281,70	271,17	15,91	4,81	16,21	22,48	17,90
56	230,00	265,15	224,29	269,77	281,70	271,51	15,28	2,48	17,29	22,48	18,05
57	250,00	250,48	229,09	270,70	281,70	271,55	0,19	8,36	8,28	12,68	8,62
58	270,00	250,36	237,00	273,19	281,70	272,02	7,27	12,22	1,18	4,33	0,75
59	250,00	237,35	242,65	274,66	281,70	272,37	5,06	2,94	9,86	12,68	8,95
60	250,00	269,48	249,10	275,58	281,70	272,60	7,79	0,36	10,23	12,68	9,04
61	230,00	325,75	253,79	277,20	281,70	273,31	41,63	10,34	20,52	22,48	18,83
62	230,00	258,71	255,48	278,06	281,69	273,80	12,48	11,08	20,89	22,47	19,04
63	250,00	258,38	252,30	278,74	281,69	274,34	3,35	0,92	11,49	12,67	9,73
64	230,00	258,09	247,63	279,05	281,69	274,80	12,21	7,66	21,33	22,47	19,48
65	250,00	325,62	243,05	279,02	281,69	275,33	30,25	2,78	11,61	12,68	10,13
66	250,00	299,96	243,15	278,94	281,69	275,51	19,98	2,74	11,57	12,68	10,20
67	230,00	251,02	247,80	279,08	281,67	275,16	9,14	7,74	21,34	22,46	19,63
68	270,00	234,97	252,61	278,94	281,60	274,70	12,97	6,44	3,31	4,29	1,74
69	230,00	251,91	259,96	278,60	280,64	273,72	9,53	13,02	21,13	22,02	19,01
70	270,00	347,15	267,74	278,18	274,11	272,34	28,57	0,84	3,03	1,52	0,87
71	270,00	302,86	274,52	277,16	263,23	270,59	12,17	1,67	2,65	2,51	0,22
72	270,00	259,02	281,09	274,68	260,14	268,10	4,07	4,11	1,73	3,65	0,71
73	250,00	329,30	277,01	258,62	259,88	259,14	31,72	10,80	3,45	3,95	3,66
74	250,00	389,79	266,80	260,66	259,88	262,64	55,92	6,72	4,26	3,95	5,05
75	230,00	242,64	258,05	263,63	259,89	265,84	5,50	12,20	14,62	13,00	15,58
76	270,00	256,37	250,63	269,14	260,13	269,77	5,05	7,18	0,32	3,66	0,09
77	230,00	236,57	244,35	271,41	261,93	272,16	2,86	6,24	18,00	13,88	18,33
78	250,00	236,28	238,84	273,13	272,75	274,35	5,49	4,47	9,25	9,10	9,74
79	250,00	238,53	238,72	272,94	279,17	275,72	4,59	4,51	9,18	11,67	10,29
80	250,00	286,91	232,83	274,77	281,65	276,92	14,76	6,87	9,91	12,66	10,77
81	250,00	274,03	239,62	274,35	281,70	277,34	9,61	4,15	9,74	12,68	10,93
82	290,00	352,85	251,25	274,60	281,71	277,52	21,67	13,36	5,31	2,86	4,31
83	250,00	330,00	256,94	275,16	281,71	277,34	32,00	2,78	10,06	12,68	10,93

...continua...

PA	VR	VE KO	VE RNA 1AR	VE RNA 2AR	VE RNA 3AR	VE RNA 4AR	P (K) (%)	P (1AR) (%)	P (2AR) (%)	P (3AR) (%)	P (4AR) (%)
84	270,00	274,80	262,76	275,82	281,71	276,86	1,78	2,68	2,16	4,34	2,54
85	270,00	272,53	289,06	275,41	281,71	277,05	0,94	7,06	2,00	4,34	2,61
86	290,00	284,31	288,62	275,39	281,71	276,55	1,96	0,48	5,04	2,86	4,64
87	250,00	250,21	278,60	274,38	281,71	275,94	0,08	11,44	9,75	12,68	10,37
88	250,00	233,95	272,13	273,25	281,71	275,75	6,42	8,85	9,30	12,68	10,30
89	250,00	210,24	265,77	272,16	281,71	276,00	15,90	6,31	8,86	12,68	10,40
90	250,00	234,58	252,03	272,17	281,71	275,75	6,17	0,81	8,87	12,68	10,30
91	230,00	233,52	217,90	268,71	281,71	279,49	1,53	5,26	16,83	22,48	21,52
92	290,00	248,04	234,99	269,27	281,71	278,68	14,47	18,97	7,15	2,86	3,90
93	250,00	233,78	241,27	269,61	281,71	278,60	6,49	3,49	7,84	12,68	11,44
94	250,00	251,77	257,30	270,77	281,71	278,44	0,71	2,92	8,31	12,68	11,38
95	270,00	252,98	270,26	272,24	281,71	278,41	6,30	0,10	0,83	4,34	3,11
96	310,00	256,84	284,23	272,53	281,71	278,33	17,15	8,31	12,09	9,13	10,22
97	250,00	351,60	278,43	271,62	281,70	277,82	40,64	11,37	8,65	12,68	11,13
98	290,00	292,36	292,46	271,63	281,68	277,53	0,81	0,85	6,34	2,87	4,30
99	270,00	292,22	286,34	270,72	281,13	276,37	8,23	6,05	0,26	4,12	2,36
100	270,00	241,58	292,82	269,94	276,29	275,09	10,53	8,45	0,02	2,33	1,89
101	310,00	287,12	301,32	268,28	263,58	273,09	7,38	2,80	13,46	14,97	11,91
102	340,00	284,81	307,67	266,14	260,45	270,72	16,23	9,51	21,73	23,40	20,38
103	340,00	285,00	313,85	259,17	259,88	264,51	16,18	7,69	23,78	23,56	22,20
104	340,00	288,39	290,38	270,80	259,85	264,55	15,18	14,60	20,35	23,58	22,19
105	340,00	254,84	317,99	256,08	259,88	260,46	25,05	6,47	24,68	23,57	23,39
106	340,00	269,19	296,21	259,74	269,37	264,00	20,83	12,88	23,61	20,77	22,35
107	340,00	246,89	327,42	253,78	259,88	252,67	27,39	3,70	25,36	23,57	25,69
108	370,00	329,84	389,61	252,35	259,88	246,90	10,85	5,30	31,80	29,76	33,27
109	420,00	329,80	374,64	252,42	259,88	248,63	21,48	10,80	39,90	38,13	40,80
110	340,00	274,93	349,48	252,51	259,88	250,48	19,14	2,79	25,73	23,57	26,33
111	310,00	300,97	316,77	252,79	259,88	253,10	2,91	2,18	18,46	16,17	18,35
112	310,00	271,45	288,88	253,22	259,88	255,44	12,44	6,81	18,32	16,17	17,60
113	370,00	240,00	258,42	260,49	269,37	264,45	35,14	30,16	29,60	27,20	28,53
114	370,00	253,38	295,17	259,98	269,37	264,60	31,52	20,23	29,74	27,20	28,49
115	370,00	322,22	294,60	260,09	269,37	264,66	12,91	20,38	29,71	27,20	28,47
116	340,00	252,83	263,18	260,23	269,37	264,96	25,64	22,59	23,46	20,77	22,07
117	340,00	322,90	283,75	260,57	269,37	263,69	5,03	16,54	23,36	20,77	22,44
118	310,00	271,62	284,33	260,60	269,37	263,39	12,38	8,28	15,94	13,11	15,04
119	270,00	269,01	314,50	262,04	259,92	267,20	0,37	16,48	2,95	3,73	1,04
120	290,00	273,77	314,38	254,73	259,88	256,92	5,60	8,41	12,16	10,39	11,41
Erro médio relativo							13,22	7,77	11,56	13,07	11,58

PA- Ponto Amostral; VR- Valor Real; VE KO- Valor Estimado Pela Krigagem Ordinária; VE RNA 1AR- Valor Estimado RNA 1 PA Relativo; VE RNA 2AR- Valor Estimado RNA 2 PA Relativos; VE RNA 3AR- Valor estimado RNA 3 PA Relativos; VE RNA 4AR- Valor estimado RNA 4 PA Relativos; P(K) - Erro Médio Relativo Krigagem; P (1AR)- Erro Médio Relativo RNA 1 PA Relativo; P (2AR)- Erro Médio Relativo RNA 2 PA Relativos; P (3AR)- Erro Médio Relativo RNA 3 PA Relativos; P (4AR)- Erro Médio Relativo RNA 4 PA Relativos.