

UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CAMPUS DE BOTUCATU

**DESEMPENHO DAS REDES NEURAIS ARTIFICIAIS NA
ESTIMATIVA DAS VARIÁVEIS FÍSICAS E QUÍMICAS DO SOLO**

JOÃO CARLOS ANGELICO

Tese apresentada à Faculdade de Ciências
Agronômicas da UNESP – Campus de
Botucatu, para obtenção do título de Doutor em
Agronomia – Área de Concentração – Energia
na Agricultura.

BOTUCATU - SP

Maio - 2005

UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CAMPUS DE BOTUCATU

**DESEMPENHO DAS REDES NEURAIS ARTIFICIAIS NA
ESTIMATIVA DAS VARIÁVEIS FÍSICAS E QUÍMICAS DO SOLO**

JOÃO CARLOS ANGELICO

Orientador: Prof. Dr. Ivan Nunes da Silva
Co-orientador: Prof. Dr. José Alfredo Covolan Ulson

Tese apresentada à Faculdade de Ciências
Agronômicas da UNESP – Campus de
Botucatu, para obtenção do título de Doutor em
Agronomia – Área de Concentração – Energia
na Agricultura.

BOTUCATU - SP

Maior – 2005

UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CAMPUS DE BOTUCATU

CERTIFICADO DE APROVAÇÃO

**TÍTULO: "DESEMPENHO DAS REDES NEURAIS ARTIFICIAIS NA
ESTIMATIVA DAS VARIÁVEIS FÍSICAS E QUÍMICAS DO SOLO"**

ALUNO: JOÃO CARLOS ANGÉLICO

ORIENTADOR: PROF. DR. IVAN NUNES DA SILVA

Aprovado pela Comissão Examinadora:




PROF. DR. IVAN NUNES DA SILVA



PROF. DR. ANGELO CATÂNEO



PROF. DR. LUIZ GONZAGA CAMPOS PORTO



PROF. DR. GASTÃO MORAES DA SILVEIRA



PROF. DR. CASIMIRO DIAS GADANHA JUNIOR

Data da Realização: 29 de abril de 2005.

Aos

meus pais: **Angelo e Conceição,**

que com toda simplicidade, através do exemplo de vida, ensinaram-me que o trabalho produz bons frutos para quem o realiza e para o próximo.

À

minha esposa **Andresa,**

pela compreensão e apoio em cada momento da elaboração deste trabalho.

Aos

meus filhos: **Lucas e Leonardo,**

que na inocência de crianças, pelas suas simples presenças, me motivam sempre a ir além.

Dedico.

AGRADECIMENTOS

Ao **Prof. Dr. Ivan Nunes da Silva**, pela amizade, apoio e orientação prestada no desenvolvimento deste trabalho, contribuindo para meu crescimento pessoal e formação científica.

Ao **Prof. Dr. José Alfredo Covolan Ulson** , que como Co-orientador deste trabalho contribuiu muito para sua concretização, colaborando com valiosas sugestões que em muito engrandeceram este trabalho.

Ao **conselho de Pós-graduação em Agronomia** – Área de concentração em Energia na Agricultura, pelo constante e inestimável empenho na melhoria do curso e pelo freqüente e valioso apoio aos alunos.

Aos **funcionários da seção de Pós-graduação em Agronomia** pela eficiência e amizade demonstradas durante o curso.

SUMÁRIO

	Página
LISTA DE QUADROS.....	VII
LISTA DE FIGURAS.....	X
RESUMO.....	01
SUMMARY.....	02
1. INTRODUÇÃO.....	03
2. REVISÃO BIBLIOGRÁFICA.....	07
2.1. Propriedades Físicas e Químicas dos Solos.....	07
2.2. Amostragem para Determinação das Propriedades do Solo.....	11
2.3. Determinação das Propriedades Físicas e Químicas do Solo.....	14
2.4. Variabilidade dos Solos – O alicerce para a Agricultura de Precisão.....	22
2.5. Princípios da Análise Geoestatística.....	26
2.6. Inteligência Artificial – Redes Neurais Artificiais.....	49
2.6.1. Arquitetura das Redes Neurais Artificiais.....	56
2.6.2. Treinamento das Redes Neurais Artificiais.....	66
2.7. Redes Neurais Artificiais e Suas Aplicações na Agricultura.....	72
3. MATERIAL E MÉTODOS.....	75
3.1. Amostragem do Solo.....	75
3.2. Metodologia.....	77
4. RESULTADOS E DISCUSSÃO.....	79
4.1. Desempenho das RNA em relação a krigagem.....	79

4.1.1. Estimativa da Areia.....	79
4.1.2. Estimativa das Demais Variáveis.....	82
4.2. Desempenho da RNA em Relação a co-krigagem.....	102
4.3. Aplicação das RNA na Estimativa dos Nutrientes e Micronutrientes em Função da Classe Textural dos Solos.....	114
5. CONCLUSÕES.....	134
6. REFERÊNCIAS BIBLIOGRÁFICAS.....	136
7. APÊNDICE.....	146
7.1. Apêndice 1.....	146
7.2. Apêndice 2.....	159

Quadro 18- Resultados obtidos na estimativa do Ca.....	93
Quadro 19- Resultados obtidos na estimativa do Mg.....	94
Quadro 20- Resultados obtidos na estimativa do Cu.....	95
Quadro 21- Resultados obtidos na estimativa do Fe.....	96
Quadro 22- Resultados obtidos na estimativa do Mn.....	97
Quadro 23- Resultados obtidos na estimativa do S.....	98
Quadro 24- Resultados obtidos na estimativa do Zn.....	99
Quadro 25- Resultados obtidos na estimativa do B.....	100
Quadro 26- Estimativa do silte em função da areia.....	103
Quadro 27- Estimativa da argila em função da areia.....	104
Quadro 28- Estimativa da SB em função do silte.....	105
Quadro 29- Estimativa da CTC em função da argila.....	106
Quadro 30- Estimativa da CTC em função da SB.....	107
Quadro 31- Estimativa da MO em função do pH.....	108
Quadro 32- Estimativa do Cu em função do Fe.....	109
Quadro 33- Estimativa do S em função do B.....	110
Quadro 34- Estimativa do B em função do K.....	111
Quadro 35- Estimativa do Mn em função do Ca.....	112
Quadro 36- Estimativa da SB em função da textura do solo.....	116
Quadro 37- Estimativa da CTC em função da textura do solo.....	117
Quadro 38- Estimativa da V em função da textura do solo.....	118
Quadro 39- Estimativa da H em função da textura do solo.....	119
Quadro 40- Estimativa da MO em função da textura do solo.....	120

Quadro 41- Estimativa da pH em função da textura do solo.....	121
Quadro 42- Estimativa da P em função da textura do solo.....	122
Quadro 43- Estimativa da K em função da textura do solo.....	123
Quadro 44- Estimativa da Ca em função da textura do solo.....	124
Quadro 45- Estimativa da Mg em função da textura do solo.....	125
Quadro 46- Estimativa da Cu em função da textura do solo.....	126
Quadro 47- Estimativa da Fe em função da textura do solo.....	127
Quadro 48- Estimativa da Mn em função da textura do solo.....	128
Quadro 49- Estimativa da S em função da textura do solo.....	129
Quadro 50- Estimativa da Zn em função da textura do solo.....	130
Quadro 51- Estimativa da B em função da textura do solo.....	131
Quadro 52- Resultado obtido na estimativa dos atributos do solo através da krigagem, RNA com uma camada de neurônios e com duas camadas de neurônios.....	133

LISTA DE FIGURAS

	Página
Figura 1- Variável estacionária de segunda ordem.....	29
Figura 2- Variável estacionária de primeira ordem.....	29
Figura 3- Variável não estacionária.....	29
Figura 4- Comportamento da função de covariância em função da distância entre as amostras.....	30
Figura 5- Exemplo do comportamento da função de autocorrelação (autocorrelograma).....	32
Figura 6- Semivariograma sem o efeito pepita.....	34
Figura 7- Semivariograma com efeito pepita.....	34
Figura 8- Semivariograma sem patamar definido.....	35
Figura 9- Semivariograma com efeito pepita puro.....	35
Figura 10- Semivariograma cíclico.....	36
Figura 11- Semivariograma com estrutura entrelaçada.....	36
Figura 12- Função XOR: uma representação gráfica.....	53
Figura 13- Esquema geral de treinamento de uma RNA.....	56
Figura 14- Modelo de neurônio artificial.....	57
Figura 15- Função degrau.....	59
Figura 16- Função linear.....	59
Figura 17- Função degrau bipolar.....	60
Figura 18- Função rampa.....	60
Figura 19- Função sigmóide.....	61
Figura 20- Função tangente hiperbólica.....	61

Figura 21- Função Gaussiana.....	62
Figura 22- Topologia de uma RNA evidenciando suas camadas.....	63
Figura 23- Redes Feedforward camada única.....	64
Figura 24- Redes Feedforward multicamadas.....	65
Figura 25- Redes recorrentes.....	65
Figura 26- Mapa indicando as regiões onde foram feitas as coletas.....	76
Figura 27 Frequência de disbuição da areia.....	80
Figura 28 Semivariograma da variável areia.....	80
Figura 29 Desempenho das RNA em relação a krigagem.....	101
Figura 30Desempenho das RNA em relação a co-krigagem.....	113
Figura 31 Erros médios.....	132

DESEMPENHO DAS REDES NEURAIS ARTIFICIAIS NA ESTIMATIVA DAS VARIÁVEIS FÍSICAS E QUÍMICAS DO SOLO

Autor: **João Carlos Angelico**

Orientador: **Prof. Dr. Ivan Nunes da Silva**

Co-orientador: **Prof. Dr. José Alfredo Covolan Ulson**

RESUMO

Métodos estatísticos de interpolação são freqüentemente utilizados para se obter as características dos solos em locais não amostrados, visando diminuir o número de amostras necessárias para um bom mapeamento do campo. Nesse trabalho, a estimativa da variabilidade espacial de atributos do solo foi realizada de duas maneiras: primeiramente utilizando-se os métodos estatísticos da krigagem e da co-krigagem e posteriormente as redes neurais artificiais. Os resultados obtidos pelos dois métodos foram comparados, com a finalidade de se verificar a eficiência das redes neurais artificiais na estimativa de atributos do solo. Os resultados mostraram que as redes neurais artificiais, em particular as redes Perceptron, com uma e com duas camadas de neurônios, são capazes de estimar as variabilidades espaciais dos solos com precisão maior do que os métodos estatísticos da krigagem e da co-krigagem. As redes neurais artificiais também se mostraram eficientes na estimativa de uma determinada variável do solo em função de sua classe textural.

**EVALUATION OF ARTIFICIAL NEURAL NETWORKS FOR ESTIMATING
PHYSICAL AND CHEMICAL VARIABLES OF SOIL. Botucatu, 2005. 160p. Tese
(Doutorado em Agronomia / Energia na Agricultura) – Faculdade de Ciências
Agronômicas, Universidade Estadual Paulista.**

Author: **João Carlos Angelico**

Adviser: **Prof. Dr. Ivan Nunes da Silva**

Co-adviser: **Prof. Dr. José Alfredo Covolan Ulson**

SUMMARY

Statistic methods of interpolation are often used to get the soil characteristics in non-sampled places in order to decrease samples numbers, which are necessary to obtain a good field mapping. In this project, the estimation of soil spatial variability attributes was done in two different ways. First, it was used statistic methods of kriging and cokriging, and in second instance, it was used artificial neural networks. The results computed by both techniques were compared each other in order to verify the efficiency of the artificial neural networks in estimating soil attributes. The results indicated that artificial neural networks, especially Perceptron networks, both with one and two layers of neurons, are able to estimate the soil spatial variability much better than the kriging and the cokriging methods. The artificial neural networks have also showed very efficient in estimating soil variables with respect to its textural class.

Keywords: neural networks, spatial variability, kriging method, artificial intelligence.

1. INTRODUÇÃO

A necessidade de produção de alimentos para uma população em crescimento, sem degradar o meio ambiente, exige conhecimentos gradativamente mais profundos das variáveis envolvidas no sistema de produção. Em função disto o conhecimento da variabilidade espacial de atributos de solo e da produtividade das culturas é primordial. A variabilidade espacial de solos deve ser considerada toda vez que a amostragem de campo for efetuada. Pesquisadores têm trabalhado com problemas de variabilidade, praticamente desde o início do século passado, mas apenas recentemente surgiu uma ferramenta compreensível para analisar e usar a variabilidade espacial chamada geoestatística e que ultimamente vem sendo intensamente usada em ciências de solos e outras propriedades agronômicas.

Normalmente o levantamento das variações observadas ao longo do campo é uma tarefa difícil (pelo fato da determinação das variáveis do solo implicar em custos e tempo relativamente elevados) levando muitos produtores a ignorá-las. Com isso, a maioria

dos agricultores aplica os insumos à taxa constante, de maneira uniforme ao longo do campo, ignorando a variabilidade do solo. Sabe-se, entretanto, que o solo pode apresentar variabilidade espacial e/ou temporal. A variabilidade espacial pode ser observada, entre outras variáveis, na fertilidade do solo, no teor de água, na topografia, no vigor das plantas e na população de pragas. A umidade do solo e o grau de compactação se enquadraria como variável temporal, pois pode variar rapidamente em função do tempo.

Em 1913 Montgomery, apud Vieira (1983), publicou um trabalho sobre a variação do nitrogênio no campo, tornando-se um dos precursores no estudo dos problemas de variabilidade espacial dos solos. Desde de então, muitos estudos foram desenvolvidos com o propósito de se determinar e mapear as variações das propriedades dos solos.

De início utilizou-se os métodos clássicos de análise estatística de dados, supondo-se que as realizações das variáveis aleatórias eram independentes entre si, ou seja, que as observações vizinhas não exerciam influências umas sobre as outras.

O matemático Krige, em 1951, apud Vieira (1995), em seus trabalhos com dados de mineração na África do Sul, verificou que a variância dos dados possuía uma estruturação que dependia da distância de amostragem, demonstrando que os fenômenos naturais apresentam-se freqüentemente com uma certa estruturação nas variações entre vizinhos, desta forma pode-se dizer que as variações não são aleatórias e, portanto, apresentam algum grau de dependência espacial. A análise espacial de dados na geoestatística apresenta-se como uma alternativa e/ou como uma complementação da análise clássica de dados, sendo que este tipo de análise considera as correlações entre as observações quando se faz estimativas.

Os conceitos básicos da geoestatística, que surgiram com os trabalhos de Krige, sofreram um grande impulso nas áreas da mineração e da geologia a partir de 1980 devido ao desenvolvimento computacional.

Além da evolução da ciência da computação outro fato marcante foi o desenvolvimento da Teoria das Variáveis Regionalizadas proposta por Matheron em 1971. Essa teoria possibilitou o emprego da interpolação em geoestatística, possibilitando a estimativa de dados e posterior mapeamento da variável. O interpolador que utiliza o semivariograma em sua modelagem é chamado de krigagem, sendo este, atualmente, o principal interpolador utilizado na análise da dependência espacial (ou temporal).

A geoestatística é o método mais comumente utilizado para se estudar a variabilidade espacial de solos, sendo esta técnica fundamentada na teoria das variáveis regionalizadas, segundo a qual os valores de uma propriedade do solo estão de alguma forma relacionados à sua distribuição espacial, logo, as observações tomadas a curtas distâncias devem ser mais semelhantes do que aquelas tomadas a distâncias maiores. As ferramentas da geoestatística permitem a análise de dependência espacial, como também, a estimativa de dados, para locais não amostrados.

Na área da computação, em meados de 1940, alguns cientistas começaram a imaginar se o computador poderia resolver problemas não apenas matemáticos, mas também situações que envolvessem raciocínio, conhecimento e inteligência, surgindo assim, uma nova área de estudos denominada Inteligência Artificial. Os sistemas inteligentes (Redes Neurais Artificiais) mostraram-se capazes de aprender através de exemplos, sendo imediatamente utilizados no reconhecimento de padrões, aproximações de funções, previsões

e controle. Com essas características as Redes Neurais Artificiais (RNA) podem desempenhar as “tarefas” da krigagem e da cokrigagem na estimativa de dados na análise de solos.

O presente trabalho tem por objetivos:

a) o desenvolvimento de um sistema inteligente, que através de redes neurais artificiais, possa estimar e mapear uma determinada variável do solo.

b) estimar uma determinada variável, cuja dificuldade de obtenção em laboratório seja grande (ou de custo elevado), em função de uma outra que pode ser determinada com mais facilidade.

c) por comparação com os métodos da krigagem e da co-krigagem, verificar a capacidade e a eficiência das redes neurais artificiais na estimativa da variabilidade espacial do solo.

2. REVISÃO BIBLIOGRÁFICA

2.1. Propriedades Físicas e Químicas dos Solos *

A tabela periódica indica que existem mais de 100 elementos químicos na natureza, porém, para as plantas, somente 16 são essenciais. Esses 16 elementos podem ser classificados em macronutrientes ou micronutrientes de acordo com a quantidade que a planta os absorve do meio ambiente. No Quadro 1 se encontram listados os 16 elementos essenciais às plantas (TOMÉ JÚNIOR, 1997). Todos os elementos químicos, independente de serem classificados como macronutrientes ou micronutrientes, são igualmente necessários, pois a produtividade será limitada pelo nutriente que estiver em menor disponibilidade, mesmo que todos os demais estejam presentes em quantidades adequadas.

*Para um aprofundamento do assunto consultar Tomé Júnior (1997).

Quadro 1: Elementos químicos considerados essenciais para as plantas

Macronutrientes		Micronutrientes	
Elemento Químico	Símbolo	Elemento Químico	Símbolo
Carbono	C	Ferro	Fe
Hidrogênio	H	Cobre	Cu
Oxigênio	O	Manganês	Mn
Nitrogênio	N	Zinco	Zn
Fósforo	P	Cloro	Cl
Potássio	K	Boro	B
Cálcio	Ca	Molibdênio	Mo
Magnésio	Mg		
Enxofre	S		

Tomé Júnior (1997)

A quantidade de nutrientes presentes no solo é extremamente dinâmica. Os principais processos de entradas (ganhos) de nutrientes no solo são:

* Sedimentação. O solo recebe materiais com os nutrientes de outros solos ou de rochas.

* Fertilizantes. É a maneira mais fácil e rápida de aumentar a quantidade de nutrientes disponíveis.

* Descargas elétricas. Durante as tempestades o solo pode receber nitrogênio transformado da forma molecular (N_2 , que é inerte) em nitrato (NO_3^-). Outra maneira de se acrescentar o nitrogênio no solo é através da ação das bactérias fixadoras de N_2 , de vida livre

ou que realizam simbiose com plantas, como as bactérias do gênero *Rhizobium*, utilizadas na cultura da soja (TOMÉ JÚNIOR, 1997).

O Quadro 2 mostra as principais formas químicas que os nutrientes podem aparecer na solução do solo.

Quadro 2. Principais formas químicas que os nutrientes aparecem no solo	
Nutriente	Principais formas que ocorrem no solo
Nitrogênio	NO_3^- (nitrato), NH_4^+ (amônio), aminoácidos solúveis e outros compostos nitrogenados solúveis
Fósforo	Íons fosfato (H_2PO_4^- ou HPO_4^{2-} , dependendo do pH), compostos org. solúveis contendo fósforo
Potássio	K^+
Cálcio	Ca^{2+}
Magnésio	Mg^{2+}
Enxofre	SO_4^{2-} (sulfato), aminoácidos sulfurados e outros compostos orgânicos solúveis contendo enxofre
Ferro	Fe^{2+} e outros compostos orgânicos contendo ferro, principalmente na forma de quelados
Cobre	Cu^{2+} e outros compostos orgânicos contendo cobre, principalmente na forma de quelados
Manganês	Mn^{2+} e outros compostos orgânicos contendo manganês, principalmente na forma de quelados
Zinco	Zn^{2+} e outros compostos orgânicos contendo zinco, principalmente na forma de quelados
Molibdênio	MoO_4^{2-} (molibdato)
Boro	H_3BO_3 (ácido bórico não-dissociado)
Cloro	Cl^- (cloreto)

Tomé Júnior (1997)

As perdas (saídas) ocorrem principalmente por:

- * Volatilização. Ocorrem perdas gasosas de nitrogênio e enxofre.
- * Lixiviação. Ocorre com todos os cátions. Só é considerada prejudicial quando os nutrientes são levados para fora do alcance das raízes.
- * Erosão. Neste processo pode ocorrer grande perda de nutrientes, sendo, em solos agrícolas o processo de perda de maior importância quantitativa (TOMÉ JÚNIOR, 1997).

Os solos das regiões intertropicais são compostos basicamente por uma fração mineral e outra de matéria orgânica. A matéria orgânica apresenta baixa estabilidade nestas regiões, devido ao elevado nível de umidade e as altas temperaturas. Mesmo assim, são de fundamental importância as propriedades físico-químicas dos solos com relação à fertilidade e produtividade agrícola. As reações de decomposição da matéria orgânica sempre levam à produção de ácidos orgânicos, e conseqüentemente, a um abaixamento do pH, constituindo-se assim no principal mecanismo de produção de prótons para o meio. Os ácidos orgânicos determinam os mecanismos das reações de oxi-redução que condicionam as reações de mobilização do ferro e manganês, tanto nos estados amorfos como nos cristalinos de baixo grau (PACCOLA, 1997).

Nas condições subtropicais e tropicais, o intemperismo de rochas basálticas, que são ricas em minerais, pode dar origem a solos argilosos, com elevado conteúdo de óxidos e hidróxidos de ferro, manganês e alumínio. Estes se encontram sob a forma de materiais amorfos, ou em condições especiais, como minerais altamente cristalizados, como, por exemplo, na forma de hematita e goeta. Os óxidos de ferro, devido à sua abundância e diversidade em graus de cristalinidade, apresentam considerável influência nas propriedades físicas e químicas dos solos (BANCROFT, 1973).

Uma variável de extrema importância a ser determinada na análise de solos é a capacidade de troca de cátions (CTC), que corresponde ao total de cargas negativas do solo. Quando a maior CTC do solo estiver ocupada por cátions essenciais como Ca^{2+} , Mg^{2+} e K^+ , melhor será a qualidade deste solo para nutrição das plantas, classificado, neste caso, como eutrófico. Porém, se grande parte da CTC está ocupada por cátions potencialmente tóxicos como H^+ e Al^{3+} , sobrando poucas cargas para os cátions nutrientes, este será um solo pobre classificado como distrófico. Por esse motivo, a CTC é uma grandeza fundamental na análise química do solo. A CTC Total de um solo acaba dividindo-se em CTC Efetiva e CTC Bloqueada. A CTC Efetiva é aquela ocupada por cátions efetivamente trocáveis, como Ca^{2+} , Mg^{2+} , K^+ e Al^{3+} e a CTC Bloqueada é aquela ocupada pelo H^+ não-trocável. Pelo fato de o H^+ bloquear as cargas negativas do solo, sendo retirado apenas por neutralização (através do OH^-), se diz que essa CTC é pH dependente. Em solos com pH baixo haverá muitos íons H^+ para ocupar as cargas negativas do solo, impedindo os processos de troca. Fornecendo-se íons OH^- através da calagem, boa parte dos íons H^+ será retirada e mais CTC Efetiva estará disponível aos processos de troca (TOMÉ JÚNIOR, 1997)

2.2. Amostragem para Determinação das Propriedades do Solo

Para garantir a qualidade na análise do solo é necessário tomar alguns cuidados com a coleta das amostras no campo, considerando que uma pequena porção de terra irá representar uma área muito grande. Jorge apud Silva (1999), defende que a amostragem pode ser responsável por até 98% dos erros nas análises de solo. Na prática costuma-se extrair 0,5 Kg de solo em cada 10 ha de área, sendo que destes 0,5 Kg, somente 10 g serão utilizados no laboratório para determinação analítica. Considerando-se uma profundidade de 20 cm no

solo tem-se: *Volume Total de Solo* $\Rightarrow 100\ 000\ m^2 \times 0,2\ m = 20000\ m^3$. Considerando a densidade média do solo valendo $1000\ Kg/m^3$, estima-se uma *Massa Total de Solo* correspondente a $20\ 000\ 000\ Kg/ha$. Portanto a porcentagem de solo na amostragem é de:

$$\% \text{ de solo na amostragem} \Rightarrow \frac{0,01kg}{2.10^7 kg} = \frac{1}{2.10^9} \quad (01).$$

Este resultado ilustra a importância da amostragem no processo de análise do solo. Tomé Jr (1997), sugere os seguintes cuidados para uma amostragem correta:

- * De um certo número de amostras simples fazer uma amostra composta. Um grande número de pontos de amostragem deve ser feito dentro da área, sendo depois misturados para formar uma única amostra representativa, que é a amostra composta. As amostras simples devem sempre conter o mesmo volume de solo, para evitar que um ponto seja mais representativo que outro na amostragem composta.

- * Dividir a área total em áreas menores com características semelhantes. Nesta divisão deve-se levar em consideração as seguintes características: vegetação presente, textura do solo, topografia, produtividade em safras anteriores, histórico de aplicações de corretivos e fertilizantes.

- * Evitar a coleta em pontos atípicos. Não se deve efetuar a coleta em áreas alagadas, com manchas de depósitos de calcário ou fertilizantes, em estradas, carregadores, formigueiros, locais próximos de casas, currais, depósitos etc. Também deve-se evitar áreas de baixa produtividade. Em áreas adubadas com culturas anuais de espaçamento largo deve-se evitar retirar as amostras sobre a linha de plantio e em áreas com culturas de espaçamento estreito deve-se retirar as amostras bem no final do ciclo, se possível após o preparo do solo para a próxima lavoura para evitar a interferência dos adubos aplicados no plantio.

* Coletar as amostras em zigue-zague. Este procedimento permite cobrir a área com mais fidelidade

* A superfície do solo, no ponto de amostragem, deve ser limpa da vegetação, restos de culturas e outros resíduos. Normalmente cava-se até 20 cm de profundidade (que é local onde a planta está absorvendo os nutrientes predominantes) e, com uma pá reta, retira-se uma fatia de uma das paredes da cova. Pode-se também utilizar equipamentos apropriados, como trados, para coleta do solo. Para uma análise de rotina, a amostra deve ser feita na camada de 0 a 20 cm de profundidade.

* Normalmente, para uma determinada área, a frequência de amostragem é de 3 a 4 anos.

* No laboratório exige-se alguns cuidados. Inicialmente a amostra deve passar por um processo de secagem, que é feito sob temperatura máxima de 40 °C (para não causar alterações na estrutura do solo) sob ventilação forçada. O processo de secagem não é recomendado em solos ricos em matéria orgânica, uma vez que posteriormente não se consegue seu molhamento completo, o que causa alterações em todas as análises a serem feitas nessa amostra. Esses materiais devem ser analisados com a unidade de campo, enquanto em uma alíquota em separado é determinado seu teor de umidade para posteriores correções dos resultados. Recomenda-se que as amostras sejam armazenadas no máximo por 6 meses, evitando que ocorra alterações significativas em suas principais características. Depois da secagem as amostras devem ser peneiradas (as vezes é necessário efetuar a moagem das amostras). Para tanto utiliza-se uma peneira com malha de 2 mm, obtendo-se a chamada Terra Fina Seca ao Ar (TFSA). Após o peneiramento e antes de realizar pesagens e tomadas de alíquotas deve-se homogeneizar a amostra.

2.3. Determinação das Propriedades Físicas e Químicas dos Solos

Boaretto apud Silva (1999), descreve a história da análise de solo da seguinte maneira:

A análise de solo provavelmente começou quando o homem interessou-se por saber como as plantas crescem. Pode-se dizer que foi Justus Von Liebig (1840) o primeiro a fazer a análise de solo. Desde aquela época até início dos anos 20, pouco progresso foi feito, ainda que Dyer (1894), Hilgard (1911) e Burd (1918) tenham dado significativas contribuições para a química do solo. No final da década de 20 e no início da de 30, porém, importantes contribuições foram feitas por Bray (1929), Herster (1934), Morgan (1932), Spurway (1933) e Truog (1930). Desde então, a análise do solo tem sido largamente aceita como fator essencial à formulação de um programa de adubação e calagem.

Segundo Van Raij et al. (1985), a análise de solo tem por finalidade essencial avaliar o grau de deficiência de nutrientes e determinar as quantidades de corretivos a serem aplicadas.

Alguns cuidados são essenciais para garantir a qualidade da análise. Primeiramente deve-se identificar cada amostra de solo. A amostra deve ser acompanhada das seguintes informações: número da amostra, nome do interessado, nome da propriedade, Município, Estado, cultura a ser implantada, cultura anterior, produção da cultura anterior e histórico da adubação ou calagem anterior. Quando já estiverem no laboratório, as amostras serão protocoladas, registradas com um número de identificação do laboratório e preparadas para as determinações analíticas (TOMÉ JÚNIOR, 1997).

As metodologias utilizadas nas análises para avaliação da fertilidade do solo, de acordo com Silva (1999), são:

1º) Determinação do pH

O conhecimento do pH do solo permite uma série de inferências sobre o estado nutricional desse solo para as plantas. Na determinação do pH do solo utiliza-se 10 cm³ de TFSA misturada com 25 cm³ de água deionizada ou destilada, ou 25 cm³ de solução de cloreto de cálcio (CaCl₂) na concentração de 0,01 M. A mistura deve ser deixada em descanso por 30 minutos visando o molhamento completo da amostra, depois é feita uma agitação durante 15 minutos, seguidos de um repouso até que se obtenha um sobrenadante límpido. O próximo passo é a determinação ou leitura do pH que é feita num aparelho conhecido como potenciômetro. Este aparelho mede a diferença de potencial entre dois eletrodos, sendo um eletrodo de vidro, sensível aos íons H⁺, e um eletrodo de prata – calomelano, que serve como referencial.

Os termos empregados para designar a acidez do solo diferem bastante. É comum utilizar-se o termo acidez Ativa, acidez de Troca e acidez Potencial. A acidez Ativa está relacionada aos íons H⁺ presentes na solução do solo. Na prática observa-se que a quantidade de íons H⁺ presentes na solução é muito pequena e poderia ser neutralizada com pequenas quantidades de carbonato de cálcio. O termo acidez de Troca (ou acidez trocável) está relacionado aos íons H⁺ e Al³⁺ adsorvidos de forma trocável às cargas negativas dos colóides extraídos com solução de KCl (1M). Essa acidez é nociva às plantas de uma maneira geral, sendo sua eliminação um dos principais motivos para se fazer a calagem do solo. Quando é feita a soma dos íons H⁺ não – trocável com a acidez de Troca obtém-se a acidez de Potencial.

2º) Determinação do Teor de Matéria Orgânica

A determinação do Teor de Matéria Orgânica é feita pelo método indireto da oxidação do carbono orgânico por via úmida (conhecido como método Walkley –

Black). Esse método leva em consideração que a matéria orgânica humificada existente nos solos contém aproximadamente 58% de carbono e, assim, conhecendo-se a quantidade de carbono existente na amostra, estima-se a quantidade de matéria orgânica. Neste processo ocorre o inconveniente de se determinar também as formas de carbono não – orgânicos existentes no solo, como carvão e resíduos de plantas não – humificadas.

No método Walkley-Black transfere-se 1 grama ou 1 cm³ de TFSA para um erlemeyer e adicionam-se 10 cm³ de solução de dicromato de potássio (0,5 M), além de 10 cm³ de ácido sulfúrico concentrado. O dicromato de potássio é o agente oxidante que transformará o carbono orgânico em CO₂. A adição de ácido sulfúrico eleva a temperatura, até aproximadamente 150 °C, favorecendo a reação química. O dicromato de potássio é adicionado numa quantidade conhecida e maior que a quantidade esperada de carbono orgânico existente em 1 cm³ de solo. Assim certa quantidade sobra e, como é conhecida a quantidade adicionada inicialmente, pode-se, por diferença, saber quanto reagiu de carbono. O excesso de dicromato de potássio é determinado por titulação com sulfato ferroso 0,5 M, na presença do indicador difenilamina. Após os 30 minutos de repouso são adicionados cerca de 50 cm³ de água, 4 cm³ de ácido fosfórico concentrado e 1 cm³ de difenilamina dissolvida em ácido sulfúrico. Nesse ponto a mistura tem uma coloração azul turquesa forte dada pela difenilamina na presença de dicromato de potássio. Adiciona-se sulfato ferroso que reagirá como excesso de dicromato, mudando a coloração da mistura de azul turquesa para verde escuro. Em função da quantidade de sulfato ferroso gasta, determina-se o carbono existente pela relação:

$$\text{Massa de Carbono} = (10 - V) \cdot 3,896 \cdot f \quad (02)$$

Onde:

- A massa de carbono é medida em gramas por decímetro cúbico de TFSA;
- V é o volume de sulfato ferroso consumido;
- f é o fator de correção da solução de sulfato ferroso.

O próximo passo é a determinação da quantidade de matéria orgânica por dm^3 que é dada pela relação:

$$\text{Matéria Orgânica} = \text{Massa de Carbono} \times 1,72 \quad (03)$$

Também é possível, por colorimetria, determinar os íons Cr^{3+} , resultantes da reação do dicromato com o carbono, construindo-se uma curva do teor de carbono em função da absorbância.

3º) Determinação do Fósforo Disponível

O fósforo disponível pode ser extraído do solo utilizando-se o extrator Mehlich ou a resina de troca aniônica. O extrator Mehlich utiliza uma solução de ácido sulfúrico e ácido clorídrico diluídos ($\text{H}_2\text{SO}_4 - 0,0125 \text{ M} + \text{HCl} - 0,05 \text{ M}$). O extrator com resina de troca aniônica utiliza um produto sintético com estrutura porosa e flexível formada por hidrocarbonetos em cadeias tridimensionais, contendo grupos químicos com cargas elétricas que podem atrair íons como o fósforo.

A quantificação do fósforo é feita por colorimetria através de um espectrofotômetro (ou colorímetro).

4º) Potássio Trocável

Para o potássio também é utilizado o extrator Mehlich ou a resina (porém com carga negativa). Após a obtenção da solução contendo K^+ , a quantificação do potássio é feita por um fotômetro de chama. Neste equipamento, através do GLP, é produzida uma chama que atinge aproximadamente 700 °C. A solução contendo K^+ é borrifada na chama e por excitação os elétrons das camadas de valência produzem fótons que são utilizados por um sensor para quantificar o potássio.

5º) Cátions Trocáveis – Ca, Mg e Al

Esses cátions podem ser extraídos por resina de carga negativa ou por uma solução salina concentrada, onde (quando se utiliza o KCl) os íons K^+ , em alta concentração, desloca os íons Ca^{2+} , Mg^{2+} e Al^{3+} adsorvidos pela CTC, tomando seus lugares. Após a extração, quantifica-se o cálcio e o magnésio por titulação com ácido etilenodiaminotetracético ou espectrofotômetro de absorção atômica.

Na titulação, uma solução contendo ácido etilenodiaminotetracético é gotejada no extrato com cálcio + magnésio até formar quelados. A quantificação do cálcio e magnésio é feita em função do volume de solução de ácido consumida. O próximo passo é a quantificação do cálcio que é feita de maneira análoga à determinação do Ca + Mg, porém insolubilizando o magnésio pela elevação do pH do extrato para 12,5. Uma vez quantificado o cálcio, obtém-se o Mg por diferença.

No aparelho de Espectrofotometria de Absorção Atômica é produzida uma onda eletromagnética com comprimento de onda específico do elemento que se quer determinar. Os átomos desse elemento presentes na chama absorvem parte desses fótons. Quanto mais átomos existirem, maior a absorção e mais atenuado será o feixe inicial.

A quantificação do Al trocável também é realizada por titulação ácido-base ou por espectrofotometria de absorção atômica.

6º) Determinação da Acidez Potencial

A determinação da acidez potencial pode ser realizada extraindo o H + Al com acetato de cálcio 0,5 M e em seguida, por titulação com NaOH diluído na presença de fenolftaleína, como é feito para o Al trocável.

Uma outra maneira de se determinar o teor de H + Al do solo é através do índice SMP (iniciais dos pesquisadores Shomaker, McLean e Pratt). Neste método utiliza-se uma solução tamponada em pH 7,5. Uma determinada quantidade de solo é adicionada à solução provocando diminuição do pH, sendo essa queda proporcional ao teor de H + Al.

7º) Determinação do Nitrogênio e Enxofre Disponíveis

Tanto o nitrogênio quanto o enxofre apresentam elevada dinâmica no solo. Por este motivo, não existe uma metodologia de laboratório capaz de integralizar um número tão grande de fatores e fornecer um índice de disponibilidade de nitrogênio e enxofre no solo. Em particular, o teor de nitrogênio total pode ser determinado com base no teor total de matéria orgânica presente no solo, considerando que esta contém cerca de 5% de nitrogênio. O teor de nitrogênio total não tem valor agrônomo para a previsão da disponibilidade desse nutriente para as culturas.

8º) Determinação de Micronutrientes

Os elementos Cobre, Ferro, Manganês e Zinco são mais freqüentemente extraídos com o extrator Mehlich. O Boro, diferentemente dos demais macronutrientes, é extraído com a utilização de água fervente.

Após a extração, o cobre, o ferro, o manganês e o zinco são quantificados por espectrofotometria de absorção atômica. O boro é quantificado por colorimetria.

Em muitos solos a concentração dos óxidos de ferro é relativamente baixa, que aliada ao tamanho relativamente pequeno de suas partículas, torna sua identificação bastante difícil. A difratometria de raios-X, associada a técnicas de análise química, é rotineiramente utilizada pelos cientistas de solo. Também é freqüentemente aplicada a espectroscopia na região do infravermelho, para se obter informações a respeito dos grupos funcionais presente em determinada amostra de solo. Quando se pretende caracterizar os óxidos de ferro de forma mais refinada costuma-se utilizar a espectroscopia Mössbauer. Como a espectroscopia Mössbauer é fundamentalmente sensível às modificações de ordem química, esta é capaz não só de distinguir entre os estados eletrônicos dos elementos em estudo como também dar informações da natureza dos compostos ligados ao Fe (BANCROFT, 1973) .

9º) Determinação da Soma de Bases

A soma de bases (SB) é determinada pela soma dos teores de Ca, Mg, K. Quando o sódio é determinado, este é acrescentado à soma.

10º) Determinação da Capacidade da Troca de Cátions Total do Solo

A capacidade de troca de cátions corresponde ao total de cargas negativas que o solo apresenta, podendo ser determinada pela soma de todos os cátions presentes no solo. Existem laudos que fornecem a determinação de Al trocável e acidez potencial separadamente. Nestes casos, deve-se tomar o cuidado de não somar o Al trocável, pois ele já está incluído na acidez potencial.

11º) Capacidade da Troca de Cátions Efetiva

O cátion H^+ não é um íon trocável pelo fato de estar adsorvido à CTC por ligação covalente, sendo possível retirá-lo somente por neutralização com aplicação de calcário. Por este motivo define-se a CTC efetiva, que corresponde às cargas do solo que estão disponíveis para os processos de troca.

12º) Determinação Granulométrica – Análise Textual

A análise granulométrica permite classificar o solo em: arenoso, argiloso, silteoso etc. A classificação das partículas, quanto ao tamanho, segue o seguinte critério:

Quadro 3. Classificação do Solo em Relação ao Tamanho das Partículas

Nome da Classe	Diâmetro (mm)
Matacão	$\geq 200,000$
Calhau	20,000 a 200,000
Cascalho	2,000 a 20,000
Areia	0,050 a 2,000
Silte	0,002 a 0,050
Argila	$\leq 0,002$

Tomé Júnior (1997)

Na determinação granulométrica, uma amostra de peso conhecido é saturada com sódio através da agitação com uma solução de NaOH 1M. Após a agitação, e em repouso, as partículas maiores decantam-se rapidamente, enquanto as argilas permanecerão dispersas por longos períodos. A densidade da suspensão é determinada em dois momentos. A primeira leitura é feita aos 40 segundos de decantação e corresponde à influência do silte e

argila em suspensão e a segunda leitura é feita 2 horas após a decantação e corresponde à densidade influenciada apenas pela argila.

Através de cálculos transforma-se a densidade em teores de silte e argila, sendo o teor de areia calculado por diferença.

13º) Saturação por Base (V%)

Na determinação da fertilidade do solo a saturação por bases é importantíssima, pois fornece uma idéia do estado de ocupação das cargas da CTC_{Total} , ou seja, do total de cargas negativas existentes no solo, qual proporção ocupada pelos cátions úteis.

A saturação por bases é utilizada para classificar os solos como:

- Solos Eutróficos (férteis) $\Rightarrow V\% \geq 50\%$
- Solos Distróficos (pouco férteis) $\Rightarrow V\% \leq 50\%$

14º) Determinação do Sódio Trocável

A leitura do sódio trocável é feita no mesmo extrato obtido para análise de potássio. Após a extração, a quantificação do sódio é feita por espectrofotometria de chama.

2.4. Variabilidade dos Solos – O Alicerce para a Agricultura de Precisão

A agricultura de precisão é garantia de uma agricultura sustentável que produz grande quantidade de alimentos com suficiente qualidade, com uso de fontes naturais, o que garante a preservação do meio ambiente. Para que isso seja possível, devem ser desenvolvidos equipamentos de precisão, capazes de efetuar operações complexas. Com o desenvolvimento da tecnologia, faz-se uso mais racional de fertilizantes e agrotóxicos

(BAERDEMAEKER et al., 2001). Segundo o autor a agricultura de precisão requer máquinas equipadas com dispositivos de alta precisão, tais como: sensor de fluxo de massa de alta precisão, pulverizador para aplicação localizada.

Historicamente, o primeiro povo que praticou, embora de maneira empírica, alguma forma de aplicação localizada de insumos, foram os incas que colocavam um peixe, como fertilizante, próximo a cada pé de milho de sua plantação; sendo o peixe maior, quanto menor fosse o pé de milho. Recentemente, os primeiros esforços para o desenvolvimento dos conceitos da Agricultura de Precisão foram feitos em 1929, quando dois pesquisadores americanos sugeriram a aplicação localizada de calcário, como forma de economizar na quantidade necessária desse insumo. Devido às dificuldades de se aplicar o insumo de forma localizada em grandes áreas, uma vez que não existiam equipamentos para aplicação e o georreferenciamento, esses conceitos ficaram no esquecimento, até aparecerem equipamentos com grande capacidade operacional e sistemas de posicionamento e de controle necessários, o que provocou, de novo, o interesse por tais conceitos a partir de 1984 (BALASTREIRE, 2000).

Halal et al. (1998) fazem previsão do avanço tecnológico para um futuro próximo, analisando as tendências tecnológicas emergentes. Uma lista de perguntas foi enviada a autoridades para que fosse feita uma estimativa da evolução que pode ocorrer em doze grandes grupos do conhecimento: energia, meio ambiente, alimentação e agricultura, hardware, software, comunicação, serviços de informação, robótica materiais, medicina, espaço e transporte. Na área de alimentação e agricultura, as estatísticas estão nos resultados do Quadro 4.

Quadro 4: Estimativa da evolução do conhecimento humano nas áreas de alimentação e agricultura.

ANO	Nível do conhecimento
2014	Agricultura orgânica alternativa e aquacultura
2015	Agricultura de precisão
2017	Comida artificial
2020	Automação das áreas agrícolas

Segundo Kutzbach (2000), a globalização e conseqüentemente a internacionalização da agricultura provocou uma competição acirrada quanto à produção e qualidade dos produtos agrícolas. Com isso, os agricultores se viram obrigados a utilizar equipamentos mais modernos. Um aspecto interessante, discutido neste trabalho, é que o desenvolvimento da mecanização agrícola não é determinado somente pelo conhecimento, habilidade e experiência da engenharia agrícola, mas também pela economia, ecologia e política agrícola. A alta performance, a operação extremamente simples, a automação e o manejo veloz, convencem muitos produtores, que a agricultura de precisão é viável. Muitos produtores adotam a agricultura de precisão pensando na qualidade dos produtos, principalmente investindo em colheitadeiras de qualidade que não danifiquem os produtos no momento da colheita. Neste artigo são citadas algumas técnicas, com relação à aplicação de herbicida, que possibilitam à preservação ambiental. Tais técnicas são: 1- cultivo mecânico com equipamentos que possibilitam a separação das plantas daninhas do solo, separando-as e depositando-as como esterco no mesmo. 2- reconhecimento por imagens das plantas daninhas

para aplicação seletiva de herbicida (para tanto se torna necessário grandes investimentos em sensores especiais). 3- choque térmico das plantas daninhas.

Kilpp (2000) mostra a importância dos mapas de produtividade na agricultura de precisão. Segundo o autor, esses mapas permitem identificar as áreas com baixo ou alto rendimento, estabelecendo a variação de produtividade dentro de uma mesma região, para a interpretação e tomada de decisão, dando condições para se determinar a melhor data do plantio, a variedade da semente, a formulação do adubo etc.

Stafford (2000) levanta alguns empecilhos no desenvolvimento da agricultura de precisão, mostrando ao mesmo tempo, fatores que favorecem o seu desenvolvimento. Segundo o autor, a agricultura de precisão é cultivada a alguns séculos em áreas pequenas, onde fazia-se um delineamento em função das condições naturais, como: cursos d'água e tipo de solo, o que possibilitava um tratamento manual do campo diferenciado. No entanto, o aumento das áreas cultivadas, produção intensiva e a mecanização na metade do último século não mais possibilitou a utilização de tais técnicas. O ressurgimento da agricultura de precisão ocorreu na década de 70, com o advento do GPS (Global Positioning System). Este ressurgimento ocorreu com força total, uma vez que os agricultores perceberam que é possível reduzir custos de produção, diminuir o impacto ambiental e produzir alimentos sem modificação genética. No entanto, existem alguns empecilhos que limitam uma expansão maior:

- 1- Necessidade de uma grande quantidade de informação, devido ao mapeamento dos diferentes tipos de solo, informações sobre a colheita e sobre fatores ambientais. Todas essas informações produzem um conjunto de dados imenso, obrigando o produtor a adquirir equipamentos para integração de tais dados (hardware e software).

- 2- É possível obter dados (informações) sobre solo, colheita e fatores ambientais, através de diferentes técnicas, porém os processos para obtenção de tais informações, normalmente são caros e laboriosos. Isto provoca gastos razoáveis na implementação da agricultura de precisão. O desenvolvimento de sensores, que realizem a leitura instantaneamente, poderia amenizar este problema.

Mc Lellan e Friesen (1997) questiona a necessidade de uma precisão de até 20 cm nos equipamentos agrícolas.. Neste trabalho o autor descreve a necessidade de precisão dos equipamentos para algumas aplicações (Quadro 5), condenando a precisão em demasia, porque quanto maior a precisão requerida pelo equipamento, maior será o custo do mesmo e mais dificuldade será encontrada no seu manuseio.

Quadro 5: Precisão requerida em algumas atividades de campo.

Aplicação	Precisão
Mapeamento do campo	Horizontal = 10 m
	Vertical = 5-20 cm
Semeadura	2-20 cm
Pulverização	20-50 cm
Cultivação e monitoramento do campo	2-100 cm

2.5. Princípios da Análise Geoestatística

A agricultura de precisão requer princípios de manejo de acordo com a variabilidade no campo, exigindo técnicas eficientes para estimar e mapear a variabilidade espacial e/ou temporal dos atributos e propriedades dos solos (ZIMBACK, 2003). Uma análise detalhada das propriedades físicas e químicas do solo demanda em custos e tempo

relativamente elevados, por esse motivo, costuma-se aplicar métodos estatísticos de interpolação para se obter as características dos solos nos locais não amostrados, visando diminuir o número de amostras necessárias para um bom mapeamento do campo. O aumento da qualidade da estimativa depende: da escolha dos métodos de interpolação que obtenham dados dos solos em locais não amostrados e da aplicação apropriada de métodos indicados para as características dos dados (KRAVCHENKO; BULLOCK, 1999).

Encontra-se na literatura trabalhos inerentes à variabilidade espacial e temporal das propriedades dos solos, publicados no início do século XX, tais como: Montgomery (1913), Robinson and Lloyd (1915) e Pendleton (1919) apud Vieira, et al. (1983). De início, as análises estatísticas de dados consideravam as variáveis aleatórias independentes entre si, ou seja, supunham que as observações vizinhas não exerciam influências umas sobre as outras. Contudo fenômenos naturais apresentam-se freqüentemente com uma certa estruturação entre vizinhos, desta forma pode-se dizer que as variações não ocorrem ao acaso, apresentando um certo grau de dependência espacial. Foi o engenheiro de Minas Sul-Africano, Daniel G. Krige, no ano de 1951 apud Vieira et al. (1983), que com seus trabalhos com dados de mineração, concluiu que a variação daqueles dados possuía uma estruturação que dependia da distância de amostragem, desta constatação surgiu os conceitos básicos de geoestatística. Na geoestatística leva-se em consideração a variabilidade espacial e/ou temporal de dados, complementado, ou mesmo substituindo, eficientemente a análise clássica. Um requisito básico para aplicação dos métodos geoestatísticos é necessidade de referenciamento das amostras, seja com relação às coordenadas geográficas ou ao tempo.

O desenvolvimento computacional a partir de 1980 foi o grande propulsor da aplicabilidade da geoestatística, inclusive em ciências do solo, considerando-se

que os processos computacionais agilizaram os cálculos relativamente trabalhosos utilizados nesta metodologia (GUIMARÃES, 2004).

Considerando-se um conjunto de medidas $Z(x)$, obtidos em um campo de área A , tem-se a ocorrência da variável Z com uma referência x , que pode ser uma posição no tempo ou no espaço (VIEIRA et al., 1983). A variável é considerada estacionária se o seu desenvolvimento no tempo (ou no espaço) ocorrer com oscilações aleatórias contínuas em torno de um valor médio. Por outro lado, os processos que não se comportam de maneira homogênea, no tempo ou no espaço, são considerados não estacionários. Essas definições básicas permitem classificar uma função aleatória $Z(x)$ como estacionária, se todos os momentos estatísticos forem invariantes para toda mudança de origem. Com rigor matemático, pode-se dizer que uma variável aleatória $Z(x)$ é estacionária quando apresenta momentos estatísticos de ordem k centrados na origem invariantes no tempo ou no espaço. Assim:

$$E[Z^K(t)] = m_K(t) = \nu, \text{ sendo } \nu \text{ uma constante} \quad (04)$$

Segundo Olea (1975) apud Vieira et al. (1983), nos estudos geoestatísticos exige-se estacionaridade de segunda ordem.

$$E[Z^2(t)] = m_2(t) = \nu \quad (05)$$

Na existência de estacionaridade todas as amostras pertencem a populações com os mesmos momentos estatísticos, isto permite a repetição de um experimento mesmo que as amostras sejam coletadas em pontos diferentes em relação ao experimento inicial (FONSECA; MARTINS, 1988).

A Figura 1 ilustra uma variável estacionária de segunda ordem, onde para qualquer trecho selecionado, a média e a variância permanecerão aproximadamente constantes. Na Figura 2 tem-se uma variável estacionária de primeira ordem, sendo que apenas a média permanece constante. Finalmente a Figura 3 representa uma variável não estacionária, onde nem a média e nem a variância permanecem constantes (GUIMARÃES, 2004).




Figura 1. Variável estacionária de segunda ordem.




Figura 2. Variável estacionária de primeira ordem.




Figura 3. Variável não estacionária.

A determinação da dependência espacial ou temporal é fundamental na geoestatística sendo, com maior frequência, verificada pela função de autocorrelação, que gera o autocorrelograma, ou pela função da semivariância, que gera o semivariograma (ZIMBACK, 2003).

Na autocorrelação pode-se “buscar” a medida de associação da variável Z nas posições x e $x + h$ pela covariância, definida como (SPIEGEL, 1985):

$$\text{Cov}[Z(x), Z(x + h)] = E[(Z(x) - \mu_{Z(x)}).(Z(x + h) - \mu_{Z(x+h)})] \quad (06)$$

onde μ ($\mu = \sum Z_i . P(Z_i)$) representa a esperança matemática.

É de se esperar que para duas variáveis aleatórias independentes a covariância entre elas seja igual a zero. Portanto, ao analisarmos a variável Z nas posições x e $x + h$, com $h = 1, 2, \dots, k$, espera-se que o valor da covariância comece alto e depois tenda a zero, sendo que quanto maior for o valor da covariância maior será a relação espacial e para covariância zero tem-se variáveis independentes. A Figura 4 mostra o comportamento de uma função covariância (GUIMARÃES, 2004).




Figura 4. Comportamento da função covariância em função da distância entre as amostras.

Na prática, a função covariância apresenta algumas dificuldades de interpretação por possuir as unidades das variáveis que a geram e, também, não ter um padrão de comparação para estimar se as variáveis estão com forte associação positiva ou não. Para contornar estes problemas, define-se a função autocovariância como uma alternativa de interpretação da dependência espacial de uma variável. Esta função tem a vantagem de ser adimensional e estar limitada ao valor -1 e 1, permitindo comparações entre variáveis e também inferências sobre o grau de associação. A função de autocorrelação é definida como sendo a razão entre a covariância dos valores assumidos pela variável Z , nas posições x e $x+h$, e a variância dessa variável Z , em função da distância h , no caso de variável estacionária de segunda ordem, assim:

$$\rho(h) = \frac{\text{Cov}[Z(x), Z(x+h)]}{\text{Var}[Z(x)]} \quad (07)$$

Esta equação pode ser trabalhada e reescrita como:

$$r(h) = \frac{\sum_{i=1}^{n(h)} [Z(x_i) - \bar{Z}][Z(x_i + h) - \bar{Z}]}{\frac{n(h)-1}{s^2}} \quad (08)$$

onde:

$\rho(h)$ é a autocorrelação entre os valores da variável Z , separados pela distância h ;

$\text{Cov}[Z(x), Z(x+h)]$ é a covariância entre a variável $Z(x)$ e a variável $Z(x+h)$;

$Var[Z(x)] = E\{[Z(x) - \mu_{Z(x)}]^2\}$ é a variância populacional;

$r(h)$ é a autocorrelação amostral para a distância h ;

$n(h)$ é o número de pontos amostrais separados pela distância h ;

$\bar{Z}$ é o valor médio da variável $Z(x)$;

s^2 é a variância amostral de $Z(x)$.

Estas funções só têm validade para variáveis com estacionaridade de segunda ordem. É de se esperar que $r(0)$ seja igual a 1, onde a autocorrelação é máxima. Esta autocorrelação decresce até valores próximos de zero, onde praticamente não existe relação entre as observações. Esta distância define a amplitude de dependência espacial ou temporal (a), sendo que acima dessa distância os dados são considerados independentes entre si. Este tipo de comportamento indica que quanto mais próximas estiverem as amostras, maior o grau de semelhança entre elas e este grau de semelhança decresce com o aumento da distância entre as observações. Pode-se ter ainda o autocorrelograma para toda distância com valor de autocorrelação igual a zero ($r(h) = 0$), exceto para $h=0$ em que $r(0) = 1$, assim temos independência entre as amostras para toda à distância ou tempo de estudo (GUIMARÃES, 2004). A Figura 5 ilustra o comportamento da função de autocorrelação.




Figura 5. Exemplo do comportamento da função de autocorrelação (autocorrelograma).

De acordo com Zimback (2003), a segunda maneira de se determinar a dependência espacial ou temporal de uma variável Z é através do semivariograma, que é definido como:

$$\gamma(h) = \frac{1}{2} \{ \text{Var}[Z(x) - Z(x+h)] \} \quad (09)$$

A equação acima simplesmente determina a variância dos dados, separados por uma distância h , dividida por dois. Esta divisão por dois dá origem ao nome semivariância. Quanto mais próximos estiverem os pontos amostrados, maior será a semelhança entre eles e, portanto menor a semivariância $\gamma(h)$ que cresce com o incremento de h , até atingir um valor constante que corresponde às variações aleatórias, ou seja, variações que não são justificadas pela semelhança de um ponto com outro. Define-se como *patamar* (C) a região onde o valor de $\gamma(h)$ torna-se constante. Chama-se a distância h , a partir da qual a semivariância se torna constante, de alcance da dependência espacial (a), sendo que as medições realizadas a distâncias maiores que a tem distribuição aleatória que são independentes entre si. Fatores como: a impossibilidade de se fazer reamostragens exatamente sobre um ponto já amostrado, erros de amostragem e erros de análise de laboratório, normalmente produzem semivariogramas onde $\gamma(0)$ difere de zero. Quando $\gamma(0) \neq 0$, surge um novo termo no semivariograma chamado de *efeito pepita* (C_0). As Figuras 6 e 7 ilustram, respectivamente, o comportamento de um semivariograma sem o efeito pepita e com o efeito pepita (GUIMARÃES, 2004).




Figura 6. Semivariograma sem o efeito pepita.




Figura 7. Semivariograma com efeito pepita.

Existem semivariograma em que as semivariâncias crescem, sem limites, para todos os valores de h , ou seja, semivariogramas sem patamar definido. Este semivariograma indica que a hipótese de estacionaridade de segunda ordem não foi atendida e, provavelmente, estamos trabalhando com a hipótese intrínseca (fenômeno com capacidade infinita de dispersão). Ele indica também que a máxima distância h entre as amostras não foi capaz de exibir toda a variância dos dados e provavelmente existe tendência dos dados para determinada direção. Se for verificada a tendência deve-se remover a mesma e verifica se a variável resíduo apresenta semivariograma com patamar (estacionaridade de segunda ordem).

Uma outra possibilidade é trabalhar com a hipótese de tendência nos dados originais. Vale ressaltar que a primeira alternativa é a mais simples e a mais utilizada.

Se o semivariograma dos resíduos apresenta efeito pepita puro, pode-se dizer que a superfície de tendência é a melhor representação espacial da variável. Uma metodologia de se ajustar superfícies de tendência é a utilização de regressão múltipla (GUIMARÃES, 2004). A Figura 8 ilustra um variograma sem patamar definido. As amostras que não apresentam dependência espacial ou temporal geram semivariogramas constantes e igual ao patamar para todo valor de h . Essas variáveis podem apresentar dependência espacial para valores de h menores que aqueles estabelecidos para a construção do semivariograma. A Figura 9 ilustra este tipo de semivariograma.




Figura 8. Semivariograma sem patamar definido.




Figura 9. Semivariograma com efeito pepita puro.

Existem semivariogramas que apresentam a semivariância com flutuações. Este semivariograma é chamado de semivariograma periódico ou cíclico e indica uma periodicidade nos dados que pode ser explicada por algum fator conhecido e analisado por meio da densidade espectral. Um semivariograma cíclico é representado na Figura 10. Finalmente pode-se ter os semivariogramas com mais de uma estrutura de variância, que são chamados de semivariogramas com estruturas entrelaçadas ou semivariogramas imbricados.

Neste caso uma explicação prática poderia estar associada ao fato de estarmos trabalhando com mais de uma população, ou seja, até uma distância X estamos trabalhando com uma determinada população e a partir daí outra ou outras populações. A Figura 11 ilustra um semivariograma com estrutura entrelaçada.




Figura 10. Semivariograma cíclico.




Figura 11. Semivariograma com estrutura entrelaçada.

A dependência espacial pode ser mensurada em função da percentagem da semivariância do efeito pepita. Segundo Cambardella et al. (1994), deve-se adotar os seguintes intervalos para o índice de dependência espacial ($IDE = \frac{C}{C + C_0} \cdot 100$):

- * forte dependência espacial: $IDE < 25\%$
- * moderada dependência espacial: $25\% \leq IDE \leq 75\%$
- * fraca dependência espacial: $75\% < IDE < 100\%$

Na prática, após a obtenção dos dados, constrói-se o semivariograma tomando-se todas direções possíveis para distância h . Apenas um semivariograma é suficiente para descrever o comportamento da variável no campo em situações de isotropia, porém

naquelas situações de anisotropia (onde os parâmetros C , C_0 , a e o modelo dependem da direção h) segundo Englund e Sparks (1988), deve-se efetuar as devidas transformações. De acordo com Vieira (1995), apud Guimarães (2004), em geral a precisão da interpolação ou o tipo de hipótese satisfeita não são afetados se, ao invés de se preocupar com a escolha de método de transformação de anisotropia, apenas limitar a faixa de distância na qual se utiliza o semivariograma.

Após a construção do semivariograma, uma função contínua deve ser ajustada as semivariâncias experimentais. Existem alguns métodos que são utilizados para se verificar a qualidade do ajuste do semivariograma aos dados experimentais, onde se destacam: Vieira et al. (1983) sugerem o método de ajuste por tentativa e erro (ajuste a critério do observador) associado à avaliação do modelo pela técnica de validação cruzada ou autovalidação (“jack-Knifing”). Macbratney e Webster (1986) sugerem o método do Critério de Informação de Akaike (AIC) para avaliar o modelo. Já Pannatier (1996) sugere a utilização do Índice de Bondade de Ajuste (IGF).

Os principais modelos utilizados em geoestatística, de acordo com Zimback (2003), são:

a) Esférico

$$\gamma(h) = C_0 + C \left[1,5 \left(\frac{h}{a} \right) - 0,5 \left(\frac{h}{a} \right)^3 \right] \quad \text{para } 0 \leq h \leq a \quad (10)$$

e

$$\gamma(h) = C_0 + C \quad \text{para } h > a \quad (11)$$

b) Exponencial

$$\gamma(h) = C_0 + C \left\{ 1 - e^{\left[-3 \left(\frac{h}{a} \right) \right]} \right\} \quad \text{para } 0 < h < d \quad (12)$$

sendo d a distância máxima na qual o semivariograma é definido

c) Gaussiano

$$\gamma(h) = C_0 + C \left\{ 1 - e^{\left[-3 \left(\frac{h}{a} \right)^2 \right]} \right\} \quad \text{para } 0 \leq h \leq d \quad (13)$$

c) Linear com patamar

$$\gamma(h) = C_0 + \frac{C}{a} h \quad \text{para } 0 \leq h \leq a \quad (14)$$

e

$$\gamma(h) = C_0 + C \quad \text{para } h > a \quad (15)$$

d) Linear sem patamar

$$\gamma(h) = C_0 + Ah^B \quad \text{para } 0 < B < 2 \quad (16)$$

A e B são constantes que definem o modelo.

Através do semivariograma é possível verificar e modelar a dependência espacial de uma variável. Com o semivariograma é possível estimar dados para um mapeamento posterior da variável, sendo o interpolador que utiliza o semivariograma para modelagem chamado de Krigagem. Para a aplicação da Krigagem assume-se que:

1º) exista uma variável $Z(x)$, onde se conhece $z(x_1)$, $z(x_2)$, ..., $z(x_n)$, que são os valores medidos;

2º) o semivariograma da variável já tenha sido determinado;

3º) o objetivo seja estimar $\hat{z}$ na posição x_0 , onde os valores não foram medidos e que o estimador seja uma combinação linear daqueles valores medidos, logo:

$$\hat{z}(x_0) = \sum_{i=1}^n \lambda_i z(x_i) \quad (17)$$

sendo λ_i os pesos associados a cada valor medido. Para que $\hat{z}$ seja uma estimativa não tendenciosa de Z , a soma dos pesos das amostras ($\sum \lambda_i$) deve ser igual a 1 (UZUMAKI, 1994). Os pesos λ_i são variáveis de acordo com a distância entre o ponto a ser estimado e os valores envolvidos nas estimativas. Naquelas situações de independência espacial $\lambda_i = \frac{1}{n}$, gerando simplesmente a média aritmética. A melhor estimativa é obtida quando:

1º) o estimador for não tendencioso, ou seja,

$$E[\hat{z}(x_0) - z(x_0)] = 0 \quad (18)$$

2º) a variância da estimativa for mínima

$$Var[\hat{z}(x_0) - z(x_0)] = \text{mínima} \quad (19)$$

As equações (18) e (19) podem ser trabalhadas e “combinadas” para obtenção da variância mínima de estimativa que segundo Vieira et al. (1983) é dada por:

$$\sigma_E^2 = \mu + \sum_{i=1}^N \lambda_i \gamma(x_i, x_0) \quad (20)$$

Sendo μ o multiplicador de Lagrange que foi aplicado na dedução da equação 17 para se obter o seu mínimo. Quando uma função apresenta extremos condicionados (condição de restrição), pode-se minimizá-la pelo teste da derivada. Porém nos casos onde não é possível resolver a restrição para uma das variáveis em termos das outras se utiliza o multiplicador de Lagrange para se obter os mínimos relativos (LEITHOLD, 1986).

De acordo com Guimarães (2004), o sistema de Krigagem pode ser escrito na forma de notação matricial, facilitando o tratamento computacional, com $n+1$ equações e $n+1$ incógnitas, gerando, desta forma uma única solução que produz n pesos λ e um multiplicador de Lagrange μ . Surgem $n+1$ equações devido ao multiplicador de Lagrange. Na notação matricial chama-se de A a matriz das semivariância dos valores amostrados envolvidos na estimativa de $\hat{z}(x_0)$, λ a matriz coluna que contém os pesos λ_i e o multiplicador de Lagrange e finalmente a matriz coluna (b) das semivariâncias entre os valores amostrados e o ponto a ser estimado. Desta forma:

$$A\lambda = b \quad (21)$$

cuja solução é da forma

$$\lambda = A^{-1}b \quad (22)$$

A variância da estimativa pode ser determinada por :

$$\sigma_E^2 = b^t \lambda \quad (23)$$

onde b^t é a transposta de b .

A determinação de algumas variáveis que caracterizam as propriedades de um determinado solo, freqüentemente são onerosas e de difícil execução. Nestas situações é interessante estimar tais variáveis em função de outras que apresentam boa correlação espacial com as primeiras e que são de simples determinação. Isto pode ser feito através de um semivariograma cruzado. Sejam duas variáveis: $Z_1(x_{1(i)})$, $i = 1, \dots, n_1$ e $Z_2(x_{2(j)})$, $j = 1, \dots, n_2$ onde as amostragens foram feitas no mesmo espaço, mas com $n_1 > n_2$. Assumindo que pelo menos a hipótese intrínseca está sendo atendida para cada variável individualmente e para a distribuição conjunta das variáveis, podemos definir:

1º) os semivariograma individuais

$$\gamma_{11}(h) = \frac{1}{2} E[Z_1(x_{1(i)} + h) - Z_1(x_{1(i)})]^2 \quad (24)$$

$$\gamma_{22}(h) = \frac{1}{2} E[Z_2(x_{2(j)} + h) - Z_2(x_{2(j)})]^2 \quad (25)$$

2º) os semivariogramas cruzados

$$\gamma_{12}(h) = \gamma_{21}(h) = \frac{1}{2} E\{[Z_1(x_{1(i)} + h) - Z_1(x_{1(i)})][Z_2(x_{2(j)} + h) - Z_2(x_{2(j)})]\} \quad (26)$$

A semivariância pode ser estimada por:

$$\gamma_{12}(h) = \gamma_{21}(h) = \frac{1}{2n(h)} \sum_{i=1}^{n(h)} \{[Z_1(x_{1(i)} + h) - Z_1(x_{1(i)})][Z_2(x_{2(j)} + h) - Z_2(x_{2(j)})]\} \quad (27)$$

sendo $n(h)$ o número de valores de Z_1 e Z_2 separados pelo vetor h (GUIMARÃES, 2004).

Ainda, segundo Guimarães (2004), o semivariograma é um caso particular do semivariograma cruzado, quando as duas variáveis são idênticas. O semivariograma cruzado só será calculado usando as informações existentes para posições geográficas coincidentes. Isto significa que Z_1 e Z_2 tem que ser, necessariamente, definidos para os mesmos locais, e as informações excedentes não são consideradas no cálculo. Um semivariograma cruzado com características que podem ser identificadas como ideais, teria aparência do semivariograma simples (de uma única variável, ou seja, patamar definido, semivariância crescente para pequenas distâncias), porém, com significados diferentes, pelo simples fato de envolver o produto das diferenças de duas variáveis distintas.

Ao contrário do semivariograma, o valor do semivariograma cruzado, para $h = 0$, não será nulo. O alcance aqui representa apenas o final ou a distância máxima de

dependência espacial entre as variáveis. Já o patamar do semivariograma cruzado, se existir, deve aproximar-se do valor da covariância entre as duas variáveis. Assim, quando as duas variáveis forem de correlação inversa, isto é, quando aumenta uma a outra diminui, a covariância será negativa e, conseqüentemente, o semivariograma cruzado será negativo. Os modelos utilizados para o semivariograma cruzado são os mesmos já discutidos para o semivariograma simples. O interpolador que utiliza o semivariograma cruzado em sua modelagem é chamado de Co-krigagem. Pode-se, de maneira análoga à krigagem, estimar valores $\hat{z}_2$, para qualquer local x_0 , através uma combinação linear entre Z_1 e Z_2 , da seguinte forma:

$$\hat{z}_2(x_0) = \sum_{i=1}^{n_1} \lambda_{1i} z_1(x_{1i}) + \sum_{j=1}^{n_2} \lambda_{2j} z_2(x_{2j}) \quad (28)$$

Onde n_1 e n_2 são respectivamente os números de vizinhos de Z_1 e Z_2 . Assumindo estacionaridade de ordem 2 e fazendo $z_1(x_{1i})$ e $z_2(x_{2j})$ como sendo uma realização das funções aleatórias $Z_1(x_{1i})$ e $Z_2(x_{2j})$, respectivamente, tem-se:

$$\hat{Z}_2(x_0) = \sum_{i=1}^{n_1} \lambda_{1i} Z_1(x_{1i}) + \sum_{j=1}^{n_2} \lambda_{2j} Z_2(x_{2j}) \quad (29)$$

com o mesmo raciocínio utilizado na krigagem pode-se obter a variância mínima de estimativa, que é dada por

$$\sigma_{K2}^2(x_0) = \mu_1 + \mu_2 + \sum_{i=1}^{n_1} \lambda_{1i} \gamma_{12}(x_{1i}, x_0) + \sum_{j=1}^{n_2} \lambda_{2j} \gamma_{22}(x_{2j}, x_0) \quad (30)$$

De maneira análoga à krigagem, pode-se também escrever o sistema de co-krigagem em notação matricial. A possibilidade de se determinar a variância da estimativa permite que se conheça a confiança associada as estimativas, tornando a Krigagem (ou co-krigagem) um método diferenciado. Quanto menor for o efeito pepita do semivariograma, menor será a variância da estimativa. Mais precisamente, quanto menor for a proporção do efeito pepita para o patamar do semivariograma, maior a continuidade do fenômeno, menor a variância da estimativa ou maior a confiança que se pode ter na estimativa. A variância da estimativa é extremamente sensível à forma do semivariograma, por isso o mapa estimado de isolinhas, de uma certa variável, deve ser sempre acompanhado do mapa correspondente da variância da estimativa, para uma visualização dos locais onde as confianças da estimativa atingem os valores exigidos. A determinação do número de vizinhos em uma estimativa, que é um item de extrema importância, pode ser feita de várias maneiras, cada um com algumas vantagens e desvantagens, sendo que sempre deve-se avaliar, na escolha do método utilizado, o ganho de precisão em relação ao aumento no tempo de computação. Os principais métodos são:

1º) Método da vizinhança única

Quando o tamanho do conjunto de dados, em termos de número de amostras disponíveis tiver tamanho razoável, relativo à quantidade de memória e tempo de processamento disponíveis no computador, pode-se usar o procedimento chamado vizinhança única. Neste procedimento todos os valores medidos são considerados vizinhos e serão

utilizados na estimativa. Deve-se sempre lembrar que a decisão de se usar vizinhança única baseia-se em sua praticidade relativa ao tamanho do conjunto de dados e não na precisão obtida na estimativa. A razão para tanto reside no alcance do semivariograma, pois os pesos associados a vizinhos separados por distâncias maiores do que o alcance, não devem ter contribuição significativa no valor estimado. Outro ponto importante é que, para se usar vizinhança única, é necessário que o semivariograma seja definido até a maior distância existente no espaço. A vantagem deste método reside no fato que, uma vez invertida a matriz de coeficientes, então as estimativas podem ser feitas para qualquer espaçamento com um pequeno consumo de tempo de processamento de computador. Desse modo, a matriz invertida pode ser arquivada no computador e usada quantas vezes for necessário, desde que não mude o modelo do semivariograma e distribuição dos pontos amostrados no espaço. Existem algumas variáveis que, embora mudem as magnitudes de variação, preservam entre si a maneira como variam no espaço, apresentando semivariogramas que podem ser agrupados em um único, quando divididos individualmente, pelas respectivas variâncias. Como exemplo pode-se incluir umidade do solo amostrada em pequenos espaços de tempo. Nesse caso então, as vantagens da vizinhança única aumentam porque modelos de semivariograma escalonados podem ser usados para obter pesos comuns a todas as variáveis.

2º) Método da distância constante

Neste método, para cada ponto estimado é selecionada uma vizinhança constando de todos os vizinhos localizados dentro de um círculo de raio especificado. Conseqüentemente, nos cantos de um campo retangular ocorre 1/4 de círculo, com 1/4 do número de vizinhos. A grande vantagem deste método está no fato que se conhece exatamente a distância na qual os vizinhos para estimativa são procurados. Isto é

particularmente importante porque se pode limitar o uso do semivariograma quanto à distância sobre qual ele será calculado. Por outro lado, o número de vizinhos pode mudar bastante ao longo do campo, fazendo com que o tamanho do sistema matricial seja variável. Em termos de programação de computador, isto pode se tornar um problema se exceder o valor usado na dimensão das matrizes.

3º) Método do número constante de vizinhos

Um outro método bastante usado é o que mantém constante o número de vizinhos em qualquer posição no campo. Para tanto, vizinhos são procurados, primeiramente dentro de um raio inicial. Se o número de vizinhos encontrados for menor do que o limite especificado, a distância é incrementada, e o processo é reiniciado. Se, por outro lado, o número encontrado for maior do que o limite, apenas o número especificado mais próximo será usado. Conseqüentemente, a distância sobre a qual se procura vizinhos varia sobre o campo. Obviamente, as vantagens deste método são as desvantagens do anterior (distância constante) e vice-versa. Porém, em situações em que a amostragem foi efetuada em espaçamentos regulares, a distância de procura por vizinhos não muda muito e as desvantagens deste método são minimizadas. Devido as amostragens regulares serem as mais usadas e as facilidades inerentes deste método, fazem dele o mais comumente usado.

4º) Método dos quadrantes

Uma alternativa interessante e bastante fundamentada em termos geoestatísticos é usar um número especificado de vizinhos em cada quadrante ao redor do valor a ser estimado. O fundamento reside na distribuição do número de vizinhos ao redor do valor estimado, o que fará com que a estimativa receba contribuição semelhante em número, de todas as direções. Muitas vezes quando não se impõe esta restrição, pode-se

despercebidamente, utilizar tendenciosamente sempre um número maior de vizinhos de um lado do que de outro. Porém, isto ainda apresentaria problemas nos cantos e extremidades da área, e também o problema de que nunca se sabe qual a distância na qual os vizinhos se localizam. Por estas razões este método apresenta mais problemas do que vantagens (GUIMARÃES, 2004).

Zimback (2003), cita alguns trabalhos que comparam a Krigagem com outros métodos de interpolação. Numerosos estudos feitos por Kravchenko e Bullock, (1999), demonstram que a ponderação do inverso da distância é mais fácil de se realizar, enquanto a Krigagem consome mais tempo e é mais complicada de se aplicar. Por outro lado a Krigagem faz uma descrição mais acurada da estrutura espacial dos dados e produz valiosa informação sobre a distribuição da estimativa do erro. Creutin e Obled (1982) e Tabios e Salas (1985) fizeram comparações entre algumas técnicas de interpolação e a Krigagem para a distribuição da precipitação anual. A Krigagem mostrou-se mais eficiente. Warrick et al. (1988) obtiveram melhores resultados para a Krigagem, quando comparado com o método do inverso da distância, para mapear a produtividade de tomate e a algumas propriedades do solo. Laslett et al. (1987) conseguiu resultados mais satisfatórios na obtenção do pH do solo usando a Krigagem, quando comparada com o método do inverso da distância. Entretanto, existem trabalhos que demonstram ser o método do inverso da distância mais eficiente que a Krigagem. Weber e Englund (1992) e Wollenhaupt et al. (1994), para mapear níveis de P e K no solo demonstraram superioridade no método do inverso da distância. Também Gotway et al. (1996) mostraram maior eficiência do método do inverso da distância no mapeamento da matéria orgânica e NO_3 no solo.

Fietz et al. (2000), avaliaram a variabilidade espacial e confeccionaram mapas de necessidade de calcário de uma área de Latossolo Roxo, localizada na Embrapa Agropecuária Oeste (em Dourados – MS), com base em técnicas de geoestatística. Através de um semivariograma dos dados, confeccionou-se uma malha através da técnica de Krigagem. Com os valores interpolados, elaborou-se um mapa de aplicação localizada de calcário. Os dados de necessidade de calcário apresentaram dependência espacial com nível moderado, com efeito pepita e patamar de 27% e alcance de 165 m. Com esses resultados a geoestatística mostrou-se valiosa na interpolação de dados e conseqüentemente na confecção de mapas utilizados na agricultura de precisão.

Torres e Prochnow (2000) utilizaram uma combinação dos softwares “Fieldlink”, para coleta dos dados no campo, e “Aglink” para a elaboração dos mapas. Inicialmente foram elaborados os mapas com amostras de solos coletadas sob a “saia” da cultura de citrus e, em seguida, elaborou-se outro mapeamento com amostras de solo coletadas no meio da rua. Os mapas gerados mostraram pH mais elevado e teores de nutrientes menores no meio da rua, o que deve ter ocorrido em função da aplicação localizada de fertilizantes sob a copa das plantas. O trabalho mostrou ser o mapeamento da fertilidade do solo uma importante ferramenta para auxiliar agrônomos, técnicos e agricultores a elaborar uma melhor estratégia de calagem e de adubação, porém os autores levantam a delicada questão sobre o número ideal de subamostras que deve compor uma amostra, o raio de retirada das subamostras e o local, dentro da grade de amostragem, onde se deve fazer a amostragem.

Vieira et al. (2000) analisaram a variabilidade espacial de algumas propriedades do solo e a produção de culturas anuais, em três locais do Estado de São Paulo, através da geoestatística. As amostras foram coletadas em grades de 10 por 10 metros.

Observou-se que as variabilidades do teor de carbono e de sódio eram extremamente contínuas, com semivariogramas esféricos. O semivariograma não representou adequadamente a elevada variabilidade dos parâmetros ligados à textura do solo. Também não se observou relação entre a variabilidade dos parâmetros ligados à permeabilidade do solo e a variabilidade da espessura do solo.

Marques Júnior (2000) avaliou a variabilidade espacial das propriedades granulométricas e químicas dos solos e da produção de café em diferentes superfícies geomórficas, sobre solos altamente intemperizados. Os resultados obtidos foram:

- as propriedades químicas e granulométricas possuem dependência com o relevo, mesmo de pequena expressão e em solos altamente intemperizados e manejados quimicamente.
- todos os atributos químicos e granulométricos apresentaram dependência espacial
- os resultados de semivariogramas foram importantes para subsidiar informações sobre a gênese e evolução dos solos na paisagem.
- o atributo produção de café apresentou dependência espacial em ambas superfícies e, alcance maior na superfície geomórficas mais plana.

2.6. Inteligência Artificial - Redes Neurais Artificiais

Sempre que o homem se depara com um problema e percebe que é necessário transpô-lo, ocorre um desenvolvimento. Dos teares até os automóveis e computadores, observa-se que a necessidade leva à criatividade, ou seja, cada vez que o ser humano sente que determinada tarefa pode ser “automatizada”, ele, então, inicia um processo de imaginar como poderia deixá-la para uma máquina. O computador, em particular, ao

contrário do que muitos pensam, a muito tempo é objeto de sonho de muitos idealizadores. O primeiro computador da história é conhecido como “engenho de diferença”, de Charles Babbage, que foi concebido por volta de 1830, e tinha como função efetuar todas as operações aritméticas e guardar informações para uso posterior. A partir de então, muitos estudiosos se dedicaram ao aperfeiçoamento dos computadores. Em meados de 1940, alguns cientistas começaram a imaginar se o computador poderia resolver problemas não apenas matemáticos, mas também situações que envolvessem raciocínio, conhecimento e inteligência, surgindo assim, uma nova área multidisciplinar, denominada Inteligência Artificial. As pesquisas sobre sistemas inteligentes podem seguir a linha simbólica ou a conexionista. A linha simbólica segue a lógica tradicional, onde os sistemas inteligentes são construídos em função da manipulação simbólica de um grande número de fatos específicos. A linha conexionista procura simular o funcionamento do cérebro humano (com seus neurônios e suas interligações) diretamente em um computador. As duas abordagens apresentam vantagens e desvantagens, porém os sistemas conexionistas empregam representações de conhecimento que parecem ser mais facilmente “aprendíveis” do que as simbólicas (NAKASHIMA, 199-?).

O trabalho pioneiro sobre Redes Neurais Artificiais foi realizado no ano de 1943, por McCulloch e Pitts (EBERHART, 1990). Neste, eles desenvolveram um estudo sobre o comportamento do neurônio biológico com o objetivo de criar um modelo matemático para o mesmo. As conclusões desta pesquisa foram de extrema importância para a futura implementação computacional do neurônio artificial:

- a atividade do neurônio é tudo ou nada ;
- a atividade de qualquer sinapse inibitória previne a excitação do neurônio naquele instante.

A primeira afirmação significa que o neurônio estará no estado ativado se a sua saída ultrapassar um valor limite, caso contrário, ficará no estado de repouso (este princípio originou a função limiar). Entende-se por estado ativado transmitir a saída (transmissão) a outros neurônios da rede. Já a segunda afirmação teve importância na construção do neurônio artificial a partir do conceito de pesos, ou seja, cada entrada do neurônio terá um valor associado; caso este seja positivo, tenderá a excitar a célula; e caso ele seja negativo, tenderá a inibir.

Muitos outros artigos e livros surgiram desde então, porém, pouco resultado foi obtido (HAYKIN, 1994). Em 1949, Donald O. Hebb escreveu o livro intitulado "The Organization of Behavior" definindo o conceito de atualização de pesos sinápticos. Hebb deixou com seu estudo dois pontos importantes:

1. numa rede neural a informação é armazenada nos pesos;
2. quando ocorre o aprendizado os pesos são alterados.

Suas idéias não eram completamente novas, mas Hebb foi o primeiro a propor uma lei de aprendizagem específica para as sinapses dos neurônios. Este primeiro passo serviu de inspiração para que muitos outros pesquisadores perseguissem a mesma idéia. Porém, apesar de todos os estudos feitos até então, o primeiro modelo de rede neural implementado foi o perceptron, por Frank Rosenblatt em 1958. Devido à profundidade de seus estudos, suas contribuições técnicas e de sua maneira moderna de pensar, muitos o vêem como o fundador da neuro computação na forma em que a temos hoje. Seu interesse inicial para a criação do Perceptron era o reconhecimento de padrões (ROSENBLATT, 1959). O perceptron é uma rede neural simples: constitui-se de uma camada de entrada e uma camada de saída. A

cada entrada existe um peso relacionado, sendo que o valor de saída será a soma dos produtos de cada entrada pelo seu respectivo peso. Como definido por McCulloch e Pitts, o neurônio possui um comportamento “tudo” ou “nada”, logo, é necessário estabelecer uma função limiar que defina quando o neurônio estará ativo ou em repouso. O trabalho de Rosenblatt também estabeleceu a base para os algoritmos de treinamento de modelos não supervisionados como o de Kohonen e para modelos supervisionados como o *backpropagation*. Um modelo é dito supervisionado quando é treinado para uma saída pré-determinada, que define um dado padrão de entrada.

A implementação do perceptron no final dos anos 50 foi recebida com grande euforia, já que o teorema da convergência de perceptrons mostrava ser possível classificar qualquer conjunto de entradas separáveis linearmente. Especulava-se sobre a possibilidade de construir sistemas inteligentes a partir de unidades (neurônios) de perceptrons. Em seu livro *Perceptrons*, Minsky e Papert, colocaram um fim a essas especulações, analisando os recursos computacionais dos dispositivos. Os autores observaram que a maioria dos problemas práticos não eram linearmente separáveis o que tornava o perceptron incapaz de aprender a resolver a maioria dos problemas práticos (WASSERMAN, 1989).

Minsky e Papert (1969), apud Rich e Knight (1993), levantaram, como exemplo, o problema do ou exclusivo (XOR), que consistia do seguinte: para duas entradas binárias, produza 1 somente se uma das entradas estiver ligada, caso contrário produza 0. Não existe uma única linha que consiga separar as saídas 1 das saídas 0, impossibilitando o perceptron de encontrar uma solução para este simples problema de

classificação conforme mostrado na Figura 12. Observe que a deficiência não está no algoritmo de aprendizagem por perceptrons, mas no modo como o perceptron representa o conhecimento. Este problema pode ser solucionado com a criação de uma camada intermediária na rede e graficamente com uma estrutura em três (ou mais) dimensões.




Figura 12. Função XOR: uma representação gráfica.

Após Rosenblatt, Bernard Widrow (WIDROW; HOFF, 1960), desenvolveram um novo tipo de redes neurais chamado de Adaline (abreviação de ADaptive LINear Element), e mais tarde propôs a sua generalização multidimensional, o MADALINE (múltipla ADALINE). Esta rede era equipada com uma nova lei de aprendizado, conhecida como a "Regra Delta", que mais tarde foi generalizada para redes com modelos neurais mais elaborados (RUMELHART et al., 1986).

Infelizmente, os anos seguintes foram marcados por um entusiasmo exagerado de muitos pesquisadores, que passaram a publicar vários materiais de divulgação que faziam uma previsão pouco confiável para a época, sobre máquinas tão poderosas como o cérebro humano e que surgiriam em um curto espaço de tempo. Em 1969, Minsky e Papert (MINSKY; PAPERT, 1969) publicaram o livro “Perceptrons - An Introduction to Computational Geometry”, onde os autores argumentaram enfaticamente quanto às limitações básicas dos perceptrons isolados, a começar pela impossibilidade de se implementar regras lógicas tão simples como o ou-exclusivo. Historicamente, a publicação deste livro paralisou, a partir de 1970, as pesquisas na área de redes neurais. Um período de pesquisa silenciosa seguiu-se durante a época de 1969 a 1982, quando poucas pesquisas foram publicadas devido aos fatos ocorridos anteriormente. Entretanto, aqueles que pesquisavam nesta época, e todos os que se seguiram no decorrer de treze anos conseguiram novamente estabelecer um campo concreto para o renascimento da área.

Em 1982 houve uma nova evolução nos trabalhos das redes neurais iniciados pela criação do modelo de Hopfield, desenvolvido por John Hopfield, renomado físico de reputação mundial, se interessou pela neuro computação, e escreveu o clássico artigo “Neural network and physical systems with emergent collective computational abilities”. Hopfield percorreu o mundo todo persuadindo centenas de cientistas, matemáticos, e tecnólogos altamente qualificados a se unirem a esta nova área emergente. Outros pesquisadores também continuaram as pesquisas sobre o assunto, entre eles destacaram-se Teuvo Kohonen (Finlândia), Edoardo Caianiello (Itália), Stephen Grossberg, James Anderson (EUA) e Kunihito Fukushima (Japão).

O modelo apresentado em Hopfield (1982) se caracteriza por ser do tipo *feedback*, isto é, há uma conexão das entradas com as saídas. Por este motivo, estas redes dificilmente chegam a um estado instável, ou seja, chegará um momento em que a saída, após oscilar entre alguns valores binários, será sempre a mesma para um mesmo padrão de entrada. Hopfield, para demonstrar este fato, utilizou o exemplo de uma função matemática que decresce a cada vez que a rede troca de estado, conseqüentemente, chegará um momento em que esta função alcançará um valor mínimo e não será mais alterada. Este é o momento em que a rede alcançou a estabilidade. A rede de Hopfield pode ser comparada a um modelo físico, onde a cada troca de estado da rede a energia da mesma diminui, portanto, a fase de aprendizado chegará ao fim no momento em que a rede tiver a sua energia minimizada.

Apesar de um grande número de pesquisadores da informática terem aderido à área de RNA pela influência de Hopfield, foi em 1986 que este campo de pesquisa se expandiu com a publicação do livro "Parallel Distributed Processing" (Processamento Distribuído Paralelo), de Rumelhart, Hinton e Williams (RUMELHART et al., 1986), onde os autores desenvolveram o algoritmo de aprendizado *backpropagation* para as redes do tipo perceptron com estruturas multicamadas. Paralelamente, os fundamentos teóricos foram melhorados, principalmente por Grossberg (1976a, 1976b), Hopfield (1982) e Kohonen (1988), que também contribuíram para o ressurgimento da área.

Desde então, várias aplicações tem sido mapeadas através de redes neurais artificiais, tais como: reconhecimento de padrões (WIDROW, et al., 1988), processamento de imagens (LIN, et al., 1991), sistemas de controle (NARENDRA; PARTHASARATHY, 1990), Robótica (SMAGT & KROSE, 1991) e identificação de sistemas (NARENDRA; PARTHASARATHY, 1990).

2.6.1. Arquitetura das Redes Neurais Artificiais

Redes neurais artificiais (RNA) são modelos computacionais inspirados no cérebro humano e que possuem a capacidade de aquisição e manutenção do conhecimento. Em outras palavras RNA podem ser definidas como um conjunto de unidades de processamento (neurônios) que são interligados por um grande número de interconexões (sinapses). Uma RNA pode ser treinada para atender uma necessidade particular, através do ajuste dos valores de conexão entre os neurônios (DEMUTH; BEALE, 1998). Comumente uma rede é treinada, ou ajustada, de maneira que um conjunto particular de dados gere um outro conjunto específico de saída, como ilustra a Figura 13.




Figura 13: Esquema geral de treinamento de uma RNA.

As RNA tem sido treinadas para desempenharem muitas funções complexas em vários campos de aplicação, entre eles destacam-se:

1- Reconhecimento de padrões: a tarefa fundamental neste caso é atribuir um padrão de entrada a uma das várias classes predefinidas. Por exemplo: Reconhecimento de voz, imagens, caracteres etc.

2- Estimação (ou predição): dado um conjunto de exemplos $y(t_1), y(t_2), \dots, y(t_n)$, prever o valor $y(t_{n+1})$ no instante de tempo t_{n+1} . A predição é útil na análise do mercado financeiro, previsão de tempo etc.

3- Categorização: neste caso procura-se explorar semelhanças entre padrões e agrupar aqueles que são parecidos. Por exemplo: garimpagem de dados.

4- Aproximação de funções: a utilidade está em encontrar uma estimativa y de uma função desconhecida f . As aplicações são diversas nas áreas de engenharia e modelagem científica.

O elemento de processamento, também conhecido por neurônio, é responsável por processar toda a informação na RNA (BRAGA, 2000). O modelo mais simples de neurônio, proposto por McCulloch e Pitts, está ilustrado na Figura 14.




Figura 14: Modelo de neurônio artificial.

Neste neurônio, tem-se:

$x_1, x_2, \dots, x_R$: elementos do vetor de entrada;

$w_1, w_2, \dots, w_R$: são os pesos (ou conexões sinápticas);

θ_R : limiar de ativação do neurônio;

u_R : saída do combinador linear;

$g(u_R)$: função de ativação;

y : sinal de saída do neurônio.

Os elementos do vetor de entrada $x_1, x_2, \dots, x_R$ são multiplicados pelos pesos $w_1, w_2, \dots, w_R$. Os resultados obtidos são somados pelo combinador linear, que ainda acrescenta o limiar de ativação do neurônio para obter a saída u_R . Assim:

$$u_R = \sum_{i=1}^R w_i \cdot x_i + \theta_R \quad (31)$$

O valor obtido na saída do combinador linear deve ser aplicado à função de ativação $g(u_R)$, para obter o sinal de saída do neurônio. Desta forma:

$$y = g(u_R) \quad (32)$$

Na verdade, a função de ativação processa o conjunto de entradas recebidas e o transforma em estado de ativação. Os estados de ativação que os neurônios podem assumir são: binários (0 e 1), bipolares (-1 e 1), reais.

As funções de ativação mais utilizadas são:

1- Função degrau

Nesse tipo de ativação, mostrado na Figura 15, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ 0 & \text{se } u < 0 \end{cases} \quad (33)$$




Figura 15: Função degrau.

A saída do neurônio assumirá o valor 1 se o nível de atividade interna total do neurônio for não-negativo, caso contrário a saída do neurônio assumirá o valor zero. Este tipo de função é utilizada em problemas de classificação de padrões.

2- Função linear

A função linear $g(u) = \alpha x$, mostrada na Figura 16, é utilizada em aproximações lineares.




Figura 16: Função linear.

3- Função degrau (bipolar)

Nesse tipo de ativação, mostrado na Figura 17, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq 0 \\ -1 & \text{se } u < 0 \end{cases} \quad (34)$$

A saída do neurônio assumirá o valor 1 se o nível de atividade interna total do neurônio for não-negativo, caso contrário, a saída do neurônio assumirá o valor -1.




Figura 17: Função degrau bipolar.

4- Função rampa

Nesse tipo de ativação, mostrado na Figura 18, tem-se:

$$g(u) = \begin{cases} 1 & \text{se } u \geq a \\ u & \text{se } -a < u < a \\ -1 & \text{se } u \leq -a \end{cases} \quad (35)$$




Figura 18: Função rampa.

Para essa função de ativação, a saída do neurônio pode assumir valores positivos e negativos no domínio de -1 a 1, e no intervalo definido em $\{-a, a\}$, a saída assume o valor da função $g(u)=u$.

5- Função sigmóide

Para as funções sigmóides, ilustradas na Figura 19, tem-se:

$$g(u) = \frac{1}{1 + e^{(-\beta u)}} \quad (36)$$




Figura 19: Função sigmóide.

Na função anterior, β é o parâmetro que define a inclinação (ganho) da função sigmóide. Nesse tipo de função, a saída do neurônio assumirá valores reais entre 0 e 1.

6- Função tangente hiperbólica

Para a função do tipo tangente hiperbólica (Figura 20), tem-se:

$$g(u) = \tanh(u) = \frac{1 - e^{-u}}{1 + e^{-u}} \quad (37)$$




Figura 20: Função tangente hiperbólica.

Para esta função de ativação, a saída do neurônio pode assumir valores reais (negativos e positivos) no domínio de -1 a 1.

7- Função Gaussiana

A função de ativação gaussiana é conhecida pelo seu uso em estatística. Aqui ela é usada quando há definição de um ponto médio em u e uma variância a este ponto:

$$g(u) = e^{\frac{-u^2}{v}} \quad (38)$$

onde v é uma variância pré-definida. Veja Figura 21 para $v = 0,2$.




Figura 21. Função Gaussiana.

Resta analisar outro tipo de função: a de aprendizado. As funções de aprendizado em geral dependem do modelo de RNA que é escolhido. Estas funções servem para realizar a alteração dos valores dos pesos da rede, possibilitando assim o aprendizado de um determinado padrão (KOHONEN, 1990). O treinamento de uma rede neural ocorre a partir

de casos reais conhecidos, adquirindo assim a sistemática necessária para executar adequadamente o processo desejado envolvidos com os dados fornecidos. Assim a rede neural é capaz de extrair regras básicas que existam em um conjunto de dados, possibilitando que ocorra o aprendizado através da experiência.

A Figura 22 ilustra a topologia de uma RNA. Esta figura mostra que as camadas de uma RNA são classificadas em:

1-Camada de Entrada: onde os padrões são apresentados à rede




Figura 22: Topologia de uma RNA evidenciando suas camadas.

2-Camadas Intermediárias ou Escondidas: onde é feita a maior parte do processamento.

Através das conexões ponderadas, estas camadas podem ser consideradas como extratoras de características.

3-Camada de Saída: onde o resultado final é concluído e apresentado.

Uma outra maneira de classificação das redes ocorre pela arquitetura em que foram implementadas. Neste caso elas podem ser classificadas como:

1- Redes Feedforward (Única Camada)

São redes neurais onde se tem uma camada de entrada e uma única camada de neurônios que é a própria camada de saída (Figura 23). Suas principais aplicações são em memória associativas e no reconhecimento de padrões (WIDROW et al., 1988). Neste tipo de redes, tem-se o modelo do Perceptron e o Adaline.




Figura 23: Redes Feedforward camada única

2- Redes Feedforward (Multicamadas)

Este tipo de rede distingue da anterior pela presença de uma ou mais camadas escondidas de neurônios (Figura 24). Por exemplo, os neurônios que recebem sinais de excitação do meio externo estão na camada de entrada; os neurônios que estão na saída representam a camada de saída e os neurônios intermediários estão nas camadas escondidas. Suas principais aplicações são em reconhecimento de padrões (JORGE, 1999), aproximador universal de funções e em controle (NETO et al, 1999; NARENDRA e PARTHASARATHY, 1990). Neste tipo de redes, tem-se o Madaline, o Perceptron Multicamadas e o de Função Base Radial (RBF).




Figura 24: Redes Feedforward Multicamadas

3- Redes Recorrentes

São redes que contém realimentação entre neurônios de camadas diferentes (Figura 25).




Figura 25: Redes recorrentes

Suas principais aplicações são em sistemas dinâmicos, memória associativa, previsão e estimação, otimização e em controle. Neste tipo de redes, temos o modelo de Hopfield e o Perceptron com realimentação.

2.6.2. Treinamento das Redes Neurais Artificiais

Para que uma rede neural aprenda por meio de exemplos é necessário que ocorra o treinamento da mesma. Um dos objetivos da pesquisa sobre redes neurais na computação é desenvolver morfologias neurais, baseadas em modelos matemáticos, que podem realizar funções diversas (HAYKIN, 1994). Na maior parte dos casos, modelos neurais são compostos de muitos elementos não lineares que operam em paralelo e que são classificados de acordo com padrões ligados à biologia.

Do ponto de vista estrutural, a arquitetura de redes neurais pode ser classificada como estática, dinâmica ou fuzzy, constituída ainda de uma única camada ou múltiplas camadas. Além disso, algumas diferenças computacionais surgem também quando se trata da maneira com que são feitas as conexões existentes entre os neurônios. Estas conexões podem ser estritamente no sentido de ida, no sentido de ida e volta, lateralmente conectadas, topologicamente ordenadas ou híbridas.

A propriedade mais importante das redes neurais é a habilidade de aprender de seu ambiente e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes (treinamento) aplicado a seus pesos. O processo de aprendizado encerra quando a rede neural consegue generalizar soluções para uma classe de problemas.

Um algoritmo de aprendizado é composto por um conjunto de regras bem definidas visando solução de um problema de aprendizado. Existem muitos tipos de algoritmos de aprendizado específicos para determinados modelos de redes neurais. Estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados. Todo o conhecimento de uma rede neural está armazenado nas sinapses, ou seja, nos pesos atribuídos às conexões entre os neurônios. De 50 a 90% do total de dados deve ser separado para o

treinamento da rede neural, dados estes escolhidos aleatoriamente, a fim de que a rede "aprenda" as regras associadas ao processo. O restante dos dados só é apresentado à rede neural na fase de testes a fim de que ela possa "deduzir" corretamente o inter-relacionamento entre os dados. As principais formas de aprendizado, que estão associados aos processos de ajuste de pesos da rede, podem ser divididos em:

1-Aprendizado Supervisionado: utiliza um agente externo que indica à rede um comportamento bom ou ruim de acordo com o padrão de entrada. A rede é treinada para fornecer a saída desejada em relação a um estímulo de entrada específico. Quando um vetor de entrada é aplicado, a saída da rede é calculada e comparada com o respectivo padrão de saída, a diferença (erro) é então propagada em sentido inverso ao fluxo de informações da rede (das saídas para as entradas) e os pesos são alterados de acordo com algum algoritmo que tende a minimizar o erro. Os vetores de entrada e saída do conjunto de treinamento são aplicados sequencialmente, e os erros são calculados e os pesos ajustados para cada vetor, até que o erro para o conjunto de treinamento seja aceitável.

2- Aprendizado Não Supervisionado: não utiliza um agente externo indicando a resposta desejada para os padrões de entrada, utiliza-se, entretanto, exemplos de características semelhantes para que a rede responda de maneira adequada. A rede se auto-organiza em relação a alguns subconjuntos de entrada cujos elementos possuem características similares. Os vetores do conjunto de treinamento consistem unicamente de vetores de entrada. O algoritmo de treinamento modifica os pesos da rede para produzir vetores de saída que são consistentes, isto é, vetores do conjunto de treinamento que são similares entre si produzirão o mesmo padrão de saída. Nesse tipo de aprendizagem espera-se que o sistema deva estatisticamente descobrir características e particularidades marcantes da população de

entrada. Ao contrário do aprendizado supervisionado, onde não existe um conjunto à priori de categorias dentro do qual os padrões irão ser classificados, o sistema é quem deve desenvolver sua própria representação do estímulo de entrada.

Denomina-se ainda, segundo Haykin (1994), ciclo de aprendizado ou épocas de treinamento como sendo uma apresentação de todos os N pares (entrada e saída) do conjunto de treinamento no processo de aprendizado. A correção dos pesos num ciclo pode ser executado de dois modos: pelo modo Padrão, onde a correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento. Cada correção de pesos baseia-se somente no erro do exemplo apresentado naquela iteração. Assim, em cada ciclo ocorrem N correções. Um outro método para apresentação de dados de treinamento é no modo Batch, onde apenas uma correção é feita por ciclo de treinamento. Todos os exemplos do conjunto de treinamento são apresentados à rede, seu erro médio é calculado e a partir deste erro fazem-se as correções dos pesos.

Para se efetuar o mapeamento do processo através de redes neurais artificiais, alguns passos devem ser seguidos para a adequada aplicação da abordagem neural (HAYKIN, 1994). Os principais passos são especificados a seguir:

Passo 1 - Coleta de dados

O primeiro passo do processo de desenvolvimento de redes neurais artificiais é a coleta de dados relativos ao problema. Esta tarefa requer uma análise cuidadosa sobre o problema visando minimizar ambigüidades e erros nos dados. Além disso, os dados coletados devem ser significativos e cobrir amplamente o domínio do problema; não devem cobrir apenas as operações normais ou rotineiras, mas também as exceções e as condições nos limites do domínio do problema.

Passo 2 - Separação em conjuntos

Normalmente, os dados coletados devem ser separados em duas categorias: dados de treinamento, que serão utilizados para o treinamento da rede; e dados de teste, que serão utilizados para verificar sua performance sob condições reais de utilização.

Depois de determinados estes conjuntos, eles são geralmente colocados em ordem aleatória para prevenção de tendências associadas à ordem de apresentação dos dados. Além disso, pode ser necessário pré-processar estes dados, através de normalizações, escalonamentos e conversões de formato para torná-los mais apropriados à sua utilização na rede.

Passo 3 - Configuração da rede

O terceiro passo é a especificação da configuração da rede, que pode ser dividido em três etapas:

3.1 Seleção da arquitetura neural apropriado à aplicação.

3.2 Determinação da topologia da rede a ser utilizada, ou seja, deve especificar o número de camadas, o número de unidades em cada camada, as funções de ativação, etc.

3.3 Determinação de parâmetros do algoritmo de treinamento e funções de ativação.

Este passo tem um grande impacto na performance do sistema resultante. Existem metodologias na condução destas tarefas. Normalmente parte dessas escolhas é feita de forma empírica. A definição da configuração de redes neurais é ainda considerada uma arte, que requer grande experiência dos projetistas.

Passo 4 - Treinamento

O quarto passo é o treinamento da rede. Nesta fase, seguindo o algoritmo de treinamento escolhido, serão ajustados os pesos das conexões. É importante considerar, nesta fase, alguns aspectos tais como a inicialização da rede, o modo de treinamento e o tempo de treinamento. Uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Normalmente, os valores iniciais dos pesos da rede são números aleatórios pequenos uniformemente distribuídos, em um intervalo definido. Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre será necessário utilizar algum critério de parada. Os principais critérios de parada do algoritmo de aprendizagem são o número máximo de ciclos e o erro quadrático médio por ciclo. Pode ocorrer que em um determinado instante do treinamento a generalização comece a degenerar, causando o problema de “overfitting”, ou seja, a rede se especializa no conjunto de dados do treinamento e perde a capacidade de generalização. O treinamento deve ser encerrado quando a rede apresentar uma boa capacidade de generalização e quando a taxa de erro for suficientemente pequena, ou seja, menor que um erro admissível.

Passo 5 - Teste

O quinto passo é o teste da rede. Durante esta fase o conjunto de teste é utilizado para determinar a performance da rede com dados que não foram previamente utilizados. Quando Redes Neurais Artificiais de uma só camada são utilizadas, os padrões de treinamento apresentados à entrada são mapeados diretamente em um conjunto de padrões de saída da rede, ou seja, não é possível a formação de uma representação interna (HAYKIN, 1994). Neste caso, a codificação proveniente do mundo exterior deve ser suficiente para implementar esse mapeamento. Tal restrição implica que padrões de entrada similares resultem em padrões de saída também similares, o que leva o sistema à incapacidade de aprender

mapeamentos mais complexos. Como resultado, padrões de entrada com estruturas similares, fornecidos do mundo externo, que levem a saídas diferentes não são possíveis de serem mapeados por redes sem representações internas, isto é, sem camadas intermediárias. Um exemplo clássico deste caso é a função ou-exclusivo (XOR).

Minsky e Papert (1969) analisaram matematicamente o Perceptron e demonstraram que redes de uma camada não são capazes de solucionar problemas que não sejam linearmente separáveis. Como não acreditavam na possibilidade de se construir um método de treinamento para redes com mais de uma camada, eles concluíram que as redes neurais seriam sempre susceptíveis a essa limitação.

Contudo, o desenvolvimento do algoritmo de treinamento *backpropagation*, citado por Rumelhart, Hinton e Williams em 1986, precedido por propostas semelhantes ocorridas nos anos 70 e 80, mostrou que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de Redes Neurais Artificiais mais utilizadas atualmente, as redes *Perceptron* Multi-Camadas (PMC), treinadas com o algoritmo *backpropagation*. Nessas redes, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema.

Como provou Cybenko (CYBENKO, 1989), a partir de extensões do Teorema de Kolmogorov são necessárias no máximo duas camadas intermediárias, com um número suficiente de unidades por camada, para se produzir quaisquer mapeamentos. Também

foi provado que apenas uma camada intermediária é suficiente para aproximar qualquer função contínua.

2.7. Redes Neurais Artificiais e suas Aplicações na Agricultura

Pokrajac e Obradovic (2001) estudaram a eficiência das redes neurais na aplicação de fertilizantes a taxas variáveis. Neste trabalho o autor procurou uma ferramenta que otimizasse o lucro no ramo da agricultura através da aplicação de fertilizantes de múltiplos nutrientes em lugar específico, pelo uso de redes neurais baseadas em técnicas de otimização não linear. A não linearidade das funções decorre do campo de colheita apresentar algumas características que podem ser controladas (estas características são: concentração de vários nutrientes e intensidade de irrigação), outras características, relacionadas ao terreno, não podem ser controladas, como, por exemplo: declividade e curvatura do perfil. Os resultados obtidos com o uso das redes neurais com bases radiais (RBF) e sigmoidal (MLP) foram comparados com o método dos mínimos quadrados (OLS), obtido dos modelos lineares. Depois do treinamento das redes as taxas de aplicação do nitrogênio, fósforo e potássio foram estimados sobre um campo de teste usando as técnicas de otimização independente e otimização simultânea. Os resultados obtidos são mostrados no Quadro 6. Os resultados experimentais sugerem que a técnica proposta tem um alto potencial no aumento do lucro com reduções substanciais nas taxas de aplicação de fertilizantes quando comparada com a tradicional aplicação uniforme ou aplicação que utilizam os modelos de regressões lineares.

Sudduth et al. (1996) usou vários métodos de análise (linear e não-linear) sobre um conjunto de dados consistindo de mapas de produtividade de vários anos sobre dois campos. Observou-se que o método linear falhava mais na produção de boas

aproximações funcionais da variabilidade do lucro (produtividade), porque nivelava as regiões de sub-campo e dando idéia de homogeneidade. Já os métodos não-lineares foram capazes de estimar uma quantidade de variações muito maior, mostrando-se mais eficientes.

Quadro 6. Comparação do custo médio de aplicação de fertilizantes e lucro obtido da fertilização uniforme e aplicação seletiva com razões estimadas por modelamento direto e otimização independente.

Tratamento		Custo Médio de Fertilização (\$ / acre)	Lucro Médio (\$ / acre)
Estimado	OLS	Uniforme	167
		Aplicação Seletiva	168
	MLP	Uniforme	169
		Aplicação Seletiva	213
	RBF	Uniforme	185
		Aplicação Seletiva	210
Valor ótimo		50	247

Drummond et al. (1998) procurou compreender melhor das relações fundamentais entre fatores limitantes e respostas nas colheitas. Os métodos tradicionais (tanto lineares como os não-lineares), nem sempre alcançaram a precisão necessária na correlação entre a produção e as propriedades do solo. O autor propõe a aplicação de redes neurais artificiais que são capazes de fornecer alto grau de precisão, enquanto minimizam a possibilidade do excessivo ajustamento dos dados. Foram obtidos conjuntos de dados do estudo dos campos, incluindo produtividade de grãos e altitude, bem como propriedades do solo, tais como: pH, matéria orgânica, fósforo, potássio e capacidade de troca de cátion. Selecionaram-se algumas redes *feedforward* para análise dos dados, incluindo algumas

variações de *backpropagation*. As redes neurais *feedforward* estimaram a relação não linear entre os parâmetros do solo e produtividade com boas características de generalização.

Ulson (2002) desenvolveu um sistema de controle inteligente para aplicação de fertilizantes líquidos em taxas variáveis. O distribuidor foi equipado com um sistema de controle inteligente, mais especificamente, uma rede neural artificial do tipo “Perceptron” multicamadas treinada com o algoritmo de Levenberg-Marquardt. Este sistema inteligente fez (estimou) a identificação inferencial da vazão volumétrica de fertilizante líquido sob as condições de contorno relevantes. Ensaios em condições reais de operação e em bancada demonstraram que o erro relativo médio, quando se utilizou rede neural artificiais, foi de: 2,91% para fertilizante líquido uran (solução – NPK 32:00:00), 2,76% para fertilizante NPK 16:08:08 do tipo suspensão e 3,43% para fertilizantes NPK 15:00:15 do tipo suspensão. O conjunto mostrou-se suficientemente robusto para ser empregado na prática agrícola.

3. MATERIAL E MÉTODOS

3.1. Amostragem do solo

Os dados de solos utilizados para estimar a variabilidade de seus atributos através da krigagem e da co-krigagem, assim como, para treinar as redes neurais artificiais foram obtidos junto a Serrana Fertilizantes do grupo Bunge, que efetuaram em seus próprios laboratórios todas as análises físicas e químicas, cujos resultados estão na planilha do apêndice 1. Nesta planilha encontram-se as seguintes variáveis: areia, silte, argila, soma de bases (SB), capacidade de troca de cátions (CTC), saturação por bases (V), Hidrogênio (H), matéria orgânica (MO), pH, Fósforo (P), Potássio (K), Cálcio (Ca), Magnésio (Mg), Cobre (Cu), Ferro (Fe), Manganês (Mn), Enxofre (S), Zinco (Zn) e Boro (B).

As amostras de solos foram coletadas em uma região próxima a divisa dos estados de Mato Grosso e Mato Grosso do Sul, próximo ao município de Itiquira, nas coordenadas compreendidas entre 17° 35' 22" e 17° 42' 38" de latitude Sul e 54° 61' 75" e

3.2. Metodologia

Dos 275 dados existentes na planilha apresentada no apêndice 1 selecionou-se aleatoriamente 28 (aproximadamente 10%), que foram utilizados como referência na avaliação de desempenho das redes neurais artificiais, da krigagem e da co-krigagem. O valor de 10 % está de acordo com aquele proposto na literatura (HAYKIN, 1994) para a verificação do desempenho (teste) das redes neurais artificiais. O restante das variáveis (247 dados) foram utilizados no treinamento das redes neurais artificiais e na estimativa através da krigagem e co-krigagem. Os resultados obtidos através da redes neurais artificiais foram comparados com aqueles obtidos pela krigagem e co-krigagem, com a finalidade de se verificar a eficiência destas redes na estimativa de atributos do solo. Um segundo conjunto de dados (com 30 pontos) foi selecionado, também aleatoriamente, para se verificar a eficiência das redes neurais artificiais na estimativa das variáveis macroscópicas e microscópicas do solo em função da sua textura (areia, silte e argila). Neste caso, o treinamento das RNA foi realizado com os 245 dados restantes.

A krigagem e a co-krigagem foram desenvolvidas com auxílio do softwre GS⁺ (Gamma Design Software), Versão Beta (5.0.3).

Nas redes neurais artificiais (RNA) utilizou-se as redes perceptron com uma camada escondida na estimativa das variáveis em função das coordenadas geográficas, assim como, para determinar uma variável do solo em função de outra, e redes perceptron com duas camadas escondidas na estimativa das variáveis macroscópicas e microscópicas do solo em função da sua textura, uma vez que nesta estimativa as redes com apenas uma camada escondida não apresentaram resultados favoráveis. Foram utilizadas as

redes perceptron pelo fato destas serem extremamente eficientes em problemas que envolvem estimativas.

As redes perceptron com uma camada escondida foram implementadas no Matlab, versão 6,5, enquanto aquela com duas camadas escondidas foram implementadas em linguagem C, pois como o Matlab é ambiente interpretado, o tempo de treinamento dessas redes no mesmo se mostrou muito longo.

O software utilizado no treinamento das redes está no apêndice 2.

4. RESULTADOS E DISCUSSÃO

Não foi observado concentração de valores em posições específicas da área e também não ocorreu sentido preferencial na distribuição dos dados, tal fato é um bom indicativo de que a distribuição espacial das variáveis (areia, silte, argila, soma de bases, capacidade de troca de cátions, saturação por base, Hidrogênio, matéria orgânica, pH, Fósforo, Potássio, Cálcio, Magnésio, Cobre, Ferro, Manganês, Enxofre, Zinco, Boro), nesta área, é aleatória e isotrópica.

4.1. Desempenho das Redes Neurais Artificiais em relação a Krigagem

4.1.1. Estimativa da areia

Verificou-se que o solo apresentou, na época de coleta, uma concentração média de 34,47 % de areia, com desvio padrão de 10,44 %, apresentando uma variabilidade de 30,28 %. A frequência de distribuição é mostrada na Figura 27. O semivariograma obtido está ilustrado pela Figura 28. A variável areia apresentou melhor

dependência espacial com o modelo exponencial. A relação entre o efeito pepita e o patamar foi de 27,00 %, indicando uma dependência espacial de forte a moderada.




Figura 27. Frequência de distribuição da areia.




Figura 28. Semivariograma da variável areia.

Na estimativa da areia através das RNA utilizou-se uma rede Perceptron com duas variáveis de entrada (latitude e a longitude), contendo 40 neurônios na camada escondida e um neurônio na camada de saída que representa a variável areia.

Os resultados obtidos, pela Krigagem e pela RNA, assim como o erro relativo de cada estimativa e o erro médio, estão listados no Quadro 7.

Quadro 7. Resultados obtidos na estimativa da areia

Talhão	Amostra	Longitude	Latitude	Areia (%) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	59,40	50,00	15,82	59,67	0,45
1	605	-54,665900	-17,394000	34,30	37,52	9,39	35,04	2,16
3	206	-54,666550	-17,407167	48,70	41,78	14,21	52,54	7,89
3	406	-54,661710	-17,404034	33,70	39,08	15,96	36,12	7,20
3	604	-54,653398	-17,405776	37,10	38,36	3,39	30,21	18,58
3	706	-54,654160	-17,399370	32,10	40,80	27,10	32,14	0,14
4	403	-54,647696	-17,419775	29,40	28,78	2,11	29,55	0,52
5	203	-54,630480	-17,423863	28,70	30,90	7,67	27,71	3,44
5	402	-54,625786	-17,419355	32,10	31,59	1,59	28,90	9,96
5	503	-54,628821	-17,415657	35,40	35,22	0,50	29,85	15,69
6	508	-54,682400	-17,401300	39,40	29,15	26,00	42,89	8,85
6	708	-54,679000	-17,406000	36,00	35,95	0,14	36,90	2,50
7	303	-54,654800	-17,416200	44,30	36,19	18,30	36,26	18,14
1	205	-54,653900	-17,376200	36,00	35,16	2,33	42,58	18,29
1	407	-54,649700	-17,369500	24,30	28,11	15,68	24,33	0,12
1	805	-54,635900	-17,371000	24,30	29,83	22,76	23,98	1,29
2	305	-54,654200	-17,364200	22,70	25,72	13,30	23,18	2,09
2	408	-54,653500	-17,355600	22,70	23,29	2,60	24,29	7,02
2	509	-54,651700	-17,352200	22,70	21,68	4,49	26,16	15,23
3	406	-54,625200	-17,355500	32,70	29,96	8,38	33,28	1,76
3	603	-54,628700	-17,365400	26,00	25,91	0,35	24,04	7,55
3	707	-54,617500	-17,360600	39,40	39,49	0,23	41,37	5,00
2	203	-54,645600	-17,388200	52,70	43,66	17,15	50,81	3,59
3	403	-54,629700	-17,400300	42,70	40,65	4,80	41,65	2,46
4	509	-54,647600	-17,398300	39,40	40,49	2,77	37,51	4,78
4	608	-54,643500	-17,399400	36,00	39,55	9,86	38,59	7,19
4	709	-54,642300	-17,395200	46,00	40,07	12,90	44,88	2,44
4	903	-54,627800	-17,407300	39,40	35,86	8,98	34,76	11,78
Erro Médio						9,60	Erro Médio	6,64

4.1.2. Estimativa das demais variáveis

Procedendo-se de maneira análoga à descrita para estimativa da areia efetuou-se a estimativa das outras variáveis, cujos resultados são mostrados nas tabelas que se seguem. Todos estes resultados foram obtidos ajustando-se os respectivos variogramas para que se obter o menor erro e conseqüentemente a maior dependência espacial possível entre as variáveis estudadas. Dentre as variáveis, o pH, o Ca, o Fe e o B apresentaram baixa dependência espacial para as respectivas latitudes e longitudes.

Todos os parâmetros físicos e químicos dos solos foram estimados por redes Perceptron com uma única camada escondida. Os números de neurônios utilizados nas camadas escondidas foram:

- | | |
|---------------------------------------|--|
| - Estimativa do Silte => 21 neurônios | - Estimativa da Argila => 18 neurônios |
| - Estimativa da SB => 40 neurônios | - Estimativa da CTC => 12 neurônios |
| - Estimativa da V => 14 neurônios | - Estimativa do H => 23 neurônios |
| - Estimativa da MO => 11 neurônios | - Estimativa do pH => 12 neurônios |
| - Estimativa do P => 30 neurônios | - Estimativa do K => 12 neurônios |
| - Estimativa do Ca => 10 neurônios | - Estimativa do Mg => 11 neurônios |
| - Estimativa do Cu => 11 neurônios | - Estimativa do Fe => 26 neurônios |
| - Estimativa do Mn => 13 neurônios | - Estimativa do S => 12 neurônios |
| - Estimativa do Zn => 32 neurônios | - Estimativa do B => 16 neurônios |

Os resultados obtidos pela krigagem e pelas RNA, assim como o erro relativo de cada estimativa e o erro médio, estão listados nos Quadros de 08 a 25.

Quadro 8. Resultados obtidos na estimativa do silte.

Talhão	Amostra	Longitude	Latitude	Silte (%) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	6,60	7,39	11,97	7,90	19,6
1	605	-54,665900	-17,39400	8,4	7,5	10,71	8,10	3,57
3	206	-54,666550	-17,407167	6,7	7,5	11,94	8,21	22,5
3	406	-54,661710	-17,404034	8,4	8,2	2,38	8,15	2,96
3	604	-54,653398	-17,405776	8,3	8,2	1,20	8,22	0,96
3	706	-54,654160	-17,399370	10	8,0	20,0	8,21	17,8
4	403	-54,647696	-17,419775	6,6	8,8	33,33	8,21	24,39
5	203	-54,630480	-17,423863	10	7,8	22,00	10,8	8,0
5	402	-54,625786	-17,419355	8,3	8,0	3,61	8,25	0,60
5	503	-54,628821	-17,415657	6,7	7,8	16,42	7,9	17,9
6	508	-54,682400	-17,401300	6,6	8,3	25,76	8,0	21,21
6	708	-54,679000	-17,406000	6,7	7,91	18,06	7,9	17,91
7	303	-54,654800	-17,416200	6,7	8,2	22,39	7,5	11,9
1	205	-54,653900	-17,376200	8,3	8,3	0,0	8,3	0,0
1	407	-54,649700	-17,369500	8,4	8,3	1,19	8,2	2,38
1	805	-54,635900	-17,371000	10,0	8,1	19,0	8,9	11,0
2	305	-54,654200	-17,364200	10,0	8,4	16,0	8,5	15,0
2	408	-54,653500	-17,355600	10,0	8,6	14,0	8,2	18,0
2	509	-54,651700	-17,352200	10,0	8,6	14,0	8,2	18,0
3	406	-54,625200	-17,355500	8,3	8,2	1,21	8,3	0,0
3	603	-54,628700	-17,365400	8,3	8,3	0,0	8,2	1,21
3	707	-54,617500	-17,360600	6,6	8,2	24,24	7,8	18,18
2	203	-54,645600	-17,388200	6,7	7,6	13,43	8,0	19,4
3	403	-54,629700	-17,400300	8,3	7,8	6,02	8,2	1,2
4	509	-54,647600	-17,398300	6,6	8,1	22,73	7,5	13,64
4	608	-54,643500	-17,399400	6,7	8,3	23,88	8,2	22,39
4	709	-54,642300	-17,395200	8,3	8,4	1,20	8,2	1,2
4	903	-54,627800	-17,407300	8,3	7,9	4,82	8,2	1,2
Erro Médio						12,91	Erro Médio	11,0

Quadro 9. Resultados obtidos na estimativa da argila.

Talhão	Amostra	Longitude	Latitude	Argila (%) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	34	39,92	17,41	39,51	16,21
1	605	-54,665900	-17,39400	57,3	54,53	4,83	53,10	7,32
3	206	-54,666550	-17,407167	44,6	49,96	12,02	44,12	1,08
3	406	-54,661710	-17,404034	57,9	49,87	13,87	51,00	11,91
3	604	-54,653398	-17,405776	54,6	55,92	2,42	59,02	8,09
3	706	-54,654160	-17,399370	57,9	51,81	10,52	58,64	1,27
4	403	-54,647696	-17,419775	64,0	61,75	3,52	57,11	10,76
5	203	-54,630480	-17,423863	61,3	60,99	0,51	67,93	10,81
5	402	-54,625786	-17,419355	59,6	60,73	1,90	64,73	8,61
5	503	-54,628821	-17,415657	57,9	57,02	1,52	62,79	8,45
6	508	-54,682400	-17,401300	54,0	62,08	14,96	42,94	20,48
6	708	-54,679000	-17,406000	57,3	51,27	10,52	49,20	14,12
7	303	-54,654800	-17,416200	49,0	55,43	13,22	51,89	5,91
1	205	-54,653900	-17,376200	55,7	56,53	1,49	47,00	15,61
1	407	-54,649700	-17,369500	67,3	63,26	6,00	64,06	4,81
1	805	-54,635900	-17,371000	65,7	61,73	6,04	69,00	5,03
2	305	-54,654200	-17,364200	67,3	64,36	4,37	67,22	0,12
2	408	-54,653500	-17,355600	67,3	66,89	0,61	70,06	4,09
2	509	-54,651700	-17,352200	67,3	68,51	1,80	68,43	1,68
3	406	-54,625200	-17,355500	59	56,21	4,73	53,23	9,78
3	603	-54,628700	-17,365400	65,7	56,67	13,74	65,53	0,25
3	707	-54,617500	-17,360600	54,0	52,46	2,85	52,39	2,98
2	203	-54,645600	-17,388200	40,6	49,67	22,34	43,46	7,06
3	403	-54,629700	-17,400300	49,0	55,48	13,22	42,55	13,15
4	509	-54,647600	-17,398300	54,0	51,81	4,05	55,83	3,38
4	608	-54,643500	-17,399400	57,3	53,26	7,05	54,08	5,61
4	709	-54,642300	-17,395200	45,7	52,64	15,18	47,44	3,81
4	903	-54,627800	-17,407300	52,3	55,73	6,56	49,72	4,93
Erro Médio						7,76	Erro Médio	7,40

Quadro 10. Resultados obtidos na estimativa da Soma de Bases (SB).

Talhão	Amostra	Longitude	Latitude	SB(Cmolc/dm³) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	3,2	3,6	12,5	3,04	4,76
1	605	-54,665900	-17,39400	3,7	3,9	5,41	4,21	13,76
3	206	-54,666550	-17,407167	3,4	3,8	11,76	3,60	6,39
3	406	-54,661710	-17,404034	4,9	4,1	16,33	4,16	15,03
3	604	-54,653398	-17,405776	3,7	4,2	13,51	4,53	22,50
3	706	-54,654160	-17,399370	4,4	3,9	11,36	4,29	2,30
4	403	-54,647696	-17,419775	4,6	4,7	2,17	4,49	2,37
5	203	-54,630480	-17,423863	4,3	3,2	25,58	3,97	7,62
5	402	-54,625786	-17,419355	3,9	3,5	10,26	3,60	7,64
5	503	-54,628821	-17,415657	3,7	3,4	8,11	3,61	2,22
6	508	-54,682400	-17,401300	3,1	4,2	35,48	3,60	16,23
6	708	-54,679000	-17,406000	4,4	4,2	4,55	4,10	6,75
7	303	-54,654800	-17,416200	4,0	4,1	2,5	4,13	3,34
1	205	-54,653900	-17,376200	6,1	4,5	26,23	5,13	15,86
1	407	-54,649700	-17,369500	4,2	4,6	9,52	4,99	18,89
1	805	-54,635900	-17,371000	5,5	4,9	10,9	4,94	10,04
2	305	-54,654200	-17,364200	5,0	5,1	2,0	4,96	0,70
2	408	-54,653500	-17,355600	4,8	5,1	6,25	4,91	2,33
2	509	-54,651700	-17,352200	6,0	4,9	18,33	4,90	18,25
3	406	-54,625200	-17,355500	5,2	4,7	9,61	4,91	5,41
3	603	-54,628700	-17,365400	5,1	4,9	3,92	4,92	3,40
3	707	-54,617500	-17,360600	4,8	4,8	0,0	4,91	2,48
2	203	-54,645600	-17,388200	3,7	4,1	10,81	3,47	6,00
3	403	-54,629700	-17,400300	3,7	3,9	5,41	3,37	8,77
4	509	-54,647600	-17,398300	4,6	3,7	19,57	3,86	16,00
4	608	-54,643500	-17,399400	3,8	4,3	13,16	3,71	2,27
4	709	-54,642300	-17,395200	3,7	4,3	16,22	3,54	4,07
4	903	-54,627800	-17,407300	4,8	3,3	31,25	3,43	28,53
Erro Médio						12,24	Erro Médio	9,05

Quadro 11. Resultados obtidos na estimativa da Capacidade de Troca de Cátions (CTC).

Talhão	Amostra	Longitude	Latitude	CTC(Cmolc/dm ³) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	6,6	7,8	18,18	8,97	35,9
1	605	-54,665900	-17,39400	9,5	9,6	1,05	8,97	5,55
3	206	-54,666550	-17,407167	7,3	8,9	21,92	8,97	22,9
3	406	-54,661710	-17,404034	8,7	8,4	3,45	8,97	3,11
3	604	-54,653398	-17,405776	8,3	9,0	8,43	8,97	8,09
3	706	-54,654160	-17,399370	8,4	9,8	16,66	8,97	6,80
4	403	-54,647696	-17,419775	9,5	9,1	4,21	7,90	16,7
5	203	-54,630480	-17,423863	8,4	7,7	8,33	7,90	5,9
5	402	-54,625786	-17,419355	7,9	7,8	1,27	7,90	0,05
5	503	-54,628821	-17,415657	8,1	7,9	2,47	7,90	2,41
6	508	-54,682400	-17,401300	8,2	9,4	14,63	8,95	9,41
6	708	-54,679000	-17,406000	8,9	8,8	1,12	8,95	0,80
7	303	-54,654800	-17,416200	9,0	9,1	1,11	8,95	0,31
1	205	-54,653900	-17,376200	9,6	9,4	2,08	8,95	6,54
1	407	-54,649700	-17,369500	9,9	9,9	0,0	9,76	1,28
1	805	-54,635900	-17,371000	10,5	9,9	5,71	9,76	6,92
2	305	-54,654200	-17,364200	10,0	9,8	2,0	9,77	2,26
2	408	-54,653500	-17,355600	9,7	9,8	1,03	9,76	0,75
2	509	-54,651700	-17,352200	10,1	9,8	2,97	9,76	3,23
3	406	-54,625200	-17,355500	9,8	9,5	3,06	9,76	0,27
3	603	-54,628700	-17,365400	9,7	9,6	1,03	9,76	0,75
3	707	-54,617500	-17,360600	9,4	9,0	4,26	9,76	3,96
2	203	-54,645600	-17,388200	8,4	9,2	9,52	8,95	6,80
3	403	-54,629700	-17,400300	9,0	7,9	12,22	8,95	0,31
4	509	-54,647600	-17,398300	10,5	8,8	16,19	8,95	14,5
4	608	-54,643500	-17,399400	9,7	9,3	4,12	8,95	7,50
4	709	-54,642300	-17,395200	8,5	9,7	14,11	8,95	5,50
4	903	-54,627800	-17,407300	9,1	7,7	15,38	7,90	13,1
Erro Médio						7,02	Erro Médio	6,60

Quadro 12. Resultados obtidos na estimativa da Saturação por Bases (V).

Talhão	Amostra	Longitude	Latitude	V (%) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	48,1	46,5	3,33	46,45	3,43
1	605	-54,665900	-17,39400	38,8	43,7	12,63	46,45	19,71
3	206	-54,666550	-17,407167	46,0	43,7	5,0	46,45	0,97
3	406	-54,661710	-17,404034	56,7	46,5	17,99	46,45	18,05
3	604	-54,653398	-17,405776	44,8	46,2	3,13	46,45	3,68
3	706	-54,654160	-17,399370	51,9	44,0	15,22	46,45	10,5
4	403	-54,647696	-17,419775	48,0	48,6	1,25	46,45	3,20
5	203	-54,630480	-17,423863	50,7	43,9	13,41	46,45	8,38
5	402	-54,625786	-17,419355	49,2	44,2	10,16	46,45	5,58
5	503	-54,628821	-17,415657	45,2	43,3	4,2	46,45	2,75
6	508	-54,682400	-17,401300	38,0	46,1	21,32	46,45	22,20
6	708	-54,679000	-17,406000	48,9	46,8	4,29	46,45	5,01
7	303	-54,654800	-17,416200	44,7	45,7	2,23	46,45	3,91
1	205	-54,653900	-17,376200	63,9	47,3	25,97	46,45	27,3
1	407	-54,649700	-17,369500	42,8	48,6	13,55	46,45	8,52
1	805	-54,635900	-17,371000	52,2	47,2	9,58	46,45	11,01
2	305	-54,654200	-17,364200	49,6	48,8	1,61	46,45	6,35
2	408	-54,653500	-17,355600	49,2	47,5	3,46	46,45	5,58
2	509	-54,651700	-17,352200	59,2	48,6	17,91	46,45	21,53
3	406	-54,625200	-17,355500	52,4	51,3	2,10	46,45	11,35
3	603	-54,628700	-17,365400	52,6	49,0	6,84	46,45	11,69
3	707	-54,617500	-17,360600	50,8	51,0	0,39	46,45	8,56
2	203	-54,645600	-17,388200	44,3	44,8	1,13	46,45	4,85
3	403	-54,629700	-17,400300	41,1	43,0	4,62	46,45	13,01
4	509	-54,647600	-17,398300	44,0	44,0	0,0	46,45	5,55
4	608	-54,643500	-17,399400	38,8	46,7	20,36	46,45	19,71
4	709	-54,642300	-17,395200	43,3	48,0	10,85	46,45	7,27
4	903	-54,627800	-17,407300	53,3	43,6	18,19	46,45	12,85
Erro Médio						8,96	Erro Médio	10,00

Quadro 13. Resultados obtidos na estimativa do Hidrogênio (H).

Talhão	Amostra	Longitude	Latitude	H(Cmolc/dm³) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	3,4	4,2	23,53	5,09	49,90
1	605	-54,665900	-17,39400	5,8	5,9	1,72	5,28	8,65
3	206	-54,666550	-17,407167	3,9	4,8	23,08	4,31	10,52
3	406	-54,661710	-17,404034	3,7	4,5	21,62	4,13	11,67
3	604	-54,653398	-17,405776	4,6	4,8	4,35	4,18	8,85
3	706	-54,654160	-17,399370	4,1	5,0	21,95	4,41	7,56
4	403	-54,647696	-17,419775	4,9	4,4	10,21	4,13	15,58
5	203	-54,630480	-17,423863	4,2	4,5	7,14	4,14	1,34
5	402	-54,625786	-17,419355	4,0	4,4	10,0	4,63	15,93
5	503	-54,628821	-17,415657	4,4	4,6	4,55	4,35	0,94
6	508	-54,682400	-17,401300	5,1	5,0	1,96	4,74	6,98
6	708	-54,679000	-17,406000	4,6	4,4	4,35	4,69	2,10
7	303	-54,654800	-17,416200	5,0	5,2	4,0	4,90	1,89
1	205	-54,653900	-17,376200	3,5	4,7	34,29	5,07	44,98
1	407	-54,649700	-17,369500	5,7	5,1	10,53	4,90	13,32
1	805	-54,635900	-17,371000	5,0	5,0	0,0	4,81	3,78
2	305	-54,654200	-17,364200	5,1	4,7	7,84	4,93	3,00
2	408	-54,653500	-17,355600	4,9	4,8	2,04	4,80	1,11
2	509	-54,651700	-17,352200	4,1	5,0	21,95	4,79	16,89
3	406	-54,625200	-17,355500	4,7	4,9	4,26	4,61	1,89
3	603	-54,628700	-17,365400	4,6	4,8	4,35	4,70	2,27
3	707	-54,617500	-17,360600	4,6	4,2	8,70	4,61	0,29
2	203	-54,645600	-17,388200	4,7	5,4	14,89	5,14	9,40
3	403	-54,629700	-17,400300	5,3	4,7	11,32	5,96	12,51
4	509	-54,647600	-17,398300	5,9	5,0	15,25	4,74	19,20
4	608	-54,643500	-17,399400	5,9	5,1	13,56	4,80	18,52
4	709	-54,642300	-17,395200	4,8	5,0	4,17	5,23	9,08
4	903	-54,627800	-17,407300	4,2	4,5	7,14	4,41	5,18
Erro Médio						10,67	Erro Médio	10,80

Quadro 14. Resultados obtidos na estimativa da Matéria Orgânica (MO).

Talhão	Amostra	Longitude	Latitude	MO (%) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	2,6	3,0	15,38	3,67	41,43
1	605	-54,665900	-17,39400	3,7	3,9	5,41	3,65	0,84
3	206	-54,666550	-17,407167	2,81	3,6	28,11	3,55	26,37
3	406	-54,661710	-17,404034	3,5	3,6	2,86	3,56	1,86
3	604	-54,653398	-17,405776	3,4	3,6	5,88	3,52	3,50
3	706	-54,654160	-17,399370	3,4	3,6	5,88	3,58	5,42
4	403	-54,647696	-17,419775	3,8	3,6	5,26	3,36	11,43
5	203	-54,630480	-17,423863	3,31	3,00	9,37	3,26	1,30
5	402	-54,625786	-17,419355	3,22	3,00	6,83	3,29	2,34
5	503	-54,628821	-17,415657	3,22	3,13	2,79	3,34	3,79
6	508	-54,682400	-17,401300	3,3	3,7	12,12	3,65	10,63
6	708	-54,679000	-17,406000	3,6	3,4	5,56	3,60	0,04
7	303	-54,654800	-17,416200	3,5	3,6	2,86	3,42	2,14
1	205	-54,653900	-17,376200	3,7	3,7	0,0	3,78	2,18
1	407	-54,649700	-17,369500	4,0	3,9	2,5	3,82	4,49
1	805	-54,635900	-17,371000	4,2	3,9	7,14	3,77	10,15
2	305	-54,654200	-17,364200	4,0	3,9	2,5	3,76	3,30
2	408	-54,653500	-17,355600	3,9	3,9	0,0	3,90	0,54
2	509	-54,651700	-17,352200	4,0	3,9	2,5	3,93	1,55
3	406	-54,625200	-17,355500	4,0	3,7	7,5	3,85	3,50
3	603	-54,628700	-17,365400	3,9	3,8	2,56	3,79	2,63
3	707	-54,617500	-17,360600	3,7	3,6	2,70	3,80	2,82
2	203	-54,645600	-17,388200	3,3	3,6	9,10	3,65	10,87
3	403	-54,629700	-17,400300	3,6	3,4	5,56	3,49	2,87
4	509	-54,647600	-17,398300	4,1	3,5	14,63	3,57	12,83
4	608	-54,643500	-17,399400	3,8	3,7	2,63	3,55	6,57
4	709	-54,642300	-17,395200	3,4	3,7	8,82	3,56	5,43
4	903	-54,627800	-17,407300	3,7	3,1	16,22	3,42	7,52
Erro Médio						6,88	Erro Médio	6,68

Quadro 15. Resultados obtidos na estimativa do pH.

Talhão	Amostra	Longitude	Latitude	pH(CaCl ₂) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	5,2	5,0	3,85	5,09	2,01
1	605	-54,665900	-17,39400	4,8	5,0	4,17	5,09	6,15
3	206	-54,666550	-17,407167	5,1	4,9	3,92	5,09	0,09
3	406	-54,661710	-17,404034	5,3	5,0	5,66	5,09	3,70
3	604	-54,653398	-17,405776	5,0	5,1	2,0	5,09	1,90
3	706	-54,654160	-17,399370	5,2	5,0	3,85	5,09	2,01
4	403	-54,647696	-17,419775	5,2	5,2	0,0	5,09	1,99
5	203	-54,630480	-17,423863	5,2	5,0	3,85	5,32	2,32
5	402	-54,625786	-17,419355	5,2	5,0	3,85	5,09	2,01
5	503	-54,628821	-17,415657	5,1	5,0	1,96	5,09	0,09
6	508	-54,682400	-17,401300	4,8	5,0	4,17	5,09	6,15
6	708	-54,679000	-17,406000	5,2	5,1	1,92	5,09	2,01
7	303	-54,654800	-17,416200	5,0	5,0	0,0	5,09	1,90
1	205	-54,653900	-17,376200	5,4	5,0	7,41	5,21	3,45
1	407	-54,649700	-17,369500	5,0	5,0	0,0	5,21	4,27
1	805	-54,635900	-17,371000	5,3	5,1	3,77	5,21	1,62
2	305	-54,654200	-17,364200	5,2	5,1	1,92	5,21	0,26
2	408	-54,653500	-17,355600	5,2	5,1	1,92	5,21	0,26
2	509	-54,651700	-17,352200	5,7	5,2	8,77	5,21	8,53
3	406	-54,625200	-17,355500	5,3	5,2	1,89	5,21	1,62
3	603	-54,628700	-17,365400	5,2	5,2	0,0	5,21	0,26
3	707	-54,617500	-17,360600	5,3	5,2	1,89	5,21	1,62
2	203	-54,645600	-17,388200	5,0	5,2	4,0	4,83	3,24
3	403	-54,629700	-17,400300	4,9	5,0	2,04	4,91	0,37
4	509	-54,647600	-17,398300	5,0	5,0	0,0	5,09	1,90
4	608	-54,643500	-17,399400	4,8	5,1	6,25	5,09	6,15
4	709	-54,642300	-17,395200	5,0	5,1	2,0	4,83	3,24
4	903	-54,627800	-17,407300	5,3	5,0	5,66	5,09	3,86
Erro Médio						3,1	Erro Médio	2,59

Quadro 16. Resultados obtidos na estimativa do Fósforo (P).

Talhão	Amostra	Longitude	Latitude	P (ppm) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	12,0	10,9	9,17	9,30	22,43
1	605	-54,665900	-17,39400	13,0	12,9	0,76	10,21	21,43
3	206	-54,666550	-17,407167	6,4	7,8	21,87	6,37	0,33
3	406	-54,661710	-17,404034	9,0	7,0	22,22	6,49	27,70
3	604	-54,653398	-17,405776	9,4	7,4	21,28	7,01	25,38
3	706	-54,654160	-17,399370	6,4	7,9	23,44	6,68	4,51
4	403	-54,647696	-17,419775	10,6	7,3	31,13	7,77	26,68
5	203	-54,630480	-17,423863	8,2	8,7	6,10	8,38	2,23
5	402	-54,625786	-17,419355	8,2	9,0	9,76	8,40	2,45
5	503	-54,628821	-17,415657	10,6	8,3	21,7	8,24	22,20
6	508	-54,682400	-17,401300	9,0	7,2	20,0	9,00	0,86
6	708	-54,679000	-17,406000	8,0	7,4	7,5	9,80	23,50
7	303	-54,654800	-17,416200	4,0	6,0	50,0	5,36	34,00
1	205	-54,653900	-17,376200	11,0	8,0	27,27	9,70	10,9
1	407	-54,649700	-17,369500	8,0	8,6	7,5	9,50	19,60
1	805	-54,635900	-17,371000	8,0	10,0	25,0	11,27	40,90
2	305	-54,654200	-17,364200	9,0	7,6	15,56	8,34	7,27
2	408	-54,653500	-17,355600	7,0	7,8	11,43	7,35	5,10
2	509	-54,651700	-17,352200	9,0	7,8	13,33	7,10	20,0
3	406	-54,625200	-17,355500	15,0	11,7	22,0	10,00	25,8
3	603	-54,628700	-17,365400	11,0	11,9	8,18	11,48	4,45
3	707	-54,617500	-17,360600	6,0	10,6	76,67	7,00	16,6
2	203	-54,645600	-17,388200	5,0	7,3	46,0	6,62	32,5
3	403	-54,629700	-17,400300	9,0	7,8	13,33	7,80	13,24
4	509	-54,647600	-17,398300	9,0	6,9	23,33	6,97	22,46
4	608	-54,643500	-17,399400	5,0	7,3	46,00	5,21	4,20
4	709	-54,642300	-17,395200	6,0	7,6	26,67	7,10	18,40
4	903	-54,627800	-17,407300	13,0	9,0	30,8	8,06	37,93
Erro Médio						22,8	Erro Médio	20,68

Quadro 17. Resultados obtidos na estimativa do Potássio (K).

Talhão	Amostra	Longitude	Latitude	K (ppm) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	63,0	77,15	22,46	87,33	38,63
1	605	-54,665900	-17,39400	109,0	94,25	13,53	89,54	17,85
3	206	-54,666550	-17,407167	60,0	88,5	47,5	88,28	47,14
3	406	-54,661710	-17,404034	120,0	73,28	38,93	89,75	25,20
3	604	-54,653398	-17,405776	81,0	87,0	7,41	92,23	13,86
3	706	-54,654160	-17,399370	68,0	74,56	9,65	92,80	36,47
4	403	-54,647696	-17,419775	143,0	115,0	19,58	90,11	36,98
5	203	-54,630480	-17,423863	72,0	63,3	12,08	61,71	14,29
5	402	-54,625786	-17,419355	74,0	104,8	41,62	64,88	12,31
5	503	-54,628821	-17,415657	60,0	69,4	15,67	65,82	9,71
6	508	-54,682400	-17,401300	50,0	93,9	87,8	85,91	71,82
6	708	-54,679000	-17,406000	105,0	89,0	15,24	86,15	17,94
7	303	-54,654800	-17,416200	88,0	106,0	20,45	90,44	2,77
1	205	-54,653900	-17,376200	157,0	99,7	36,49	96,60	38,46
1	407	-54,649700	-17,369500	91,0	108,0	18,68	100,60	10,55
1	805	-54,635900	-17,371000	112,0	116,0	3,57	112,46	0,41
2	305	-54,654200	-17,364200	105,0	119,3	13,62	98,82	5,88
2	408	-54,653500	-17,355600	100,0	116,7	16,7	101,26	1,26
2	509	-54,651700	-17,352200	106,0	99,2	6,42	103,51	2,34
3	406	-54,625200	-17,355500	135,0	124,2	8,0	135,04	0,03
3	603	-54,628700	-17,365400	108,0	110,0	1,85	124,18	14,98
3	707	-54,617500	-17,360600	152,0	143,9	5,33	145,16	4,49
2	203	-54,645600	-17,388200	126,0	90,5	28,17	99,08	21,36
3	403	-54,629700	-17,400300	124,0	62,9	49,27	94,76	23,57
4	509	-54,647600	-17,398300	79,0	106,0	34,17	95,91	21,41
4	608	-54,643500	-17,399400	63,0	95,0	50,79	97,85	55,32
4	709	-54,642300	-17,395200	76,0	99,67	31,14	99,57	31,01
4	903	-54,627800	-17,407300	94,0	63,9	32,02	74,56	20,67
Erro Médio						24,58	Erro Médio	21,30

Quadro 18. Resultados obtidos na estimativa do Cálcio (Ca).

Talhão	Amostra	Longitude	Latitude	Ca(Cmolc/dm³) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)	
1	306	-54,675000	-17,396100	2,0	2,6	30,0	2,56	28,19	
1	605	-54,665900	-17,39400	2,3	2,54	10,43	2,56	11,47	
3	206	-54,666550	-17,407167	2,3	2,51	9,13	2,56	11,47	
3	406	-54,661710	-17,404034	3,2	2,7	15,63	2,56	19,88	
3	604	-54,653398	-17,405776	2,5	2,71	8,4	2,56	2,55	
3	706	-54,654160	-17,399370	3,0	2,7	10,0	2,56	14,53	
4	403	-54,647696	-17,419775	2,9	2,7	6,9	2,75	5,01	
5	203	-54,630480	-17,423863	2,9	2,4	17,24	3,23	11,65	
5	402	-54,625786	-17,419355	2,6	2,5	3,85	2,56	1,39	
5	503	-54,628821	-17,415657	2,5	2,4	4,0	2,56	2,55	
6	508	-54,682400	-17,401300	2,2	2,7	22,73	2,56	16,53	
6	708	-54,679000	-17,406000	2,9	2,8	3,45	2,56	11,59	
7	303	-54,654800	-17,416200	2,3	2,7	17,39	2,56	11,51	
1	205	-54,653900	-17,376200	4,2	3,0	28,57	3,35	20,21	
1	407	-54,649700	-17,369500	2,9	3,1	6,89	3,35	15,55	
1	805	-54,635900	-17,371000	3,8	2,9	23,68	3,35	11,81	
2	305	-54,654200	-17,364200	3,5	3,2	8,57	3,35	4,25	
2	408	-54,653500	-17,355600	3,4	3,2	5,88	3,35	1,44	
2	509	-54,651700	-17,352200	4,1	3,2	21,95	3,35	18,26	
3	406	-54,625200	-17,355500	3,3	3,1	6,06	3,35	1,54	
3	603	-54,628700	-17,365400	3,4	3,2	5,88	3,35	1,44	
3	707	-54,617500	-17,360600	2,9	3,0	3,45	3,35	15,55	
2	203	-54,645600	-17,388200	2,1	3,1	47,62	2,56	22,08	
3	403	-54,629700	-17,400300	2,4	2,4	0,0	2,56	6,82	
4	509	-54,647600	-17,398300	3,0	2,5	16,67	2,56	14,53	
4	608	-54,643500	-17,399400	2,4	2,8	16,67	2,56	6,82	
4	709	-54,642300	-17,395200	2,3	2,9	26,09	2,56	11,47	
4	903	-54,627800	-17,407300	3,1	2,4	22,58	2,56	17,29	
Erro Médio						14,28	Erro Médio		11,33

Quadro 19. Resultados obtidos na estimativa do Magnésio (Mg).

Talhão	Amostra	Longitude	Latitude	Mg(Cmolc/dm³) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	1,0	1,0	0,0	1,00	0,69
1	605	-54,665900	-17,39400	1,1	1,0	9,09	1,09	0,61
3	206	-54,666550	-17,407167	0,9	1,2	33,33	1,08	20,03
3	406	-54,661710	-17,404034	1,4	1,2	14,29	1,05	24,67
3	604	-54,653398	-17,405776	1,0	1,2	20,0	1,09	9,06
3	706	-54,654160	-17,399370	1,2	1,0	16,67	1,12	6,17
4	403	-54,647696	-17,419775	1,3	1,5	15,38	1,35	4,24
5	203	-54,630480	-17,423863	1,2	0,9	25,0	1,22	1,90
5	402	-54,625786	-17,419355	1,1	1,0	9,09	1,16	5,73
5	503	-54,628821	-17,415657	1,0	0,9	10,0	1,16	16,04
6	508	-54,682400	-17,401300	0,8	1,4	75,0	1,02	28,15
6	708	-54,679000	-17,406000	1,2	1,2	0,0	1,20	0,10
7	303	-54,654800	-17,416200	1,5	1,3	13,33	1,30	13,23
1	205	-54,653900	-17,376200	1,5	1,2	20,0	1,23	17,72
1	407	-54,649700	-17,369500	1,1	1,2	9,09	1,25	13,86
1	805	-54,635900	-17,371000	1,4	1,3	7,14	1,26	9,83
2	305	-54,654200	-17,364200	1,2	1,3	8,33	1,25	4,57
2	408	-54,653500	-17,355600	1,1	1,2	9,09	1,26	14,89
2	509	-54,651700	-17,352200	1,6	1,2	25,0	1,26	20,81
3	406	-54,625200	-17,355500	1,5	1,3	13,33	1,27	15,12
3	603	-54,628700	-17,365400	1,4	1,3	7,14	1,26	9,34
3	707	-54,617500	-17,360600	1,5	1,4	6,66	1,27	15,11
2	203	-54,645600	-17,388200	1,3	1,1	15,38	1,21	6,29
3	403	-54,629700	-17,400300	1,0	0,9	10,0	1,21	21,84
4	509	-54,647600	-17,398300	1,4	1,1	21,43	1,16	16,69
4	608	-54,643500	-17,399400	1,2	1,3	8,33	1,17	1,85
4	709	-54,642300	-17,395200	1,2	1,3	8,33	1,20	0,13
4	903	-54,627800	-17,407300	1,5	1,0	33,3	1,19	20,11
Erro Médio						15,85	Erro Médio	11,35

Quadro 20. Resultados obtidos na estimativa do Cobre (Cu).

Talhão	Amostra	Longitude	Latitude	Cu (ppm) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	1,0	1,2	20,0	1,26	26,00
1	605	-54,665900	-17,39400	1,2	1,1	8,33	1,26	5,00
3	206	-54,666550	-17,407167	2,0	1,1	45,0	1,26	36,90
3	406	-54,661710	-17,404034	1,5	1,3	13,3	1,26	15,90
3	604	-54,653398	-17,405776	1,1	1,4	27,27	1,26	14,54
3	706	-54,654160	-17,399370	1,0	1,2	20,0	1,26	26,00
4	403	-54,647696	-17,419775	1,7	1,2	29,41	1,51	11,12
5	203	-54,630480	-17,423863	1,1	1,1	0,0	1,10	0,72
5	402	-54,625786	-17,419355	1,0	1,1	10,0	1,10	10,79
5	503	-54,628821	-17,415657	1,9	1,0	47,37	1,10	41,68
6	508	-54,682400	-17,401300	1,3	1,1	15,38	1,26	3,07
6	708	-54,679000	-17,406000	1,1	1,2	9,1	1,26	14,54
7	303	-54,654800	-17,416200	1,3	1,3	0,0	1,26	3,07
1	205	-54,653900	-17,376200	1,3	1,1	15,38	0,88	31,88
1	407	-54,649700	-17,369500	1,2	1,0	16,67	0,88	26,20
1	805	-54,635900	-17,371000	1,0	0,8	20,0	0,88	11,44
2	305	-54,654200	-17,364200	0,9	0,9	0,0	0,88	1,60
2	408	-54,653500	-17,355600	0,9	1,0	11,11	0,88	1,60
2	509	-54,651700	-17,352200	1,0	1,1	10,0	0,88	11,44
3	406	-54,625200	-17,355500	1,2	0,8	33,33	0,88	26,20
3	603	-54,628700	-17,365400	0,9	0,8	11,11	0,88	1,60
3	707	-54,617500	-17,360600	1,0	0,8	20,0	0,88	11,44
2	203	-54,645600	-17,388200	0,9	0,9	0,0	0,88	1,60
3	403	-54,629700	-17,400300	1,4	0,8	42,86	0,88	36,74
4	509	-54,647600	-17,398300	0,5	0,9	80,0	0,88	77,10
4	608	-54,643500	-17,399400	0,6	0,7	16,66	0,88	47,59
4	709	-54,642300	-17,395200	0,5	0,7	40,0	0,88	77,10
4	903	-54,627800	-17,407300	1,0	1,1	10,0	0,88	11,42
Erro Médio						20,44	Erro Médio	20,80

Quadro 21. Resultados obtidos na estimativa do Ferro (Fe).

Talhão	Amostra	Longitude	Latitude	Fe (ppm) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	118,0	104,3	11,61	119,45	1,23
1	605	-54,665900	-17,39400	151,0	102,8	31,92	118,83	21,29
3	206	-54,666550	-17,407167	105,0	108,4	3,24	119,45	13,76
3	406	-54,661710	-17,404034	241,0	117,9	51,08	119,44	50,43
3	604	-54,653398	-17,405776	91,0	100,1	10,0	118,82	30,57
3	706	-54,654160	-17,399370	86,0	103,3	20,12	101,72	18,28
4	403	-54,647696	-17,419775	77,0	136,2	76,88	119,45	55,13
5	203	-54,630480	-17,423863	128,0	83,9	34,45	113,80	11,08
5	402	-54,625786	-17,419355	74,0	84,8	14,59	85,13	15,04
5	503	-54,628821	-17,415657	79,0	84,0	6,33	84,95	7,53
6	508	-54,682400	-17,401300	135,0	96,8	28,3	119,45	11,51
6	708	-54,679000	-17,406000	86,0	98,9	15,0	119,45	38,89
7	303	-54,654800	-17,416200	112,0	121,1	8,13	119,45	6,65
1	205	-54,653900	-17,376200	92,0	91,56	0,48	87,69	4,68
1	407	-54,649700	-17,369500	92,0	82,1	10,76	82,61	10,19
1	805	-54,635900	-17,371000	80,0	86,4	8,0	82,61	3,26
2	305	-54,654200	-17,364200	81,0	88,1	8,76	82,61	1,99
2	408	-54,653500	-17,355600	84,0	87,4	4,05	82,61	1,65
2	509	-54,651700	-17,352200	63,0	85,3	25,4	82,61	31,13
3	406	-54,625200	-17,355500	84,0	82,8	1,43	82,61	1,65
3	603	-54,628700	-17,365400	76,0	83,4	9,74	82,61	8,70
3	707	-54,617500	-17,360600	63,0	80,5	27,78	82,61	31,13
2	203	-54,645600	-17,388200	144,0	88,1	38,82	114,32	20,60
3	403	-54,629700	-17,400300	91,0	84,3	7,36	93,78	3,05
4	509	-54,647600	-17,398300	83,0	89,0	7,23	85,00	2,42
4	608	-54,643500	-17,399400	93,0	100,0	7,53	84,44	9,20
4	709	-54,642300	-17,395200	71,0	93,4	31,55	96,35	35,71
4	903	-54,627800	-17,407300	68,0	83,9	23,38	70,75	4,05
Erro Médio						19,10	Erro Médio	16,10

Quadro 22. Resultados obtidos na estimativa do Manganês (Mn).

Talhão	Amostra	Longitude	Latitude	Mn (ppm) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	17,1	19,8	15,79	18,61	8,84
1	605	-54,665900	-17,39400	19,9	22,8	14,57	19,45	2,21
3	206	-54,666550	-17,407167	22,7	29,8	31,28	25,11	10,64
3	406	-54,661710	-17,404034	24,0	27,8	15,83	25,23	5,15
3	604	-54,653398	-17,405776	31,2	24,2	22,43	26,69	14,43
3	706	-54,654160	-17,399370	20,5	24,0	17,07	21,79	6,29
4	403	-54,647696	-17,419775	26,5	27,1	2,26	20,62	22,18
5	203	-54,630480	-17,423863	17,8	17,0	4,49	20,58	15,65
5	402	-54,625786	-17,419355	17,0	18,3	7,64	20,58	21,09
5	503	-54,628821	-17,415657	17,7	18,9	6,78	20,58	16,31
6	508	-54,682400	-17,401300	15,6	18,0	15,38	18,52	18,77
6	708	-54,679000	-17,406000	19,3	19,0	1,55	22,48	16,48
7	303	-54,654800	-17,416200	28,9	24,9	13,84	27,59	4,50
1	205	-54,653900	-17,376200	20,4	23,7	16,18	18,53	9,13
1	407	-54,649700	-17,369500	20,6	25,0	21,36	23,00	11,66
1	805	-54,635900	-17,371000	24,4	26,1	6,97	26,65	9,25
2	305	-54,654200	-17,364200	26,4	24,1	8,71	22,81	13,57
2	408	-54,653500	-17,355600	20,5	23,4	14,15	22,79	11,20
2	509	-54,651700	-17,352200	25,7	21,6	15,95	22,79	11,30
3	406	-54,625200	-17,355500	21,1	21,5	1,89	23,98	13,65
3	603	-54,628700	-17,365400	22,4	25,0	11,6	27,19	21,38
3	707	-54,617500	-17,360600	22,6	26,5	17,26	31,17	37,95
2	203	-54,645600	-17,388200	19,1	28,0	46,59	24,67	29,20
3	403	-54,629700	-17,400300	33,1	32,0	3,32	36,21	9,40
4	509	-54,647600	-17,398300	29,6	22,1	25,34	26,52	10,37
4	608	-54,643500	-17,399400	25,1	30,4	21,12	26,80	6,77
4	709	-54,642300	-17,395200	24,0	25,7	7,08	26,65	11,05
4	903	-54,627800	-17,407300	28,3	24,0	15,19	23,31	17,61
Erro Médio						14,35	Erro Médio	13,78

Quadro 23. Resultados obtidos na estimativa do enxofre (S).

Talhão	Amostra	Longitude	Latitude	S (ppm) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	5,5	4,5	18,18	4,21	23,36
1	605	-54,665900	-17,39400	5,6	5,4	3,57	4,33	22,51
3	206	-54,666550	-17,407167	5,5	5,6	1,82	6,04	9,97
3	406	-54,661710	-17,404034	14,4	6,8	52,78	6,18	57,03
3	604	-54,653398	-17,405776	9,4	5,8	38,3	6,36	32,29
3	706	-54,654160	-17,399370	5,9	5,9	0,0	6,30	6,83
4	403	-54,647696	-17,419775	4,0	5,0	25,0	6,37	59,26
5	203	-54,630480	-17,423863	11,9	9,4	21,0	9,73	18,20
5	402	-54,625786	-17,419355	9,9	10,27	3,74	9,73	1,68
5	503	-54,628821	-17,415657	10,4	9,5	8,65	9,73	6,41
6	508	-54,682400	-17,401300	3,1	3,6	16,13	4,20	35,74
6	708	-54,679000	-17,406000	3,8	4,2	10,53	4,28	12,87
7	303	-54,654800	-17,416200	5,3	7,5	41,5	6,37	20,19
1	205	-54,653900	-17,376200	4,1	5,2	26,83	4,22	3,01
1	407	-54,649700	-17,369500	4,8	4,1	14,58	4,21	12,25
1	805	-54,635900	-17,371000	3,8	4,3	13,16	5,29	39,37
2	305	-54,654200	-17,364200	4,1	4,8	17,07	4,20	2,51
2	408	-54,653500	-17,355600	4,9	4,4	10,21	4,20	14,22
2	509	-54,651700	-17,352200	3,6	3,8	5,56	4,20	16,74
3	406	-54,625200	-17,355500	5,6	5,3	5,36	4,56	18,55
3	603	-54,628700	-17,365400	5,3	4,4	16,98	5,62	6,11
3	707	-54,617500	-17,360600	5,4	6,0	11,11	6,26	16,02
2	203	-54,645600	-17,388200	7,8	6,2	20,51	6,21	20,26
3	403	-54,629700	-17,400300	8,0	7,2	10,0	6,37	20,36
4	509	-54,647600	-17,398300	6,4	5,8	9,38	6,36	0,61
4	608	-54,643500	-17,399400	7,5	6,5	13,33	6,36	15,08
4	709	-54,642300	-17,395200	5,4	7,3	35,19	6,36	17,89
4	903	-54,627800	-17,407300	6,0	8,7	45,0	6,37	6,17
Erro Médio						17,7	Erro Médio	18,41

Quadro 24. Resultados obtidos na estimativa do zinco (Zn).

Talhão	Amostra	Longitude	Latitude	Zn (ppm) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	3,5	4,17	19,14	3,89	11,23
1	605	-54,665900	-17,39400	4,3	4,9	13,95	4,26	0,81
3	206	-54,666550	-17,407167	6,5	5,1	21,54	6,62	1,97
3	406	-54,661710	-17,404034	6,5	4,7	27,69	6,51	0,25
3	604	-54,653398	-17,405776	5,1	4,9	3,92	4,84	4,90
3	706	-54,654160	-17,399370	5,8	4,8	17,24	5,65	2,44
4	403	-54,647696	-17,419775	6,2	6,1	1,61	6,81	9,93
5	203	-54,630480	-17,423863	5,0	4,5	10,0	4,84	3,12
5	402	-54,625786	-17,419355	6,1	4,6	24,59	4,82	20,89
5	503	-54,628821	-17,415657	11,4	4,4	61,4	4,90	57,00
6	508	-54,682400	-17,401300	3,8	4,4	15,8	3,81	0,47
6	708	-54,679000	-17,406000	5,0	3,9	22,0	4,34	13,13
7	303	-54,654800	-17,416200	3,5	3,9	11,43	4,56	30,45
1	205	-54,653900	-17,376200	4,3	3,9	9,3	3,90	9,23
1	407	-54,649700	-17,369500	2,9	3,6	24,14	3,83	32,31
1	805	-54,635900	-17,371000	4,4	3,5	20,45	4,36	0,79
2	305	-54,654200	-17,364200	4,1	3,7	9,76	3,75	8,42
2	408	-54,653500	-17,355600	3,6	3,9	8,33	3,74	4,06
2	509	-54,651700	-17,352200	4,2	4,0	4,76	3,74	10,80
3	406	-54,625200	-17,355500	5,0	4,6	8,0	4,1	17,87
3	603	-54,628700	-17,365400	4,3	4,0	6,98	4,41	2,64
3	707	-54,617500	-17,360600	3,6	4,5	25,0	3,78	5,18
2	203	-54,645600	-17,388200	2,3	3,1	34,78	3,24	41,05
3	403	-54,629700	-17,400300	4,3	3,6	16,3	1,50	64,89
4	509	-54,647600	-17,398300	3,2	3,9	21,88	3,96	23,78
4	608	-54,643500	-17,399400	2,6	2,9	11,54	3,44	32,60
4	709	-54,642300	-17,395200	2,9	2,9	0,0	2,77	4,27
4	903	-54,627800	-17,407300	4,5	4,7	4,44	2,88	35,87
Erro Médio						16,28	Erro Médio	16,08

Quadro 25. Resultados obtidos na estimativa do boro (B).

Talhão	Amostra	Longitude	Latitude	B (ppm) Valor Real	Val.Estimado (Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	0,37	0,29	21,62	0,29	21,52
1	605	-54,665900	-17,39400	0,49	0,36	26,53	0,38	20,94
3	206	-54,666550	-17,407167	0,29	0,34	17,24	0,29	0,11
3	406	-54,661710	-17,404034	0,50	0,33	34,0	0,38	22,52
3	604	-54,653398	-17,405776	0,22	0,27	22,72	0,26	18,18
3	706	-54,654160	-17,399370	0,22	0,29	31,82	0,28	27,27
4	403	-54,647696	-17,419775	0,33	0,40	21,21	0,31	4,47
5	203	-54,630480	-17,423863	0,44	0,33	25,0	0,31	28,35
5	402	-54,625786	-17,419355	0,24	0,34	41,67	0,31	31,35
5	503	-54,628821	-17,415657	0,27	0,34	25,93	0,38	43,42
6	508	-54,682400	-17,401300	0,33	0,29	12,12	0,29	12,01
6	708	-54,679000	-17,406000	0,27	0,27	0,0	0,29	7,53
7	303	-54,654800	-17,416200	0,20	0,29	45,0	0,24	21,54
1	205	-54,653900	-17,376200	0,24	0,26	8,33	0,28	17,35
1	407	-54,649700	-17,369500	0,20	0,26	30,0	0,28	40,83
1	805	-54,635900	-17,371000	0,29	0,28	3,45	0,28	2,87
2	305	-54,654200	-17,364200	0,24	0,27	12,5	0,28	17,35
2	408	-54,653500	-17,355600	0,24	0,26	8,33	0,28	17,35
2	509	-54,651700	-17,352200	0,26	0,27	3,85	0,28	8,33
3	406	-54,625200	-17,355500	0,30	0,31	3,33	0,28	6,11
3	603	-54,628700	-17,365400	0,35	0,30	14,29	0,28	19,52
3	707	-54,617500	-17,360600	0,29	0,32	10,34	0,28	2,87
2	203	-54,645600	-17,388200	0,27	0,31	14,81	0,28	4,31
3	403	-54,629700	-17,400300	0,29	0,34	17,24	0,28	2,87
4	509	-54,647600	-17,398300	0,35	0,29	17,14	0,38	10,67
4	608	-54,643500	-17,399400	0,41	0,34	17,07	0,38	5,52
4	709	-54,642300	-17,395200	0,24	0,35	45,83	0,28	17,35
4	903	-54,627800	-17,407300	0,41	0,34	17,07	0,28	31,30
Erro Médio						19,6	Erro Médio	16,56

O gráfico da Figura 29 compara os erros médios obtidos pelos dois métodos, a krigagem e as RNA. Na estimativa de todas as variáveis, o método da krigagem acumulou um erro médio de 13,90 % , enquanto as RNA obtiveram erro médio de 12,48 %, diferença de 1,42 % em favor as RNA.

As redes neurais artificiais foram menos eficientes nas estimativas da saturação por bases (V), no hidrogênio (H), no cobre (Cu), e no enxofre (S), apresentando melhores resultados para todas as outras variáveis.




Figura 29. Desempenho das RNA em relação a krigagem

Observa-se no gráfico que as variáveis que apresentaram maior erro na estimativa foram: o fósforo (P), o potássio (P), o cobre (Cu), o ferro (Fe), o enxofre (S), o zinco (Zn) e o boro (B), todos com erros superiores a 15 %.

4.2. Desempenho das Redes Neurais Artificiais em relação a co-Krigagem

Na co-krigagem também se utilizou o software GS⁺ (Gamm Design Software) nas estimativas. Foram selecionadas as seguintes variáveis: determinação do silte em função da areia, argila em função da areia, SB em função do silte, CTC em função da argila, CTC em função da SB, MO em função do pH, Cu em função do Fe, S em função do B, B em função do K e Mn em função do Ca. Das 10 estimativas efetuadas não foi possível obter correlação entre a SB e o silte, o Cu e o Fe e o S e o B.

Também se utilizou redes Perceptron com uma camada escondida nesta estimativa, sendo que o número de neurônios foram:

- silte em função da areia => 14 neurônios
- argila em função da areia => 18 neurônios
- SB em função do silte => 16 neurônios
- CTC em função da argila => 20 neurônios
- CTC em função da SB => 11 neurônios
- MO em função do pH => 8 neurônios
- Cu em função do Fe => 10 neurônios
- S em função do B => 25 neurônios
- B em função do K => 21 neurônios
- Mn em função do Ca => 28 neurônios.

Os resultados obtidos, pela co-krigagem e pelas RNA, assim como o erro relativo de cada estimativa e o erro médio, estão listados nos Quadros de 26 a 35.

Quadro 26. Estimativa do silte em função da areia.

Talhão	Amostra	Longitude	Latitude	Silte (%) Valor Real	Val.Estimado (co-Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	6,6	6,93	5,00	6,82	3,40
1	605	-54,665900	-17,39400	8,4	7,71	8,21	8,21	2,14
3	206	-54,666550	-17,407167	6,7	8,40	25,37	7,42	10,77
3	406	-54,661710	-17,404034	8,4	9,82	16,90	8,28	1,38
3	604	-54,653398	-17,405776	8,3	8,45	1,80	8,07	2,68
3	706	-54,654160	-17,399370	10,0	7,40	26,00	8,35	16,45
4	403	-54,647696	-17,419775	6,6	9,13	38,33	8,57	29,91
5	203	-54,630480	-17,423863	10,0	7,98	20,20	11,06	10,67
5	402	-54,625786	-17,419355	8,3	8,23	0,84	8,38	1,04
5	503	-54,628821	-17,415657	6,7	7,45	11,19	8,18	22,11
6	508	-54,682400	-17,401300	6,6	8,46	28,18	7,96	20,61
6	708	-54,679000	-17,406000	6,7	6,72	0,29	8,17	21,99
7	303	-54,654800	-17,416200	6,7	7,66	14,33	7,68	14,76
1	205	-54,653900	-17,376200	8,3	8,46	1,93	8,04	3,06
1	407	-54,649700	-17,369500	8,4	7,68	8,57	8,71	3,73
1	805	-54,635900	-17,371000	10,0	9,17	8,30	8,70	12,97
2	305	-54,654200	-17,364200	10,0	9,11	8,90	8,79	12,02
2	408	-54,653500	-17,355600	10,0	11,07	10,70	10,24	2,40
2	509	-54,651700	-17,352200	10,0	20,27	102,70	10,23	2,33
3	406	-54,625200	-17,355500	8,3	7,97	3,97	8,14	1,93
3	603	-54,628700	-17,365400	8,3	8,34	0,48	8,57	3,31
3	707	-54,617500	-17,360600	6,6	8,29	25,60	7,75	17,45
2	203	-54,645600	-17,388200	6,7	7,42	10,74	7,12	6,27
3	403	-54,629700	-17,400300	8,3	7,18	13,49	7,70	7,20
4	509	-54,647600	-17,398300	6,6	7,90	19,69	7,90	19,84
4	608	-54,643500	-17,399400	6,7	7,82	16,71	8,11	21,03
4	709	-54,642300	-17,395200	8,3	7,38	11,08	7,51	9,51
4	903	-54,627800	-17,407300	8,3	9,53	14,81	7,91	4,62
Erro Médio						16,23	Erro Médio	10,20

Quadro 27. Estimativa da argila em função da areia.

Quadro 27. Estimativa da argila em função da área.								
Talhão	Amostra	Longitude	Latitude	Argila (%) Valor Real	Val.Estimado (co-Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	34,0	35,51	4,44	33,89	0,30
1	605	-54,665900	-17,39400	57,3	58,01	1,23	57,04	0,44
3	206	-54,666550	-17,407167	44,6	49,95	11,99	44,52	0,16
3	406	-54,661710	-17,404034	57,9	52,79	8,82	57,79	0,17
3	604	-54,653398	-17,405776	54,6	53,76	1,54	54,74	0,25
3	706	-54,654160	-17,399370	57,9	51,11	11,72	59,13	2,13
4	403	-54,647696	-17,419775	64,0	64,69	1,07	61,99	3,12
5	203	-54,630480	-17,423863	61,3	64,05	4,48	61,33	0,049
5	402	-54,625786	-17,419355	59,6	59,27	0,55	59,46	0,22
5	503	-54,628821	-17,415657	57,9	52,29	9,69	56,36	2,65
6	508	-54,682400	-17,401300	54,0	59,87	10,87	52,76	2,28
6	708	-54,679000	-17,406000	57,3	43,42	24,22	55,85	2,52
7	303	-54,654800	-17,416200	49,0	56,49	15,28	48,68	0,71
1	205	-54,653900	-17,376200	55,7	56,5	1,44	55,05	1,16
1	407	-54,649700	-17,369500	67,3	65,80	2,22	66,14	1,71
1	805	-54,635900	-17,371000	65,7	60,71	7,59	66,12	0,64
2	305	-54,654200	-17,364200	67,3	67,36	0,09	67,70	0,60
2	408	-54,653500	-17,355600	67,3	69,68	3,53	67,49	0,29
2	509	-54,651700	-17,352200	67,3	69,28	2,94	67,40	0,15
3	406	-54,625200	-17,355500	59,0	54,41	7,77	57,43	2,65
3	603	-54,628700	-17,365400	65,7	66,24	0,82	64,20	2,28
3	707	-54,617500	-17,360600	54,0	50,46	6,55	51,48	4,65
2	203	-54,645600	-17,388200	40,6	44,23	8,94	40,12	1,17
3	403	-54,629700	-17,400300	49,0	50,08	2,20	49,55	1,12
4	509	-54,647600	-17,398300	54,6	50,43	7,63	52,51	2,75
4	608	-54,643500	-17,399400	57,3	49,46	13,68	55,52	3,09
4	709	-54,642300	-17,395200	45,7	49,16	7,57	46,55	1,86
4	903	-54,627800	-17,407300	52,3	51,81	0,93	52,61	0,59
Erro Médio						6,43	Erro Médio	1,42

Quadro 28. Estimativa da SB em função do Silte.

Talhão	Amostra	Longitude	Latitude	SB(Cmolc/dm ³) Valor Real	Val.Estimado (co-Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	3,2	-	-	3,61	13,00
1	605	-54,665900	-17,39400	3,7	-	-	4,07	10,21
3	206	-54,666550	-17,407167	3,4	-	-	3,99	17,55
3	406	-54,661710	-17,404034	4,9	-	-	3,99	18,47
3	604	-54,653398	-17,405776	3,7	-	-	4,13	11,85
3	706	-54,654160	-17,399370	4,4	-	-	4,10	6,71
4	403	-54,647696	-17,419775	4,6	-	-	4,11	10,63
5	203	-54,630480	-17,423863	4,3	-	-	4,23	1,54
5	402	-54,625786	-17,419355	3,9	-	-	3,46	11,26
5	503	-54,628821	-17,415657	3,7	-	-	3,34	9,71
6	508	-54,682400	-17,401300	3,1	-	-	3,64	17,57
6	708	-54,679000	-17,406000	4,4	-	-	3,92	10,80
7	303	-54,654800	-17,416200	4,0	-	-	3,88	2,94
1	205	-54,653900	-17,376200	6,1	-	-	4,79	21,44
1	407	-54,649700	-17,369500	4,2	-	-	4,90	16,71
1	805	-54,635900	-17,371000	5,5	-	-	4,91	10,71
2	305	-54,654200	-17,364200	5,0	-	-	4,97	0,53
2	408	-54,653500	-17,355600	4,8	-	-	4,98	3,88
2	509	-54,651700	-17,352200	6,0	-	-	4,98	16,85
3	406	-54,625200	-17,355500	5,2	-	-	4,96	4,53
3	603	-54,628700	-17,365400	5,1	-	-	4,89	4,06
3	707	-54,617500	-17,360600	4,8	-	-	4,84	0,86
2	203	-54,645600	-17,388200	3,7	-	-	3,62	1,93
3	403	-54,629700	-17,400300	3,7	-	-	3,96	7,15
4	509	-54,647600	-17,398300	4,6	-	-	3,63	20,98
4	608	-54,643500	-17,399400	3,8	-	-	3,72	1,90
4	709	-54,642300	-17,395200	3,7	-	-	3,74	1,31
4	903	-54,627800	-17,407300	4,8	-	-	4,06	15,38
Erro -Médio						-	Erro Médio	9,60

Quadro 29. Estimativa da CTC em função da Argila.

Talhão	Amostra	Longitude	Latitude	CTC(Cmolc/dm³) Valor Real	Val.Estimado (co-Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	6,6	9,44	43,03	7,60	15,37
1	605	-54,665900	-17,39400	9,5	9,94	4,63	9,58	0,91
3	206	-54,666550	-17,407167	7,3	8,98	23,01	7,94	8,84
3	406	-54,661710	-17,404034	8,7	9,01	3,56	8,69	0,02
3	604	-54,653398	-17,405776	8,3	9,19	10,72	8,44	1,80
3	706	-54,654160	-17,399370	8,4	9,19	9,40	9,38	11,74
4	403	-54,647696	-17,419775	9,5	9,55	0,52	8,76	7,73
5	203	-54,630480	-17,423863	8,4	7,63	9,16	8,30	1,16
5	402	-54,625786	-17,419355	7,9	7,58	4,05	7,96	0,79
5	503	-54,628821	-17,415657	8,1	7,67	5,30	7,99	1,29
6	508	-54,682400	-17,401300	8,2	9,58	16,82	8,58	4,69
6	708	-54,679000	-17,406000	8,9	8,83	0,78	8,93	0,36
7	303	-54,654800	-17,416200	9,0	9,18	2,00	8,89	1,22
1	205	-54,653900	-17,376200	9,6	9,35	2,60	9,68	0,87
1	407	-54,649700	-17,369500	9,9	9,97	0,70	10,07	1,73
1	805	-54,635900	-17,371000	10,5	10,04	4,38	9,99	4,83
2	305	-54,654200	-17,364200	10,0	9,69	3,10	9,89	1,04
2	408	-54,653500	-17,355600	9,7	9,63	0,72	9,61	0,82
2	509	-54,651700	-17,352200	10,1	9,8	2,97	9,53	5,61
3	406	-54,625200	-17,355500	9,8	9,48	3,27	9,35	4,59
3	603	-54,628700	-17,365400	9,7	9,67	0,31	9,76	0,66
3	707	-54,617500	-17,360600	9,4	9,19	2,23	9,29	1,11
2	203	-54,645600	-17,388200	8,4	9,04	7,62	8,74	4,08
3	403	-54,629700	-17,400300	9,0	9,54	6,00	9,10	1,16
4	509	-54,647600	-17,398300	10,5	8,55	18,57	9,33	11,13
4	608	-54,643500	-17,399400	9,7	9,39	3,20	9,58	1,20
4	709	-54,642300	-17,395200	8,5	9,21	8,35	8,91	4,93
4	903	-54,627800	-17,407300	9,1	8,62	5,27	8,65	4,85
Erro Médio						7,23	Erro Médio	3,72

Quadro 30. Estimativa da CTC em função da SB.

Talhão	Amostra	Longitude	Latitude	CTC(Cmolc/dm³) Valor Real	Val.Estimado (co-Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	6,6	6,98	5,76	8,25	25,12
1	605	-54,665900	-17,39400	9,5	9,84	3,58	9,14	3,69
3	206	-54,666550	-17,407167	7,3	9,39	28,63	8,15	11,77
3	406	-54,661710	-17,404034	8,7	9,02	3,68	9,26	6,48
3	604	-54,653398	-17,405776	8,3	8,92	7,47	8,27	0,32
3	706	-54,654160	-17,399370	8,4	8,93	6,31	9,28	10,53
4	403	-54,647696	-17,419775	9,5	9,55	0,53	8,95	5,76
5	203	-54,630480	-17,423863	8,4	7,63	9,16	8,45	0,63
5	402	-54,625786	-17,419355	7,9	7,58	4,05	8,04	1,86
5	503	-54,628821	-17,415657	8,1	7,31	9,75	7,99	1,23
6	508	-54,682400	-17,401300	8,2	9,58	16,83	8,12	0,94
6	708	-54,679000	-17,406000	8,9	8,86	0,45	9,16	2,92
7	303	-54,654800	-17,416200	9,0	9,17	1,89	8,53	5,12
1	205	-54,653900	-17,376200	9,6	9,35	2,60	10,44	8,83
1	407	-54,649700	-17,369500	9,9	9,97	0,71	9,39	5,07
1	805	-54,635900	-17,371000	10,5	10,04	4,38	10,10	3,73
2	305	-54,654200	-17,364200	10,0	9,69	3,10	9,99	0,03
2	408	-54,653500	-17,355600	9,7	9,63	0,72	9,80	1,04
2	509	-54,651700	-17,352200	10,1	9,80	2,97	10,34	2,41
3	406	-54,625200	-17,355500	9,8	9,48	3,27	9,67	1,22
3	603	-54,628700	-17,365400	9,7	9,67	0,31	9,73	0,40
3	707	-54,617500	-17,360600	9,4	9,19	2,23	9,27	1,36
2	203	-54,645600	-17,388200	8,4	9,04	7,62	9,07	7,98
3	403	-54,629700	-17,400300	9,0	9,54	6,00	8,90	1,07
4	509	-54,647600	-17,398300	10,5	8,55	18,57	9,72	7,35
4	608	-54,643500	-17,399400	9,7	9,39	3,20	9,16	5,52
4	709	-54,642300	-17,395200	8,5	9,21	8,35	9,07	6,77
4	903	-54,627800	-17,407300	9,1	7,38	18,90	9,54	4,85
Erro Médio						6,47	Erro Médio	4,78

Quadro 31. Estimativa da MO em função do pH.

Talhão	Amostra	Longitude	Latitude	MO (%) Valor Real	Val.Estimado (co-Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	2,6	2,77	6,54	3,30	27,16
1	605	-54,665900	-17,39400	3,7	3,87	4,59	3,68	0,39
3	206	-54,666550	-17,407167	2,81	3,55	26,33	3,34	19,00
3	406	-54,661710	-17,404034	3,5	3,54	1,14	3,29	5,96
3	604	-54,653398	-17,405776	3,4	3,62	6,47	3,31	2,44
3	706	-54,654160	-17,399370	3,4	3,54	4,11	3,31	2,51
4	403	-54,647696	-17,419775	3,8	3,77	0,79	3,60	5,19
5	203	-54,630480	-17,423863	3,31	2,98	9,97	3,41	3,16
5	402	-54,625786	-17,419355	3,22	3,03	5,90	3,32	3,15
5	503	-54,628821	-17,415657	3,22	3,04	5,59	3,31	3,01
6	508	-54,682400	-17,401300	3,3	3,46	4,84	3,32	0,73
6	708	-54,679000	-17,406000	3,6	3,47	3,61	3,53	1,92
7	303	-54,654800	-17,416200	3,5	3,60	2,85	3,42	2,26
1	205	-54,653900	-17,376200	3,7	3,65	1,35	3,83	3,74
1	407	-54,649700	-17,369500	4,0	3,91	2,25	3,93	1,72
1	805	-54,635900	-17,371000	4,2	4,00	4,76	3,92	6,43
2	305	-54,654200	-17,364200	4,0	3,87	3,25	3,93	1,70
2	408	-54,653500	-17,355600	3,9	3,83	1,79	3,90	0,07
2	509	-54,651700	-17,352200	4,0	3,92	2,00	4,07	1,94
3	406	-54,625200	-17,355500	4,0	3,75	6,25	3,54	11,47
3	603	-54,628700	-17,365400	3,9	3,83	1,79	3,92	0,52
3	707	-54,617500	-17,360600	3,7	3,63	1,89	3,64	1,40
2	203	-54,645600	-17,388200	3,3	3,54	7,28	3,68	11,67
3	403	-54,629700	-17,400300	3,6	3,83	6,39	3,48	3,24
4	509	-54,647600	-17,398300	4,1	3,46	15,61	3,68	10,11
4	608	-54,643500	-17,399400	3,8	3,74	1,58	3,55	6,34
4	709	-54,642300	-17,395200	3,4	3,75	10,29	3,68	8,39
4	903	-54,627800	-17,407300	3,7	2,88	22,16	3,59	2,93
Erro Médio						6,12	Erro Médio	5,31

Quadro 32. Estimativa do Cu em função do Fe.

Talhão	Amostra	Longitude	Latitude	Cu (ppm) Valor Real	Val.Estimado (co-Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	1,0	-	-	1,17	17,75
1	605	-54,665900	-17,39400	1,1	-	-	1,18	1,34
3	206	-54,666550	-17,407167	0,9	-	-	1,27	36,21
3	406	-54,661710	-17,404034	1,4	-	-	1,53	2,58
3	604	-54,653398	-17,405776	1,0	-	-	1,29	17,68
3	706	-54,654160	-17,399370	1,2	-	-	1,29	29,20
4	403	-54,647696	-17,419775	1,3	-	-	1,29	23,55
5	203	-54,630480	-17,423863	1,2	-	-	1,07	2,44
5	402	-54,625786	-17,419355	1,1	-	-	1,07	7,35
5	503	-54,628821	-17,415657	1,0	-	-	1,07	43,50
6	508	-54,682400	-17,401300	0,8	-	-	1,06	18,39
6	708	-54,679000	-17,406000	1,2	-	-	1,24	13,19
7	303	-54,654800	-17,416200	1,5	-	-	1,29	0,40
1	205	-54,653900	-17,376200	1,5	-	-	0,94	27,31
1	407	-54,649700	-17,369500	1,1	-	-	0,94	21,24
1	805	-54,635900	-17,371000	1,4	-	-	0,96	3,13
2	305	-54,654200	-17,364200	1,2	-	-	0,92	3,00
2	408	-54,653500	-17,355600	1,1	-	-	0,89	0,06
2	509	-54,651700	-17,352200	1,6	-	-	0,92	7,74
3	406	-54,625200	-17,355500	1,5	-	-	0,96	19,26
3	603	-54,628700	-17,365400	1,4	-	-	0,97	7,87
3	707	-54,617500	-17,360600	1,5	-	-	0,97	2,63
2	203	-54,645600	-17,388200	1,3	-	-	0,95	6,07
3	403	-54,629700	-17,400300	1,0	-	-	0,97	30,40
4	509	-54,647600	-17,398300	1,4	-	-	0,62	24,08
4	608	-54,643500	-17,399400	1,2	-	-	0,62	3,49
4	709	-54,642300	-17,395200	1,2	-	-	0,62	24,29
4	903	-54,627800	-17,407300	1,5	-	-	0,65	34,02
Erro Médio						-	Erro Médio	15,26

Quadro 33. Estimativa do S em função do B.

Talhão	Amostra	Longitude	Latitude	S (ppm) Valor Real	Val.Estimado (co-Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	5,5	-	-	4,57	16,78
1	605	-54,665900	-17,39400	5,6	-	-	5,07	9,35
3	206	-54,666550	-17,407167	5,5	-	-	5,32	3,23
3	406	-54,661710	-17,404034	14,4	-	-	5,57	61,26
3	604	-54,653398	-17,405776	9,4	-	-	7,47	20,51
3	706	-54,654160	-17,399370	5,9	-	-	6,72	13,98
4	403	-54,647696	-17,419775	4,0	-	-	7,14	78,53
5	203	-54,630480	-17,423863	11,9	-	-	10,06	15,42
5	402	-54,625786	-17,419355	9,9	-	-	10,34	4,50
5	503	-54,628821	-17,415657	10,4	-	-	9,50	8,62
6	508	-54,682400	-17,401300	3,1	-	-	3,63	17,35
6	708	-54,679000	-17,406000	3,8	-	-	4,12	8,61
7	303	-54,654800	-17,416200	5,3	-	-	6,00	13,29
1	205	-54,653900	-17,376200	4,1	-	-	4,64	13,30
1	407	-54,649700	-17,369500	4,8	-	-	4,67	2,64
1	805	-54,635900	-17,371000	3,8	-	-	4,88	28,53
2	305	-54,654200	-17,364200	4,1	-	-	4,44	8,46
2	408	-54,653500	-17,355600	4,9	-	-	4,38	10,48
2	509	-54,651700	-17,352200	3,6	-	-	4,39	22,10
3	406	-54,625200	-17,355500	5,6	-	-	4,98	11,01
3	603	-54,628700	-17,365400	5,3	-	-	5,29	0,17
3	707	-54,617500	-17,360600	5,4	-	-	5,35	0,84
2	203	-54,645600	-17,388200	7,8	-	-	5,09	34,69
3	403	-54,629700	-17,400300	8,0	-	-	6,67	16,56
4	509	-54,647600	-17,398300	6,4	-	-	5,31	16,94
4	608	-54,643500	-17,399400	7,5	-	-	5,90	21,26
4	709	-54,642300	-17,395200	5,4	-	-	6,13	13,64
4	903	-54,627800	-17,407300	6,0	-	-	8,24	37,49
Erro Médio						-	Erro Médio	18,20

Quadro 34. Estimativa do B em função do K.

Talhão	Amostra	Longitude	Latitude	B (ppm) Valor Real	Val.Estimado (co-Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	0,37	0,34	8,11	0,39	5,4
1	605	-54,665900	-17,39400	0,49	0,44	10,20	0,45	8,16
3	206	-54,666550	-17,407167	0,29	0,28	3,45	0,23	20,68
3	406	-54,661710	-17,404034	0,5	0,29	42,00	0,45	10,00
3	604	-54,653398	-17,405776	0,22	0,28	27,27	0,25	13,63
3	706	-54,654160	-17,399370	0,22	0,29	31,82	0,28	27,27
4	403	-54,647696	-17,419775	0,33	0,34	3,03	0,31	6,06
5	203	-54,630480	-17,423863	0,44	0,37	15,91	0,28	36,36
5	402	-54,625786	-17,419355	0,24	0,32	33,33	0,30	25,00
5	503	-54,628821	-17,415657	0,27	0,32	18,52	0,34	25,92
6	508	-54,682400	-17,401300	0,33	0,29	12,12	0,25	24,24
6	708	-54,679000	-17,406000	0,27	0,30	11,11	0,26	3,70
7	303	-54,654800	-17,416200	0,2	0,19	5,00	0,16	20,00
1	205	-54,653900	-17,376200	0,24	0,24	0,00	0,25	4,16
1	407	-54,649700	-17,369500	0,20	0,28	40,00	0,29	45,00
1	805	-54,635900	-17,371000	0,29	0,29	0,00	0,22	24,13
2	305	-54,654200	-17,364200	0,24	0,25	4,17	0,26	8,33
2	408	-54,653500	-17,355600	0,24	0,25	4,17	0,26	8,33
2	509	-54,651700	-17,352200	0,26	0,26	0,00	0,25	3,84
3	406	-54,625200	-17,355500	0,30	0,35	16,67	0,31	3,33
3	603	-54,628700	-17,365400	0,35	0,32	8,57	0,27	22,85
3	707	-54,617500	-17,360600	0,29	0,40	37,93	0,29	0,00
2	203	-54,645600	-17,388200	0,27	0,32	18,52	0,30	11,11
3	403	-54,629700	-17,400300	0,29	0,30	3,45	0,29	0,00
4	509	-54,647600	-17,398300	0,35	0,31	11,43	0,31	11,42
4	608	-54,643500	-17,399400	0,41	0,30	26,83	0,30	26,82
4	709	-54,642300	-17,395200	0,24	0,29	20,83	0,29	20,83
4	903	-54,627800	-17,407300	0,41	0,25	39,02	0,30	26,82
Erro Médio						16,20	Erro Médio	15,84

Quadro 35. Estimativa do Mn em função do Ca.

Talhão	Amostra	Longitude	Latitude	Mn (ppm) Valor Real	Val.Estimado (co-Krigagem)	Erro (%)	Val.Estimado (RNA)	Erro (%)
1	306	-54,675000	-17,396100	17,1	17,66	3,27	16,25	4,94
1	605	-54,665900	-17,39400	19,9	21,46	7,84	18,46	7,19
3	206	-54,666550	-17,407167	22,7	24,60	8,37	22,06	2,80
3	406	-54,661710	-17,404034	24,0	21,48	10,50	24,48	2,01
3	604	-54,653398	-17,405776	31,2	25,59	17,98	23,97	23,15
3	706	-54,654160	-17,399370	20,5	25,35	23,66	26,42	28,88
4	403	-54,647696	-17,419775	26,5	26,57	0,26	23,42	11,58
5	203	-54,630480	-17,423863	17,8	19,97	12,19	13,82	22,34
5	402	-54,625786	-17,419355	17,0	18,10	6,47	14,90	12,29
5	503	-54,628821	-17,415657	17,7	17,15	3,10	18,08	2,19
6	508	-54,682400	-17,401300	15,6	20,90	33,97	16,08	3,12
6	708	-54,679000	-17,406000	19,3	16,85	12,69	19,24	0,30
7	303	-54,654800	-17,416200	28,9	24,41	15,54	31,65	9,54
1	205	-54,653900	-17,376200	20,4	22,84	11,96	26,91	31,94
1	407	-54,649700	-17,369500	20,6	25,42	23,39	23,52	14,21
1	805	-54,635900	-17,371000	24,4	23,29	4,55	29,12	19,36
2	305	-54,654200	-17,364200	26,4	25,87	2,00	22,50	14,75
2	408	-54,653500	-17,355600	20,5	23,43	14,29	21,57	5,25
2	509	-54,651700	-17,352200	25,7	21,39	16,77	21,48	16,40
3	406	-54,625200	-17,355500	21,1	20,53	2,70	23,43	11,07
3	603	-54,628700	-17,365400	22,4	24,36	8,75	26,87	20,42
3	707	-54,617500	-17,360600	22,6	28,29	25,18	26,56	17,53
2	203	-54,645600	-17,388200	19,1	27,44	43,66	25,10	31,43
3	403	-54,629700	-17,400300	33,1	34,85	5,29	30,71	7,19
4	509	-54,647600	-17,398300	29,6	20,85	29,56	31,14	5,21
4	608	-54,643500	-17,399400	25,1	29,51	17,57	25,88	3,12
4	709	-54,642300	-17,395200	24,0	24,96	4,00	27,29	13,74
4	903	-54,627800	-17,407300	28,3	20,97	25,90	25,63	9,41
Erro Médio						14,00	Erro Médio	12,55




Figura 30. Desempenho das RNA em relação à co-krigagem

O desempenho da co-krigagem e das RNA está ilustrado no gráfico da Figura 30. Para todas as variáveis as RNA obtiveram melhores resultados. Na estimativa de todas as variáveis, o método da co-krigagem acumulou um erro médio de 10,38 % , desconsiderando a falta de correlação entre o *SB* e o *silte*, o *Cu* e o *Fe* e o *S* e o *B*, enquanto as RNA obtiveram erro médio de 9,68 %, diferença de 0,7 % em favor as RNA.

As RNA mostraram-se mais eficientes, não somente pela pequena vantagem de 0,7 % em relação ao erro, mas pelo fato de poder generalizar aquelas variáveis que não apresentaram correlação na co-krigagem.

Os maiores erros observados, na estimativa pelas redes neurais artificiais, foram para: o cobre em função do ferro, o enxofre em função do boro, o boro em função do potássio e o magnésio em função do cálcio, todos com erros superiores a 10 %.

4. 3. Aplicação das Redes Neurais Artificiais na Estimativa dos Nutrientes e Micronutrientes em função da classe textural dos solos

Com a globalização da economia o agricultor deve levar em consideração a qualidade, o baixo custo e a tecnologia limpa para poder competir nas atividades agrícolas. Na produção agrícola os fertilizantes e corretivos correspondem aproximadamente a $\frac{1}{4}$ da planilha de gastos (segundo TOMÉ JÚNIOR, 1984), mostrando a importância das análises químicas e físicas dos solos. No Brasil são feitas aproximadamente 550 mil análises por ano.

A determinação do “custo por análise” depende de muitos fatores, tais como: reagentes utilizados, custo com pessoal, equipamentos e materiais diversos. Todas essas variáveis estão evidentemente ligadas ao número de amostras que são analisadas. Por isso, seria interessante, em função de algumas variáveis do solo, poder estimar outras que apresentam maior dificuldade de análise ou maior custo. Isso implicaria em redução de custos e economia de tempo.

Neste sentido as redes neurais mostraram-se bastante eficientes. Em função da textura do solo, que é relativamente fácil de ser determinada, estimou-se as outras variáveis, tanto macroscópica como microscópicas. Os resultados obtidos são mostrados nos Quadros de 36 a 51.

Nas estimativas abaixo utilizou-se redes Perceptron de duas camadas escondidas, pois com apenas uma camada escondida os resultados não foram satisfatórios. Os números de neurônios utilizados em cada rede estão listados abaixo, onde N_1 corresponde ao número de neurônios da primeira camada escondida e N_2 corresponde ao número de neurônios da segunda camada escondida.

- estimativa do SB $\Rightarrow N_1 = 15$ e $N_2 = 30$
- estimativa da CTC $\Rightarrow N_1 = 15$ e $N_2 = 30$
- estimativa da V $\Rightarrow N_1 = 20$ e $N_2 = 35$
- estimativa do H $\Rightarrow N_1 = 15$ e $N_2 = 30$
- estimativa da MO $\Rightarrow N_1 = 20$ e $N_2 = 35$
- estimativa do pH $\Rightarrow N_1 = 15$ e $N_2 = 30$
- estimativa do P $\Rightarrow N_1 = 25$ e $N_2 = 40$
- estimativa do K $\Rightarrow N_1 = 20$ e $N_2 = 35$
- estimativa do Ca $\Rightarrow N_1 = 20$ e $N_2 = 35$
- estimativa do Mg $\Rightarrow N_1 = 25$ e $N_2 = 40$
- estimativa do Cu $\Rightarrow N_1 = 20$ e $N_2 = 35$
- estimativa do Fe $\Rightarrow N_1 = 20$ e $N_2 = 35$
- estimativa do Mn $\Rightarrow N_1 = 25$ e $N_2 = 40$
- estimativa do S $\Rightarrow N_1 = 25$ e $N_2 = 40$
- estimativa do Zn $\Rightarrow N_1 = 15$ e $N_2 = 30$
- estimativa do B $\Rightarrow N_1 = 25$ e $N_2 = 40$

Quadro 36. Estimativa da SB em função da textura do solo.

[illegible]

Quadro 49. Estimativa do S em função da textura do solo.

Tal.	Amos.	Longitude	Latitude	Areia (%)	Silte (%)	Argila (%)	S (ppm) Real	S (ppm) RNA	Erro (%)
1	305	-54,6738	-17,3986	62,7	6,7	30,6	5,6	5,79	3,39
1	604	-54,6644	-17,3964	36	8,3	55,7	4,8	3,84	20,00
3	304	-54,6609	-17,4102	42,1	8,3	49,6	10,8	11,18	3,52
3	405	-54,66	-17,4063	35,4	8,3	56,3	7,1	5,29	25,49
3	704	-54,6509	-17,4043	38,7	8,4	52,9	5,6	5,88	5,00
4	503	-54,6452	-17,4182	25,4	10	64,6	8,5	9,3	9,41
5	205	-54,637	-17,4226	27,1	11,6	61,3	7,8	9,64	23,59
5	306	-54,6391	-17,4191	32,1	8,3	59,6	9,6	10,6	10,42
5	406	-54,6377	-17,4166	32,1	8,3	59,6	10,5	11,46	9,14
5	502	-54,626	-17,4164	33,7	8,4	57,9	11,4	11,12	2,46
5	505	-54,6342	-17,414	30,4	8,3	61,3	4,9	5,43	10,82
6	508	-54,6824	-17,4013	39,4	6,6	54	3,1	4,31	39,03
7	303	-54,6548	-17,4162	44,3	6,7	49	5,3	3,63	31,51
1	305	-54,6509	-17,3752	34,3	8,4	57,3	4,6	6,38	38,70
1	405	-54,6479	-17,3746	32,7	8,3	59	4,3	5,96	38,60
1	605	-54,6424	-17,3729	26	10	64	4,3	4,7	9,30
1	607	-54,644	-17,3672	22,7	10	67,3	3,9	2,91	25,38
1	707	-54,6413	-17,3665	24,3	8,4	67,3	5,5	6,99	27,09
2	405	-54,6514	-17,3636	26	6,7	67,3	3,8	3,85	1,32
2	408	-54,6535	-17,3556	22,7	10	67,3	4,9	5,83	18,98
2	507	-54,6503	-17,3572	19,4	11,6	69	4,1	3,78	7,80
3	704	-54,6246	-17,3654	26	10	64	5,6	7,44	32,86
1	203	-54,6534	-17,3893	39,4	6,6	54	6,4	4,68	26,88
1	303	-54,6507	-17,388	52,7	6,7	40,6	6,3	6,51	3,33
2	304	-54,6433	-17,3849	42,7	8,3	49	5,6	4,76	15,00
3	404	-54,6299	-17,3972	46	8,3	45,7	6,9	8,33	20,72
4	511	-54,6506	-17,3937	39,4	6,6	54	6,3	5,64	10,48
4	610	-54,6467	-17,3943	46	6,7	47,3	8,1	8,82	8,89
4	709	-54,6423	-17,3952	46	8,3	45,7	5,4	3,61	33,15
4	805	-54,633	-17,4036	39,4	8,3	52,3	7,1	6,52	8,17
								Erro Médio	16,79

Quadro 51. Estimativa do B em função da textura do solo.

Tal.	Amos.	Longitude	Latitude	Areia (%)	Silte (%)	Argila (%)	B (ppm) Real	B (ppm) RNA	Erro (%)
1	304	-54,6724	-17,4012	61	6,7	32,3	0,34	0,37	8,82
1	404	-54,6696	-17,3995	49,4	6,6	44	0,34	0,4	17,65
1	604	-54,6644	-17,3964	36	8,3	55,7	0,5	0,37	26,00
3	505	-54,6576	-17,4049	35,4	10	54,6	0,19	0,16	15,79
3	507	-54,6612	-17,4013	35,4	11,7	52,9	0,27	0,23	14,81
3	606	-54,6565	-17,4009	25,4	13,3	61,3	0,64	0,53	17,19
3	805	-54,6498	-17,4003	35,4	8,3	56,3	0,44	0,53	20,45
4	503	-54,6452	-17,4182	25,4	10	64,6	0,49	0,59	20,41
5	604	-54,631	-17,4123	28,7	8,4	62,9	0,82	0,8	2,44
6	605	-54,6881	-17,4084	22,7	8,3	69	0,31	0,44	41,94
8	302	-54,6756	-17,4139	32,7	10	57,3	0,16	0,05	68,75
9	203	-54,6695	-17,4121	52,7	6,7	40,6	0,2	0,31	55,00
1	404	-54,6472	-17,3773	36	8,3	55,7	0,29	0,37	27,59
1	405	-54,6479	-17,3746	32,7	8,3	59	0,22	0,2	9,09
1	407	-54,6497	-17,3695	24,3	8,4	67,3	0,2	0,23	15,00
1	704	-54,6387	-17,3744	27,7	10	62,3	0,27	0,4	48,15
1	706	-54,6403	-17,3695	22,7	8,3	69	0,26	0,3	15,38
2	504	-54,6475	-17,3652	19,4	10	70,6	0,29	0,21	27,59
3	402	-54,6344	-17,3623	22,7	8,3	69	0,27	0,22	18,52
3	408	-54,62	-17,3536	42,7	8,3	49	0,42	0,32	23,81
3	506	-54,6234	-17,3577	32,7	6,7	60,6	0,29	0,28	3,45
3	602	-54,6314	-17,3665	22,7	8,3	69	0,33	0,3	9,09
3	607	-54,6191	-17,3581	39,4	8,3	52,3	0,39	0,37	5,13
1	203	-54,6534	-17,3893	39,4	6,6	54	0,19	0,22	15,79
2	304	-54,6433	-17,3849	42,7	8,3	49	0,2	0,07	65,00
2	405	-54,6406	-17,3815	59,4	6,6	34	0,52	0,46	11,54
3	405	-54,6306	-17,3946	52,7	6,7	40,6	0,42	0,45	7,14
4	705	-54,6358	-17,4052	29,4	6,6	64	0,29	0,19	34,48
4	707	-54,6392	-17,4001	46	8,3	45,7	0,33	0,36	9,09
4	806	-54,6349	-17,4012	39,4	6,6	54	0,26	0,18	30,77
								Erro Médio	22,12

A Figura 31 ilustra os erros ocorridos na estimativa de cada variável. Estes erros são medidos em relação aos valores estimados e o conjunto de valores de referência.




Figura 31. Erros médios.

Os resultados da Figura 31 são bastante expressivos, conforme mostra a comparação feita no Quadro 52 com os valores obtidos na estima dos atributos do solo através da krigagem e das redes neurais artificiais com uma camada de neurônios. Observa-se que as RNA com duas camadas escondidas foram menos eficientes, quando comparadas com os métodos da krigagem e das RNA com uma camada escondida, somente na estimativa do boro, onde o erro ficou em torno de 22%. Os resultados obtidos para os demais atributos do solo foram significativamente melhores.

Quadro 52. Resultados obtidos na estimativa dos atributos do solo através da krigagem, RNA com uma camada de neurônios e com duas camadas de neurônios.

	Erros observados na estimativa (em %)		
	Krigagem	RNA*	RNA** (Em função da textura)
SB	12,24	9,05	2,93
CTC	7,02	6,60	1,69
V	8,96	10,00	3,40
H	10,67	10,80	2,97
MO	6,88	6,68	3,61
Ph	3,10	2,59	3,74
P	22,80	20,68	4,06
K	24,58	21,30	4,07
Ca	14,28	11,33	4,48
Mg	15,85	11,35	4,76
Cu	20,44	20,80	2,60
Fe	19,10	16,10	5,22
Mn	14,35	13,78	2,37
S	17,70	18,41	16,79
Zn	16,28	16,08	1,54
B	19,60	16,56	22,12

* Utilizou-se redes neurais artificiais com uma camada de neurônios.

** Utilizou-se redes neurais artificiais com duas camadas de neurônios.

5. CONCLUSÕES

Os resultados mostraram que as redes neurais artificiais podem realizar a estimativa das variáveis do solo para locais não amostrados com uma eficiência ligeiramente maior do que a krigagem. Essas redes podem ser implementadas com relativa facilidade em softwares como o Matlab, por exemplo, evitando a construção de semivariogramas que exigem perspicácia do operador para ser ajustado.

Em relação a co-krigagem as vantagens das RNA foram ainda maiores, uma vez que além de poder estimar com maior precisão uma variável em relação à outra, como faz a co-krigagem, mostram ser capazes de estimar aquelas grandezas que não apresentavam correlação nos métodos estatísticos.

A possibilidade de estimar as propriedades físicas e químicas em função da granulometria do solo com pequena margem de erro, como mostraram os resultados, torna as RNA uma ferramenta valiosíssima na área agrícola.

Uma prática interessante seria a utilização das RNA na quantificação das variáveis de difícil determinação por alguns anos seguidos. Possivelmente ocorreria a diminuição gradativa do número de análises de laboratório necessárias com o decorrer dos anos, devido a capacidade de aprendizado e generalização destas redes. Este fato sugere uma investigação nesse campo podendo colaborar com as práticas agrícolas realizadas no sentido de se obter melhores resultados agronômicos.

6. REFERÊNCIAS BIBLIOGRÁFICAS

BAERDEMAEKER, J. B. et al. **Mechatronic Systems**, Communication, and Control in Precision Agriculture. p. 48-70, 2001.

BALASTREIRE, L. A. **O estado da arte da Agricultura de Precisão no Brasil**- Piracicaba- SP, 224p, 2000.

BANCROFT, G. M. “**Mössbauer spectroscopy: an introduction for inorganic chemists and geochemists**”. London, McGraw Hill, 251p. 1973.

BRAGA, A. P.; et al. **Redes Neurais Artificiais** – Teoria e Aplicações. Ed. LTC – Livros Técnicos e Científicos, 2000.

CAMBARDELLA, C. E.; et al. **Field-scale variability of soil properties in**

Central Iowa soils. Soil Sci. Soc. Am. J., v.58, p. 1501 – 1510, 1994.

CREUTIN, J. D.; OBLED, C. **Objective analysis and mapping techniques for rainfalls**

fields: An objective comparison. Water Resource Res., v. 18, p. 413-431, 1982.

CYBENKO, G. **Approximation by superpositions of a sigmoid function,** *Mathematics of*

Control, Signals and Systems, vol.2, pp. 303-314, 1989.

DEMUTH, H. ; BEALE, M. **Neural Network Toolbox – For Use with Matlab.**

User's Guide, version 3, 1998.

DRUMMOND, S. ; JOSHI, A. ; SUDDUTH, K. A. **Application of Neural**

Networks: Precision Farming. 1998.

EBERHART, R.; DOBBINS, R. **Neural Networks PC Tools - A Practical Guide.**

Academic Press, San Diego, 1990.

ENGLUND, E. J.; SPARKS, A. **Geo-EAS.** Users's guide. USEMS, Las Vegas,

1988. sp.

FIETZ, C. R. ; FABRICIO, A. C.; SALTON, J. C. **Mapa de Aplicação Localizada**

de Calcário em uma Área Experimental. Artigo apresentado no trabalho de

Balastreire, L. A. O Estado da Arte da Agricultura de Precisão no Brasil. P. 165-169. 2000. Piracicaba.

FONSECA, J.S.; MARTINS, G. A. **Curso de Estatística**. 3ª edição. Editora Atlas. 286 p. 1988.

GOTWAY, C. A.; HARTFORD, A. H. **Geostatistical methods for incorporating auxiliary information in the prediction of spatial variables**. J. Agri., Biol. Environ. Statistics, v. 1, p. 17-39, 1996.

GROSSBERG, S. “**Adaptive pattern classification and universal recording: I. Parallel development and coding of neural betectors**”. Biological Cybernetics. , v.23, p.121-134, 1976a.

GROSSBERG, S. “**Adaptive pattern classification and universal recording: II. Feedback, expectation, olfaction, illusions**”. Biological Cybernetics. , v.23, p.187-202, 1976b.

GUIMARÃES, E. C. **Geoestatística Básica e Aplicada**. Universidade Federal de Uberlândia. Faculdade de Matemática. Núcleo de estudos estatísticos e Biométricos. 77 p. 2004.

HALAL, W. E. ; KULL, M. D. ; LEFFMANN, A. **The George Washington**

University Forecast of Emerging technologies. A Continuous Assessment of the technology Revolution. 1998.

HAYKIN, S. **Neural Networks** – A Comprehensive Foundation. McMillan Inc., Englenwood Cliffs, NJ, 1994.

HOPFIELD, J. J. “**Neural networks and physical systems with emergent collctive computational abilities**”. National academy of Sciences of the U.S.A., v.79. p.2554-2558, 1982.

JORGE, D. C.; COURY, D. V.; CARVALHO, A. C. **Redes neurais artificiais aplicadas a localização de faltas em linhas de transmissão de energia elétrica, IV Congresso Brasileiro de Redes Neurais**, São José dos Campos, pp. 61-66, 1999.

KILPP, A. R. “**Solução em Agricultura de Precisão**”. O estado da arte da Agricultura de Precisão no Brasil- Piracicaba- SP, p.39-70, 2000.

KOHONEN, T. “**An introduction to neural network**”. Neural Networks, v.1, no.1, p.3-16, 1988.

KOHONEN, T. **The Self-Organizing Map**. Proceedings of the IEEE, V.78, n. 9, 1990.

KRAVCHENKO, A. N.; BULLOCK, D. G. **A comparative study of interpretation methods for mapping properties**. Agron. J., v. 91, p. 393-400, 1999.

KUTZBACH, H. D. **Trends in Power and Machinery**. J. agric. Engng Res. v.76, p.237-247. 2000.

LASLETT, G. M. et al. **Comparison of several spatial prediction methods for soil pH**. J. Soil Sci., v. 38, p. 325-341, 1987.

LEITHOLD, L. **O Cálculo com Geometria Analítica**. Editora Harbra. 2ª Edição. p.760-70. 1986.

LIN, W. C. et al. “**A hierarchical multiple view approach to three-dimensional object recognition**”. IEEE Trans. On Neural Networks, v.2, p. 84-92, 1991.

MARQUES JÚNIOR, J. **Variabilidade Espacial de propriedades Químicas e Físicas de Latossolos em Áreas de Cerrado sob Cultivo de Café, em Patrocínio, MG**. Artigo apresentado no trabalho de Balastreire, L. A. O Estado da Arte da Agricultura de Precisão no Brasil. P. 165-169. 2000. Piracicaba.

McBRATNEY, A. B.; WEBSTER, R. **Choosing functions for semivariograms of soil proprieties and fitting them to sampling estimates**. Journal of Soil Science, v. 37, p.617-639, 1986.

McLELLAN, J. F. ; FRIESEN, L. **Pulsesearch Navigation Systems Inc.** Calgary, Alberta , Canada, 1997.

MINSKY, M. L. e PAPERT, S.A. ***Perceptrons: An Introduction to Computational Geometry***. The MIT Press, Cambridge, Massachusetts, 1969.

NAKASHIMA, G. Y. **Apostila do curso de Inteligência Artificial da Universidade do Sagrado Coração (USC) – Bauru.** [199-?].

NARENDRA, K. S. ; PARTHASARATHY, K. “**Identification and control of dynamical systems using neural networks**”. IEEE Trans. on Neural Networks, v.1, p.4-27, 1990.

NETO, J. F.; SODRÉ, E.; CARVALHO, M. A. Jr. **Monitoração da segurança estática do sistema sul-sudeste através da tecnologia de redes neurais. IV Congresso Brasileiro de Redes Neurais**, São José dos Campos, p. 182-87, 1999.

PACCOLA, A. A. **Transformações e neogênese de minerais em um latossolo vermelho escuro por ação antrópica de cultivo e adição química.** Botucatu, Tese (Livre Docente na área de Geologia Agrícola) Faculdade de Ciências Agronômicas-UNESP. 177 p. 1997.

PANNATIER, Y. **Variowin** – Software for spatial data analysis in 2D. New York:

Springer-Verlag, 1996. 90 p.

POKRAJAC, D. ; OBRADOVIC, Z. **Neural Network-Based Software for Fertilizer Optimization in Precision Farming**. Center for Information Science and Technology. Temple University. p. 2110-15, 2001.

RICH, E. ; KNIGHT, K. **Inteligência Artificial**. Makron Books do Brasil Editora Ltda. São Paulo. p. 560-608. 1993.

ROSENBLATT, F. **Principles of Neurodynamics and the Theory of Brain Mechanisms**. Spartan Books, Washinton, DC, 1959.

RUMELHART, D. E. ; HINTON, G. E. ; WILLIAMS, R. J. “**Learning integral representations by error propagation**”. In: Parallel Distributed Processing, vol. 1, chap. 8, Mit Press: Cambridge, Massachusetts, 1986.

SILVA, F. C. **Manual de Análises Químicas de Solos, Plantas e Fertilizantes**. Embrapa Solos, Embrapa Informática Agropecuária – Brasília. 1999. 370 p.

SMAGT, P. P. ; KROSE, B. J. A. “**A real-time learning neural robot controller**”. Proc. Of the 1991 Internacional Conference on Artificial Neural Networks, Espoo, Finland, p.351-356, 1991.

SPIEGEL, M. R. **Estatística. Editora McGraw-Hill do Brasil.** 2º Edição. 454 p. 1985.

STAFFORD, J. V. **Implementing Precision Agriculture in the 21 st Century.** *J.agric. Engng Res.* v.76, p.267-275, 2000.

SUDDUTH, K. A. et al. **Analysis of spatial factors influencing crop yield, “in proceedings 3rd Int. Conf. On Precision Agriculture**, ROBERT, et al. (ed.), Minneapolis, MN, June 23- 26, 1996.

TABIOS, G. Q.; SALAS, J. D. **A comparative analysis of techniques for spatial interpolation of precipitation.** *Water resour. Bull.*, v. 21, p. 365-380, 1985.

TOMÉ JÚNIOR, J. B. **Manual de Interpretação de Análise de Solo.** Guaíba: Agropecuária, 1997. 247p.

TORRES, F.P.; PROCHNOW, L.I. **Mapeamento de fertilidade do solo.** Artigo apresentado no trabalho de Balastreire, L. A. O Estado da Arte da Agricultura de Precisão no Brasil. P. 165-169. 2000. Piracicaba.

ULSON, J. A. C. **Desenvolvimento de um sistema de controle inteligente para aplicação de fertilizantes líquidos em taxas variáveis.** Botucatu, Tese de Doutorado. Faculdade de Ciências Agronômicas – UNESP. 149p. 2002.

UZUMAKI, E. T. **Geoestatística multivariada**: Estudo de métodos de predição. Dissertação (Estatística – Instituto de Matemática, estatística e Ciência da Computação), UNICAMP, 1994. 104p.

VAN RAIJ, et al. **Recomendações de adubação e calagem para o Estado de São Paulo**. Campinas: Instituto Agrônômico. 1985. 107 p. - Boletim Técnico, 100 –

VIEIRA, S. R. **Curso de atualização em conservação do solo – Uso de geoestatística**. Campinas, iAC, v.1, 1995.

VIEIRA, S. R. et al. **Geostatistical Theory and Application to Variability of Some Agronomical Properties**. HILGARDIA. Vol. 31, No. 3. June 1983. 75p.

VIEIRA, S. R. et al. **Mapeamento de Atributos de Solo e Planta Usando Geoestatística**. Artigo apresentado no trabalho de Balastreire, L. A. O Estado da Arte da Agricultura de Precisão no Brasil. P. 165-169. 2000. Piracicaba.

WARRICK, A. W. et al. **Direct comparisons between kriging and other interpolation – Validation of flow and transport models for the unsaturated zone**. New Mexico, 1988. p. 254-326.

WASSERMAN, P. **Neural Computing Theory and Practice**. Van Nostrand Rheinhold, New York, 1989.

WEBER, D. D., ENGLUND, E. J. **Evaluation and comparison of spatial interpolators.**

Math. Geol., v. 24, p. 381-391, 1992.

WIDROW, B. ; HOFF, M. E . “**Adaptive switching circuits**”. Proceedings of IRE

WESCON Convention Record, p. 96-104, 1960.

WINDROW, B. ; WINTER, R. G. ; BAXTER, R. A. “**Layered neural nets for**

pattern recognition”. IEEE Trans. On Acoustics, Speech, and Signal Processing,

v.36, p.1109-1117, 1988.

WOLLENHAUPT, N. C.; WOLKOWSKI, R. P.; CLAYTON, M. K. **Mapping soil test**

phosphorus and potassium for variable-rate fertilizer application. J. Prod. agric., v. 7, p.

441-448, 1994.

ZIMBACK, C. R. L. **Geoestatística.** Grupo de Estudos e Pesquisas Agrárias

Georreferenciadas. Universidade Estadual Paulista – Faculdade de Ciências

Agronômicas. Botucatu. 2003.

7. APÊNDICE

7.1. Apêndice 1

PLANILHA DE DADOS DAS PROPRIEDADES FÍSICAS E QUÍMICAS DOS SOLOS

1ª PARTE

Talhão	Amostra	Longitude	Latitude	Areia (%)	Silte (%)	Argila (%)	SB (Cmolc/dm3)	CTC //	V (%)	H (Cmolc/dm3)	MO (%)	pH (CaCl2)
1	303	-54,6704	-17,4034	52,7	6,7	40,6	3,2	8	39,4	4,9	3,2	4,9
1	304	-54,6724	-17,4012	61	6,7	32,3	2,9	7,2	40,1	4,3	2,7	4,9
1	305	-54,6738	-17,3986	62,7	6,7	30,6	3,3	7,3	45,9	3,9	2,8	5,1
1	306	-54,675	-17,3961	59,4	6,6	34	3,2	6,6	48,1	3,4	2,6	5,2
1	403	-54,6679	-17,4019	42,7	8,3	49	3,9	8,9	44	5	3,6	5
1	404	-54,6696	-17,3995	49,4	6,6	44	3,6	7,8	46,4	4,2	3,1	5,1
1	405	-54,671	-17,3971	52,7	8,3	39	3,5	8,2	43	4,7	3,3	5
1	406	-54,6727	-17,3946	56	6,7	37,3	3,4	7,6	44,5	4,2	3	5
1	503	-54,665	-17,4005	32,7	6,7	60,6	3,6	9,5	38,1	5,9	3,8	4,8
1	504	-54,6668	-17,3979	34,3	8,4	57,3	3,3	9,7	33,8	6,2	3,8	4,7
1	505	-54,6684	-17,3956	41	8,4	50,6	4	9,3	43,3	5,3	3,7	5
1	506	-54,6701	-17,393	46	6,7	47,3	4	8,8	45,5	4,8	3,6	5,1
1	603	-54,6626	-17,3991	32,7	6,7	60,6	4,3	9,7	43,9	5,4	3,9	5
1	604	-54,6644	-17,3964	36	8,3	55,7	4,4	9,7	45,4	5,3	3,9	5
1	605	-54,6659	-17,394	34,3	8,4	57,3	3,7	9,5	38,8	5,8	3,7	4,8
1	606	-54,6676	-17,3916	37,7	6,6	55,7	3,8	9,7	38,6	6	3,8	4,8
2	303	-54,6602	-17,3968	32,7	6,7	60,6	4,5	10	45,4	5,4	4	5
2	304	-54,6616	-17,3943	36	8,3	55,7	4,7	10,1	46,8	5,4	4,1	5,1
2	305	-54,6632	-17,3918	34,3	6,7	59	3,6	10,4	35	6,5	4,2	4,7

2	306	-54,6647	-17,3894	37,7	6,6	55,7	4,6	10,5	44,2	5,9	4,2	5
2	403	-54,6575	-17,3952	32,7	8,3	59	4,7	10,3	46,1	5,6	4,2	5,1
2	404	-54,659	-17,3925	42,7	8,3	49	4,1	10	41,3	5,9	4,4	4,9
2	405	-54,6607	-17,3904	39,4	6,6	54	3,6	9,8	36,6	6,1	4	4,8
2	406	-54,6622	-17,3877	42,7	8,3	49	4,8	10,4	46	5,6	4,2	5,1
2	503	-54,655	-17,3931	42,7	6,7	50,6	3,9	9	43,3	5,1	3,6	5
2	504	-54,6562	-17,3909	36	8,3	55,7	4,2	9,7	42,8	5,6	3,8	5
2	505	-54,6578	-17,3887	46	6,7	47,3	3,6	9,3	38,7	5,7	3,7	4,8
2	506	-54,6596	-17,3863	47,7	8,3	44	4,2	9	46,8	4,8	3,6	5,1
2	606	-54,6564	-17,3843	52,7	6,7	40,6	3,9	8,5	45,4	4,6	3,4	5
2	607	-54,6599	-17,3827	59,4	6,6	34	3	7	43	4	2,9	5
3	205	-54,66421	-17,410063	52,1	10	37,9	4,5	7,8	57,6	3,3	3,14	5,3
3	206	-54,66655	-17,407167	48,7	6,7	44,6	3,4	7,3	46	3,9	2,81	5,1
3	304	-54,660855	-17,410202	42,1	8,3	49,6	3,4	7,5	45	4,1	2,97	5
3	305	-54,662516	-17,408045	43,7	6,7	49,6	3,5	7,5	45,8	4,1	2,97	5
3	306	-54,664098	-17,405625	40,4	6,7	52,9	3,4	7,6	44,3	4,2	2,89	5
3	403	-54,657774	-17,411616	42,1	8,3	49,6	4,6	8,5	54,2	3,9	3,4	5,3
3	404	-54,658316	-17,409006	35,4	11,7	52,9	4,4	8,5	51,3	4,2	3,4	5,3
3	405	-54,660027	-17,406344	35,4	8,3	56,3	4,5	8,9	50,2	4,4	3,5	5,2
3	406	-54,66171	-17,404034	33,7	8,4	57,9	4,9	8,7	56,7	3,7	3,5	5,3
3	503	-54,654677	-17,40945	35,4	10	54,6	4,4	8,9	49,6	4,5	3,59	5,2
3	504	-54,655773	-17,407229	35,4	8,3	56,3	4,3	8,8	48,8	4,5	3,5	5,2
3	505	-54,657569	-17,404858	35,4	10	54,6	4,2	9	46,9	4,8	3,59	5,1
3	506	-54,659027	-17,402483	28,7	11,7	59,6	4,6	7,7	59,9	3,1	3,05	5,4
3	507	-54,66116	-17,401312	35,4	11,7	52,9	4,5	9,3	48,5	4,8	3,59	5,2
3	603	-54,651429	-17,407127	22,1	13,3	64,6	4,5	7,5	59,3	3,1	2,97	5,5
3	604	-54,653398	-17,405776	37,1	8,3	54,6	3,7	8,3	44,8	4,6	3,4	5
3	605	-54,654908	-17,403417	35,4	10	54,6	5	9,2	54,4	4,2	3,59	5,2
3	606	-54,656536	-17,400942	25,4	13,3	61,3	4,5	7,5	60,4	3	2,97	5,4
3	607	-54,65806	-17,398826	32,1	11,6	56,3	5,2	7,3	71,1	2,1	2,81	5,6
3	704	-54,650931	-17,404283	38,7	8,4	52,9	4,6	8,8	52,9	4,1	3,5	5,2
3	705	-54,652579	-17,401759	35,4	8,3	56,3	3,7	8,4	43,7	4,7	3,4	5
3	706	-54,65416	-17,39937	32,1	10	57,9	4,4	8,4	51,9	4,1	3,4	5,2
3	707	-54,655739	-17,396971	40,4	6,7	52,9	4,5	8,5	52,8	4	3,31	5,2
3	804	-54,648584	-17,402758	35,4	10	54,6	4,3	8,5	50,9	4,2	3,4	5,2
3	805	-54,649842	-17,400347	35,4	8,3	56,3	4,3	8,5	50	4,3	3,4	5,1
3	806	-54,651429	-17,397885	37,1	8,3	54,6	4,8	9,4	51,6	4,5	3,69	5,2
3	807	-54,65336	-17,395214	42,1	8,3	49,6	4,3	9,1	47,8	4,7	3,59	5,1
4	304	-54,651342	-17,419353	26	8,3	65,7	4,6	9,1	50	4,6	3,69	5,2
4	403	-54,647696	-17,419775	29,4	6,6	64	4,6	9,5	48	4,9	3,8	5,2
4	404	-54,649181	-17,41748	36	8,3	55,7	4,4	9,6	46,4	5,1	3,8	5,1
4	405	-54,650911	-17,414349	36	6,7	57,3	4,6	9,7	47,2	5,1	3,8	5,2
4	406	-54,652907	-17,412165	36	8,3	55,7	4,4	9,4	47,1	5	3,69	5,1
4	502	-54,644921	-17,42089	25,4	11,7	62,9	4,9	8,4	58,1	3,5	3,4	5,5
4	503	-54,645239	-17,418196	25,4	10	64,6	4	7,6	52,5	3,6	2,97	5,5
4	504	-54,646892	-17,41583	26	10	64	5,5	9,6	57,2	4,1	3,8	5,4
4	505	-54,648545	-17,413464	31	8,4	60,6	4,8	9,5	50,4	4,7	3,69	5,2

4	506	-54,650198	-17,411098	33,7	8,4	57,9	4,4	8,6	50,9	4,2	3,4	5,4
4	603	-54,64243	-17,417093	32,1	8,3	59,6	3,5	8	43,3	4,5	3,22	5
4	604	-54,644412	-17,414253	22,7	8,3	69	4,3	9	48,1	4,6	3,59	5,1
4	605	-54,646065	-17,411887	28,7	10	61,3	4,4	7,2	60,4	2,9	2,89	5,4
4	606	-54,647718	-17,409521	24,3	8,4	67,3	4,1	9,2	45,2	5	3,69	5,1
4	607	-54,649981	-17,408028	28,7	8,4	62,9	3,9	8	48,6	4,1	3,14	5,3
4	703	-54,640279	-17,415042	25,4	10	64,6	4,1	7,2	57,4	3,1	2,81	5,5
4	704	-54,641932	-17,412676	25,4	11,7	62,9	4,4	7,8	56,2	3,4	3,05	5,5
4	705	-54,643585	-17,41031	24,3	8,4	67,3	3,9	9	44	5	3,59	5
4	706	-54,645238	-17,407944	26	8,3	65,7	4,1	9,4	43,8	5,3	3,69	5
4	707	-54,646891	-17,405578	29,4	6,6	64	4,5	9,1	49,5	4,6	3,59	5,2
5	203	-54,63048	-17,423863	28,7	10	61,3	4,3	8,4	50,7	4,2	3,31	5,2
5	204	-54,634016	-17,423177	25,4	11,7	62,9	5,2	9,2	56,6	4	3,69	5,3
5	205	-54,636955	-17,422623	27,1	11,6	61,3	4,8	8,7	54,9	3,9	3,5	5,3
5	206	-54,639803	-17,421834	28,7	8,4	62,9	4,6	8,4	54,6	3,8	3,4	5,2
5	207	-54,64192	-17,42116	28,7	10	61,3	4,2	8,1	51,6	3,9	3,31	5,2
5	302	-54,626758	-17,422001	28,7	6,7	64,6	3,4	8,3	40,5	5	3,31	4,9
5	303	-54,630265	-17,42116	27,1	8,3	64,6	3	7,8	38	4,8	3,05	4,8
5	304	-54,633078	-17,420475	28,7	6,7	64,6	3,6	8,3	43,4	4,7	3,31	5
5	305	-54,636171	-17,419792	30,4	8,3	61,3	4,3	8,5	50,4	4,2	3,4	5,2
5	306	-54,639108	-17,419087	32,1	8,3	59,6	3,8	7,9	47,8	4,1	3,14	5,1
5	402	-54,625786	-17,419355	32,1	8,3	59,6	3,9	7,9	49,2	4	3,22	5,2
5	403	-54,629601	-17,418394	35,4	6,7	57,9	3	7,7	38,3	4,8	3,05	4,8
5	404	-54,632592	-17,417729	30,4	6,7	62,9	3,5	7,5	46,3	4	2,97	5,2
5	405	-54,635499	-17,416923	28,7	8,4	62,9	3,3	8	41,4	4,7	3,22	5
5	406	-54,637683	-17,416565	32,1	8,3	59,6	3,8	7,9	48,4	4,1	3,22	5,2
5	502	-54,626012	-17,416438	33,7	8,4	57,9	3,8	7,7	48,6	4	3,05	5,2
5	503	-54,628821	-17,415657	35,4	6,7	57,9	3,7	8,1	45,2	4,4	3,22	5,1
5	504	-54,631683	-17,415064	32,1	6,6	61,3	3,6	7,6	47,1	4	2,97	5,2
5	505	-54,634205	-17,413975	30,4	8,3	61,3	3,5	7,8	44,5	4,4	3,05	5
5	602	-54,625853	-17,413799	32,1	8,3	59,6	3,1	7,2	42,3	4,2	2,89	5
5	603	-54,628227	-17,41287	37,1	8,3	54,6	3,1	7,3	42,1	4,2	2,89	5
5	604	-54,631037	-17,41226	28,7	8,4	62,9	3,6	7,6	47	4,1	2,97	5,2
5	703	-54,627334	-17,410182	32,1	10	57,9	2,9	6,9	41,4	4,1	2,66	4,9
6	503	-54,6956	-17,4091	21	8,4	70,6	3,9	9,3	41,8	5,4	3,7	5
6	504	-54,6923	-17,4076	14,3	6,7	79	4,3	9,7	44	5,4	3,9	5
6	505	-54,6897	-17,4061	17,7	8,3	74	4,8	9,7	49,3	4,9	3,9	5,2
6	506	-54,6874	-17,4045	19,4	11,6	69	4,4	9,5	46,5	5,1	3,8	5,1
6	507	-54,6848	-17,4029	22,7	10	67,3	2,7	9	29,8	6,1	3,6	4,5
6	508	-54,6824	-17,4013	39,4	6,6	54	3,1	8,2	38	5,1	3,3	4,8
6	509	-54,68	-17,3997	57,7	6,6	35,7	3,3	7,1	46,2	3,8	2,8	5,1
6	604	-54,6906	-17,41	21	8,4	70,6	3,8	9,6	39,9	5,7	3,8	4,9
6	605	-54,6881	-17,4084	22,7	8,3	69	3,8	9,6	39,6	5,8	3,8	4,9
6	606	-54,6856	-17,4068	22,7	8,3	69	4,5	9,5	46,8	5,1	3,7	5,1
6	607	-54,6831	-17,4053	27,7	8,3	64	3,4	8,9	38,2	5,5	3,5	4,8
6	608	-54,6806	-17,4037	39,4	8,3	52,3	6,5	9,4	69	2,9	3,6	5,6
6	609	-54,6781	-17,4021	56	6,7	37,3	3,1	7,1	43,1	4,1	2,7	5

6	705	-54,6865	-17,4108	22,7	10	67,3	5,1	10,1	50,1	5,1	4,1	5,2
6	706	-54,684	-17,4092	19,4	10	70,6	4,6	9,8	47	5,2	4	5,1
6	707	-54,6816	-17,4076	31	8,4	60,6	4	9	44,5	5	3,6	5
6	708	-54,679	-17,406	36	6,7	57,3	4,4	8,9	48,9	4,6	3,6	5,2
6	709	-54,6765	-17,4045	47,7	6,6	45,7	2,9	7,4	39,3	4,5	2,9	4,9
6	806	-54,6824	-17,4116	19,4	8,3	72,3	4,9	10	49,1	5,1	4	5,2
6	807	-54,6799	-17,41	27,7	8,3	64	4,3	9	48	4,7	3,6	5,1
6	808	-54,6773	-17,4084	36	6,7	57,3	4,6	9,1	50,4	4,5	3,6	5,2
6	809	-54,6754	-17,4068	44,3	8,4	47,3	3,9	8,3	47,8	4,3	3,4	5,1
6	907	-54,679	-17,4128	27,7	6,6	65,7	4,9	9,6	50,9	4,7	3,8	5,2
6	908	-54,6757	-17,4107	42,7	6,7	50,6	5	9,8	50,6	4,8	3,9	5,1
7	202	-54,6543	-17,4183	36	6,7	57,3	3,5	9,3	38,1	5,7	3,6	4,8
7	203	-54,6571	-17,4177	39,4	6,6	54	3,8	9,2	41,9	5,3	3,6	4,9
7	204	-54,66	-17,417	46	8,3	45,7	4,6	9,5	48,9	4,8	3,7	5,1
7	205	-54,6634	-17,4161	46	6,7	47,3	4,8	9,1	52,8	4,3	3,5	5,2
7	303	-54,6548	-17,4162	44,3	6,7	49	4	9	44,7	5	3,5	5
7	305	-54,6613	-17,4143	52,7	6,7	40,6	4,1	8,4	49,3	4,2	3,4	5,2
8	302	-54,6756	-17,4139	32,7	10	57,3	4,5	9,4	48,5	4,8	3,7	5,1
8	303	-54,6736	-17,4121	42,7	8,3	49	5,3	10	52,7	4,7	4	5,2
9	202	-54,6721	-17,4143	36	8,3	55,7	5,6	10,3	54,3	4,7	4	5,2
9	203	-54,6695	-17,4121	52,7	6,7	40,6	3,2	8,2	38,6	5,1	3,3	4,8
9	302	-54,6696	-17,4156	47,7	8,3	44	5,3	10,4	50,4	5,2	4	5,2
9	303	-54,6675	-17,4141	47,7	8,3	44	3,5	8,6	41	5,1	3,4	4,9
1	203	-54,6521	-17,3815	59,4	6,6	34	3,2	7,8	41,5	4,5	3,1	4,9
1	204	-54,653	-17,3789	44,3	8,4	47,3	4	9	44,8	5	3,5	5
1	205	-54,6539	-17,3762	36	8,3	55,7	6,1	9,6	63,9	3,5	3,7	5,4
1	206	-54,6547	-17,3732	32,7	8,3	59	5,5	9,6	56,8	4,2	3,7	5,3
1	303	-54,6492	-17,381	52,7	8,3	39	3,4	8,6	40,2	5,1	3,3	4,9
1	304	-54,6501	-17,3779	42,7	6,7	50,6	5,6	9,7	57,2	4,2	3,8	5,3
1	305	-54,6509	-17,3752	34,3	8,4	57,3	4,8	9,6	50,3	4,8	3,8	5,2
1	306	-54,6519	-17,372	24,3	8,4	67,3	4,8	9,5	50,6	4,7	3,8	5,2
1	403	-54,6464	-17,3797	49,4	8,3	42,3	3,8	8,9	43,3	5	3,5	5
1	404	-54,6472	-17,3773	36	8,3	55,7	5,8	9,7	59,5	3,9	3,9	5,3
1	405	-54,6479	-17,3746	32,7	8,3	59	5,1	9,9	51	4,9	4	5,2
1	406	-54,6489	-17,3716	26	8,3	65,7	4,6	10,8	42,6	6,2	4,2	5
1	407	-54,6497	-17,3695	24,3	8,4	67,3	4,2	9,9	42,8	5,7	4	5
1	504	-54,6444	-17,3769	39,4	8,3	52,3	5,6	9,4	59,3	3,8	3,6	5,3
1	505	-54,6452	-17,3737	32,7	6,7	60,6	4,4	9,8	44,5	5,4	3,9	5
1	506	-54,646	-17,3711	29,4	6,6	64	4,2	9,8	42,7	5,6	4	5
1	507	-54,6469	-17,3682	22,7	8,3	69	3,9	9,5	41,1	5,6	3,6	4,9
1	604	-54,6414	-17,3756	34,3	8,4	57,3	4,9	9,2	53,9	4,2	3,6	5,2
1	605	-54,6424	-17,3729	26	10	64	4,3	9,8	44	5,5	4	5
1	606	-54,6432	-17,3701	22,7	8,3	69	4,5	9,5	46,8	5,1	3,8	5,1
1	607	-54,644	-17,3672	22,7	10	67,3	4,5	9,6	47,1	5,1	3,8	5,1
1	704	-54,6387	-17,3744	27,7	10	62,3	5,1	9,4	53,5	4,4	3,7	5,4
1	705	-54,6394	-17,3721	26	8,3	65,7	4,4	9,8	44,7	5,4	4	5
1	706	-54,6403	-17,3695	22,7	8,3	69	4,2	9,5	44,6	5,3	3,8	5,1

1	707	-54,6413	-17,3665	24,3	8,4	67,3	4,8	10	48,2	5,2	4	5,2
1	708	-54,6418	-17,3645	19,4	8,3	72,3	5,2	10,1	51,5	4,9	4	5,2
1	804	-54,6352	-17,3733	27,7	10	62,3	5,4	10,2	53,2	4,8	4,1	5,3
1	805	-54,6359	-17,371	24,3	10	65,7	5,5	10,5	52,2	5	4,2	5,3
1	806	-54,6367	-17,3683	24,3	8,4	67,3	5,2	10,4	50,2	5,2	4,1	5,2
1	807	-54,6385	-17,3656	26	8,3	65,7	5,6	10,6	52,4	5,1	4,2	5,3
2	203	-54,6555	-17,3705	32,7	8,3	59	7,2	10,7	68	3,4	4,2	5,9
2	204	-54,6559	-17,368	27,7	10	62,3	5,9	10,6	55,9	4,7	4,1	5,4
2	205	-54,6569	-17,3652	22,7	10	67,3	6,1	10,4	58,7	4,3	4	5,4
2	206	-54,6579	-17,3626	26	8,3	65,7	5	9,7	51,5	4,7	3,9	5,3
2	304	-54,653	-17,3677	26	10	64	4,6	10	45,8	5,4	4	5,1
2	305	-54,6542	-17,3642	22,7	10	67,3	5	10	49,6	5,1	4	5,2
2	306	-54,655	-17,3616	22,7	10	67,3	4,7	9,7	48,8	4,9	3,9	5,2
2	307	-54,6557	-17,3591	26	8,3	65,7	5	9,5	52,9	4,5	3,8	5,3
2	404	-54,6503	-17,3666	26	6,7	67,3	4,1	9,6	43,2	5,4	3,8	5
2	405	-54,6514	-17,3636	26	6,7	67,3	5	9,9	50,7	4,9	4	5,2
2	406	-54,6523	-17,3609	19,4	10	70,6	4,9	9,8	50,3	4,9	4	5,2
2	407	-54,653	-17,3582	19,4	11,6	69	4,9	9,6	51	4,7	3,8	5,2
2	408	-54,6535	-17,3556	22,7	10	67,3	4,8	9,7	49,2	4,9	3,9	5,2
2	504	-54,6475	-17,3652	19,4	10	70,6	4,5	9,8	45,7	5,3	3,9	5,1
2	505	-54,6486	-17,3627	19,4	10	70,6	4,8	10	47,6	5,3	4	5,2
2	506	-54,6492	-17,3598	19,4	8,3	72,3	5,2	9,9	52,7	4,7	3,9	5,2
2	507	-54,6503	-17,3572	19,4	11,6	69	4,8	9,8	49,4	4,9	3,9	5,3
2	508	-54,6513	-17,3544	22,7	10	67,3	4,7	9,8	47,6	5,1	3,9	5,1
2	509	-54,6517	-17,3522	22,7	10	67,3	6	10,1	59,2	4,1	4	5,7
2	604	-54,6449	-17,3643	22,7	10	67,3	5	9,9	50,5	4,9	4	5,4
2	605	-54,6456	-17,3619	22,7	10	67,3	4,9	10	49,3	5,1	4,1	5,2
2	606	-54,6465	-17,3592	19,4	10	70,6	4,4	9,7	45,6	5,3	3,8	5,1
2	607	-54,6474	-17,3565	22,7	8,3	69	4,2	9,5	43,7	5,4	3,8	5
2	608	-54,6486	-17,354	19,4	8,3	72,3	5,6	10,3	54,5	4,7	4	5,4
2	705	-54,6425	-17,3615	22,7	6,7	70,6	4,5	9,6	47,3	5,1	3,9	5,2
2	706	-54,6436	-17,3581	21	8,4	70,6	4,7	9,6	49,3	4,9	3,8	5,3
2	804	-54,6379	-17,3624	22,7	6,7	70,6	5,1	10	51,5	4,8	3,9	5,2
2	805	-54,6403	-17,3602	19,4	8,3	72,3	4,7	9,8	48,3	5,1	4	5,1
3	402	-54,6344	-17,3623	22,7	8,3	69	5,7	10,6	54,2	4,8	4	5,3
3	403	-54,6323	-17,3605	19,4	10	70,6	4,9	10	48,4	5,2	3,9	5,1
3	404	-54,6298	-17,3588	19,4	8,3	72,3	4,8	9,9	48,4	5,1	4	5,1
3	405	-54,6275	-17,3572	29,4	8,3	6,2	4,7	9,3	50,8	4,6	3,7	5,3
3	406	-54,6252	-17,3555	32,7	8,3	59	5,2	9,8	52,4	4,7	4	5,3
3	407	-54,6229	-17,3537	39,4	8,3	52,3	4,4	8,7	51	4,2	3,5	5,3
3	408	-54,62	-17,3536	42,7	8,3	49	4,7	8,7	54,4	4	3,5	5,4
3	502	-54,6334	-17,3647	19,4	10	70,6	6	10,1	59,4	4,1	4	5,4
3	503	-54,6305	-17,3629	21	8,4	70,6	5,8	10,3	56,2	4,5	4,1	5,3
3	504	-54,6282	-17,3611	26	8,3	65,7	4,9	9,4	52,3	4,5	3,7	5,2
3	505	-54,6256	-17,3595	29,4	8,3	62,3	4,6	9,6	47,4	5,1	3,8	5,1
3	506	-54,6234	-17,3577	32,7	6,7	60,6	4,3	9,2	46,1	5	3,7	5,1
3	507	-54,6208	-17,3558	42,7	8,3	49	5,1	8,9	56,9	3,8	3,5	5,3

3	602	-54,6314	-17,3665	22,7	8,3	69	5,1	9,8	52	4,7	3,9	5,2
3	603	-54,6287	-17,3654	26	8,3	65,7	5,1	9,7	52,6	4,6	3,9	5,2
3	604	-54,6263	-17,3635	29,4	8,3	62,3	4,5	9,1	49,9	4,5	3,6	5,2
3	605	-54,6241	-17,3619	29,4	6,6	64	5,3	10	53	4,7	3,9	5,3
3	606	-54,6214	-17,3601	32,7	8,3	59	5,2	8,8	58,9	3,6	3,5	5,4
3	607	-54,6191	-17,3581	39,4	8,3	52,3	5	9,4	53,2	4,4	3,7	5,2
3	704	-54,6246	-17,3654	26	10	64	4,8	10,1	47,9	5,3	3,9	5,2
3	705	-54,6221	-17,3643	31	8,4	60,6	4,7	9,5	50	4,7	3,8	5,2
3	706	-54,6196	-17,3625	39,4	8,3	52,3	4,8	9,1	52,2	4,3	3,7	5,3
3	707	-54,6175	-17,3606	39,4	6,6	54	4,8	9,4	50,8	4,6	3,7	5,3
1	202	-54,6519	-17,3914	39,4	6,6	54	3,4	9	37,2	5,7	3,6	4,8
1	203	-54,6534	-17,3893	39,4	6,6	54	2,5	8,5	29	5,8	3,4	4,6
1	204	-54,6547	-17,387	49,4	4,9	45,7	2,6	8,3	30,9	5,5	3,3	4,6
1	302	-54,6491	-17,3906	42,7	6,7	50,6	1,9	8,2	22,6	5,9	3,3	4,4
1	303	-54,6507	-17,388	52,7	6,7	40,6	2,9	8,4	34,1	5,4	3,3	4,7
1	304	-54,6524	-17,386	57,7	6,6	35,7	3,3	8,3	39,4	5,1	3,3	4,9
1	402	-54,6478	-17,3899	46	8,3	45,7	3,4	8,3	41,4	4,9	3,4	4,9
2	203	-54,6456	-17,3882	52,7	6,7	40,6	3,7	8,4	44,3	4,7	3,3	5
2	204	-54,6468	-17,3855	52,7	8,3	39	2,9	8,1	35,5	5,1	3,2	4,7
2	205	-54,6465	-17,3833	59,4	6,6	34	2,5	8,2	30	5,5	3,2	4,6
2	302	-54,6418	-17,3909	49,4	6,6	44	3,7	8,9	42,1	5,1	3,8	5
2	303	-54,6428	-17,3876	42,7	6,7	50,6	4,7	9,4	49,9	4,7	3,7	5,2
2	304	-54,6433	-17,3849	42,7	8,3	49	4,8	9,1	53,4	4,2	3,7	5,2
2	305	-54,644	-17,3821	52,7	6,7	40,6	6	10,9	55	4,9	4,2	5,3
2	401	-54,6388	-17,3917	41	8,4	50,6	3,5	9,4	37,5	5,9	3,6	4,8
2	403	-54,6398	-17,3871	41	8,4	50,6	5,2	10,4	50,4	5,1	4	5,2
2	404	-54,6404	-17,3843	42,7	8,3	49	5	10,1	49,7	5,1	4	5,1
2	405	-54,6406	-17,3815	59,4	6,6	34	6,2	10,5	59,1	4,3	4,2	5,3
3	304	-54,6327	-17,3979	47,7	8,3	44	2,8	8,6	32,3	5,6	3,4	4,7
3	305	-54,6333	-17,395	44,3	8,4	47,3	3,3	8,9	36,8	5,4	3,5	4,8
3	402	-54,6281	-17,4028	47,7	8,3	44	4,5	9,9	45,1	5,4	4	5,1
3	403	-54,6297	-17,4003	42,7	8,3	49	3,7	9	41,1	5,3	3,6	4,9
3	404	-54,6299	-17,3972	46	8,3	45,7	3,9	9,7	39,8	5,9	3,9	4,9
3	405	-54,6306	-17,3946	52,7	6,7	40,6	3,6	9,2	38,6	5,7	3,7	4,8
3	205	-54,6363	-17,3951	52,7	6,7	40,6	2,5	8,6	29,5	5,8	3,4	4,6
4	503	-54,6381	-17,4133	26	8,3	65,7	4	9,7	41	5,7	3,8	4,9
4	504	-54,6396	-17,4108	29,4	6,6	64	4,3	9,7	43,9	5,4	3,9	5
4	505	-54,641	-17,4083	31	10	59	4	10,1	39,8	6,1	4	4,9
4	506	-54,643	-17,4059	32,7	10	57,3	4,2	9,8	42,6	5,6	3,9	5
4	507	-54,6444	-17,4033	36	6,7	57,3	4,5	9,9	45,3	5,4	4	5,1
4	508	-54,6461	-17,4009	34,3	8,4	57,3	4,1	9,5	42,9	5,4	3,8	5
4	509	-54,6476	-17,3983	39,4	6,6	54	4,6	10,5	44	5,9	4,1	5
4	510	-54,6493	-17,3961	39,4	8,3	52,3	3,9	9	43,5	5,1	3,7	5
4	511	-54,6506	-17,3937	39,4	6,6	54	4	9,1	44	5,1	3,7	5
4	603	-54,6353	-17,4114	26	8,3	65,7	4,1	8,6	48,1	4,5	3,4	5,2
4	604	-54,6369	-17,4089	29,4	8,3	62,3	3,9	9,1	43	5,2	3,6	5
4	605	-54,6384	-17,4069	29,4	6,6	64	2,6	9,5	27,5	6,6	3,8	4,5

4	606	-54,6401	-17,4042	27,7	8,3	64	4,6	9,5	48,4	4,9	3,8	5,2
4	607	-54,6417	-17,4018	36	8,3	55,7	4,2	9,5	44,6	5,3	3,7	5
4	608	-54,6435	-17,3994	36	6,7	57,3	3,8	9,7	38,8	5,9	3,8	4,8
4	609	-54,6448	-17,3969	39,4	8,3	52,3	4	9,7	41,7	5,7	3,8	4,9
4	610	-54,6467	-17,3943	46	6,7	47,3	3,3	9,2	35,5	5,7	3,7	4,7
4	703	-54,6329	-17,41	32,7	8,3	59	3,9	8,6	45	4,7	3,4	5,1
4	704	-54,6344	-17,4075	29,4	8,3	62,3	5,6	9,9	56,5	4,3	4	5,4
4	705	-54,6358	-17,4052	29,4	6,6	64	4,1	9,8	41,7	5,7	4	4,9
4	706	-54,6375	-17,4027	36	8,3	55,7	4,1	9,1	45	5	3,7	5,1
4	707	-54,6392	-17,4001	46	8,3	45,7	3,7	9,4	39,9	5,6	3,7	4,9
4	708	-54,6407	-17,3977	41	8,4	50,6	3,5	8,8	39,6	5,3	3,6	4,9
4	709	-54,6423	-17,3952	46	8,3	45,7	3,7	8,5	43,3	4,8	3,4	5
4	710	-54,6445	-17,3934	47,7	8,3	44	2,9	8,4	34,6	5,3	3,3	4,7
4	803	-54,63	-17,4086	32,7	6,7	60,6	3,8	8	48	4,2	3,2	5,1
4	804	-54,6317	-17,4061	26	8,3	65,7	4	9,2	43,6	5,2	3,6	5
4	805	-54,633	-17,4036	39,4	8,3	52,3	5,1	9,7	52,5	4,6	3,8	5,2
4	806	-54,6349	-17,4012	39,4	6,6	54	4,1	9	45,6	4,9	3,6	5,1
4	807	-54,637	-17,3991	46	6,7	47,3	3,7	8,5	43,4	4,8	3,4	5
4	808	-54,6388	-17,3965	46	6,7	47,3	2,9	8,1	36,3	4,9	3,3	4,8
4	903	-54,6278	-17,4073	39,4	8,3	52,3	4,8	9,1	53,3	4,2	3,7	5,3
4	904	-54,6295	-17,4048	39,4	8,3	52,3	4,5	9,5	47,3	5	3,8	5,2

PLANILHA DE DADOS DAS PROPRIEDADES FÍSICAS E QUÍMICAS DOS SOLOS

2ª PARTE

Tal.	Amos.	Longitude	Latitude	P (ppm)	K (ppm)	Ca (Cmolc/dm ³)	Mg //	Cu (ppm)	Fe (ppm)	Mn (ppm)	S (ppm)	Zn (ppm)	B (ppm)
1	303	-54,6704	-17,4034	14	67	2,1	0,9	1	112	20,5	6	4,1	0,39
1	304	-54,6724	-17,4012	20	70	1,9	0,8	1,2	113	17,2	5,8	5,1	0,34
1	305	-54,6738	-17,3986	18	56	2,2	1	1,1	124	17,6	5,6	4,1	0,37
1	306	-54,675	-17,3961	12	63	2	1	1	118	17,1	5,5	3,5	0,37
1	403	-54,6679	-17,4019	14	87	2,6	1,1	1,1	110	16,8	6	6,1	0,42
1	404	-54,6696	-17,3995	12	79	2,4	1	1,1	121	16,6	5,6	4,4	0,34
1	405	-54,671	-17,3971	11	52	2,4	1	0,8	120	17,3	4,5	4	0,45
1	406	-54,6727	-17,3946	12	63	2,3	0,9	0,9	114	26,6	3,6	4	0,39
1	503	-54,665	-17,4005	13	80	2,4	1	0,9	89	20,3	4,8	4,7	0,39
1	504	-54,6668	-17,3979	14	115	2,1	0,9	1	104	20,5	5,6	4,5	0,37
1	505	-54,6684	-17,3956	13	78	2,7	1,1	1,1	112	22,1	4,8	4,6	0,39
1	506	-54,6701	-17,393	13	78	2,7	1,1	0,9	108	20,4	4,5	4,2	0,42
1	603	-54,6626	-17,3991	10	98	2,8	1,2	1,1	86	17,1	3,6	5	0,52
1	604	-54,6644	-17,3964	16	113	2,9	1,2	1,1	101	18,5	4,8	5	0,5
1	605	-54,6659	-17,394	13	109	2,3	1,1	1,2	151	19,9	5,6	4,3	0,49

1	606	-54,6676	-17,3916	15	97	2,4	1,1	1,2	133	21,3	5,8	4,7	0,46
2	303	-54,6602	-17,3968	12	82	3	1,3	1,1	107	20,5	4,6	5,9	0,41
2	304	-54,6616	-17,3943	14	86	3,1	1,4	1	116	25,3	4,4	5,4	0,41
2	305	-54,6632	-17,3918	14	88	2,3	1,1	1,2	109	20,9	4,4	4,2	0,45
2	306	-54,6647	-17,3894	14	88	3,1	1,3	1,2	104	27,8	4,8	5,2	0,56
2	403	-54,6575	-17,3952	13	94	3,2	1,3	0,9	84	20,2	4,9	5,8	0,39
2	404	-54,659	-17,3925	14	95	2,8	1,1	2,4	97	20,2	3,5	6,1	0,33
2	405	-54,6607	-17,3904	12	74	2,4	1	1,2	86	19,9	4	4,4	0,41
2	406	-54,6622	-17,3877	9	63	3,2	1,4	1,1	89	34	4,3	4,9	0,34
2	503	-54,655	-17,3931	10	73	2,6	1,1	1,3	98	22	4,5	5,1	0,39
2	504	-54,6562	-17,3909	11	100	2,7	1,2	1,4	101	24,1	3,9	5,6	0,35
2	505	-54,6578	-17,3887	14	77	2,4	1	1,4	103	25,5	3,9	5,4	0,34
2	506	-54,6596	-17,3863	13	73	2,8	1,2	1,5	104	33,5	4,8	5,9	0,33
2	606	-54,6564	-17,3843	11	66	2,6	1,1	2,3	104	26,8	4,3	9,2	0,37
2	607	-54,6599	-17,3827	10	48	2	0,9	1,3	89	22	4	4,4	0,27
3	205	-54,66421	-17,410063	6,8	68	3,1	1,2	1,9	84	35,8	3,8	5,7	0,2
3	206	-54,66655	-17,407167	6,4	60	2,3	0,9	2	105	22,7	5,5	6,5	0,29
3	304	-54,660855	-17,410202	5,8	67	2,3	0,9	1,6	88	27,4	10,8	4,3	0,22
3	305	-54,662516	-17,408045	7,5	61	2,4	0,9	1,4	89	24,6	7	4,4	0,18
3	306	-54,664098	-17,405625	6,4	66	2,3	0,9	1,5	89	21,4	8,8	5	0,19
3	403	-54,657774	-17,411616	8,2	122	3,1	1,2	2,3	262	40,3	12,6	6,3	0,54
3	404	-54,658316	-17,409006	8,6	147	2,8	1,2	2,1	240	37,5	11,5	6,6	0,64
3	405	-54,660027	-17,406344	9	138	2,9	1,2	1,6	159	29,6	7,1	5,4	0,41
3	406	-54,66171	-17,404034	9	120	3,2	1,4	1,5	241	24	14,4	6,5	0,5
3	503	-54,654677	-17,40945	7,2	87	3	1,2	1,5	89	27,8	11,9	4,7	0,23
3	504	-54,655773	-17,407229	5,4	75	3	1,1	1,3	72	24,3	8	4,1	0,22
3	505	-54,657569	-17,404858	7,9	51	2,9	1,2	1,6	89	25	5,9	5	0,19
3	506	-54,659027	-17,402483	5,8	71	3,2	1,2	1,4	251	29,8	4,5	6	0,54
3	507	-54,66116	-17,401312	7,5	48	3,1	1,3	1,5	113	19	7,3	5	0,27
3	603	-54,651429	-17,407127	6,8	105	3	1,2	1,6	221	27,7	4,4	4,9	0,45
3	604	-54,653398	-17,405776	9,4	81	2,5	1	1,1	91	31,2	9,4	5,1	0,22
3	605	-54,654908	-17,403417	8,6	80	3,5	1,3	0,9	85	27,7	5,1	5,4	0,24
3	606	-54,656536	-17,400942	9	87	3,1	1,2	1,7	226	32,7	4,6	6,2	0,64
3	607	-54,65806	-17,398826	4,4	26	3,6	1,5	1,9	169	18,7	8,4	6	0,45
3	704	-54,650931	-17,404283	7,2	91	3,1	1,3	1,2	86	28,6	5,6	5,1	0,34
3	705	-54,652579	-17,401759	6,1	65	2,5	1	1	81	22,8	5,8	3,8	0,33
3	706	-54,65416	-17,39937	6,4	68	3	1,2	1	86	20,5	5,9	5,8	0,22
3	707	-54,655739	-17,396971	9,8	70	3,1	1,2	1,4	81	23,5	5,8	5,5	0,3
3	804	-54,648584	-17,402758	7,9	86	2,9	1,2	1,3	78	27,5	4,9	6	0,3
3	805	-54,649842	-17,400347	9,4	66	2,9	1,2	1,4	88	23	6	5,8	0,44
3	806	-54,651429	-17,397885	7,5	94	3,3	1,3	1,2	79	26,1	5,9	6	0,29
3	807	-54,65336	-17,395214	9,4	89	2,9	1,2	1,6	97	27,9	5,4	6,7	0,26
4	304	-54,651342	-17,419353	5,8	104	3	1,3	1,1	87	22,5	4	5,1	0,34
4	403	-54,647696	-17,419775	10,6	143	2,9	1,3	1,7	77	26,5	4	6,2	0,33
4	404	-54,649181	-17,41748	4,4	95	3	1,2	1	103	23,6	5,6	5,8	0,35
4	405	-54,650911	-17,414349	21,2	137	3	1,2	1,2	94	27,1	5	5,9	0,29
4	406	-54,652907	-17,412165	8,6	131	2,9	1,2	1,7	85	26	3,9	5,5	0,24

4	502	-54,644921	-17,42089	7,2	110	3,2	1,4	1,1	212	29,8	5,3	5,9	0,61
4	503	-54,645239	-17,418196	6,1	108	2,6	1,1	1,5	237	34,5	8,5	6,5	0,49
4	504	-54,646892	-17,41583	7,9	104	3,3	1,9	1,3	84	25,7	5	6,7	0,29
4	505	-54,648545	-17,413464	6,8	116	3	1,5	1	84	29,9	5,5	5	0,33
4	506	-54,650198	-17,411098	9	149	2,9	1,1	1,7	272	32,7	4,4	6,7	0,44
4	603	-54,64243	-17,417093	6,1	64	2,4	0,9	1,1	90	31,1	8,5	5,1	0,24
4	604	-54,644412	-17,414253	6,4	122	2,6	1,4	0,9	106	20,9	5,1	5,5	0,39
4	605	-54,646065	-17,411887	9	136	2,9	1,1	1,4	290	33,4	5,4	6,6	0,5
4	606	-54,647718	-17,409521	8,2	131	2,6	1,2	1,1	92	25,9	4,3	6,2	0,39
4	607	-54,649981	-17,408028	8,2	155	2,5	1	1,3	247	33,1	4,1	6,1	0,44
4	703	-54,640279	-17,415042	7,9	95	2,8	1,1	1,4	196	24,3	4,9	6,2	0,82
4	704	-54,641932	-17,412676	7,2	109	2,9	1,2	1,4	251	26,6	3,8	5,5	0,67
4	705	-54,643585	-17,41031	6,8	131	2,4	1,2	0,7	82	20	4,6	4,8	0,41
4	706	-54,645238	-17,407944	7,9	125	2,6	1,2	0,8	87	23,5	3,6	5	0,39
4	707	-54,646891	-17,405578	6,8	125	2,8	1,4	0,9	81	25,4	3,5	4,7	0,44
5	203	-54,63048	-17,423863	8,2	72	2,9	1,2	1,1	128	17,8	11,9	5	0,44
5	204	-54,634016	-17,423177	9	73	3,6	1,4	1,1	94	18,9	6,3	5,5	0,34
5	205	-54,636955	-17,422623	9,4	74	3,3	1,3	0,9	82	18	7,8	5,3	0,24
5	206	-54,639803	-17,421834	8,6	74	3,2	1,2	1	68	23,7	9	6	0,34
5	207	-54,64192	-17,42116	8,6	78	2,8	1,2	0,8	71	18,7	11,9	4,8	0,29
5	302	-54,626758	-17,422001	7,5	63	2,3	0,9	0,9	74	14,9	11,4	4,6	0,37
5	303	-54,630265	-17,42116	8,6	63	2	0,8	1,1	96	18,7	9,1	4,4	0,39
5	304	-54,633078	-17,420475	11,8	73	2,4	1	1,3	88	17,7	9,9	5,3	0,27
5	305	-54,636171	-17,419792	9,4	76	2,9	1,2	1	71	18,6	10,1	5,1	0,31
5	306	-54,639108	-17,419087	7,9	68	2,5	1,1	1,1	70	18,6	9,6	6	0,2
5	402	-54,625786	-17,419355	8,2	74	2,6	1,1	1	74	17	9,9	6,1	0,24
5	403	-54,629601	-17,418394	9,8	61	2	0,8	1	82	15,1	12,8	4,4	0,29
5	404	-54,632592	-17,417729	9,8	60	2,4	0,9	1,3	83	19,1	10,6	4,8	0,23
5	405	-54,635499	-17,416923	11,4	80	2,2	0,9	1,2	79	20	13,3	5	0,27
5	406	-54,637683	-17,416565	6,8	77	2,5	1,1	2	74	17,6	10,5	6,6	0,33
5	502	-54,626012	-17,416438	11,4	61	2,5	1,1	1,3	91	19,8	11,4	5,1	0,29
5	503	-54,628821	-17,415657	10,6	60	2,5	1	1,9	79	17,7	10,4	11,4	0,27
5	504	-54,631683	-17,415064	13,5	65	2,4	1	1,1	75	18,2	4,1	5,4	0,31
5	505	-54,634205	-17,413975	8,6	73	2,3	1	1	74	19,4	4,9	5	0,24
5	602	-54,625853	-17,413799	8,6	60	2,1	0,8	1,2	80	16,3	8,8	4,2	0,3
5	603	-54,628227	-17,41287	6,4	68	2	0,9	1,2	86	16,9	7,5	5,1	0,35
5	604	-54,631037	-17,41226	5,8	71	2,3	1,1	0,9	82	18	7,5	3,8	0,82
5	703	-54,627334	-17,410182	6,4	64	1,9	0,8	1	95	18,8	11,1	4,2	0,27
6	503	-54,6956	-17,4091	5	76	2,5	1,2	0,7	88	13,2	3,3	3,2	0,34
6	504	-54,6923	-17,4076	7	69	2,8	1,3	0,8	101	15,5	3,6	3,5	0,34
6	505	-54,6897	-17,4061	18	105	3	1,5	1	112	21,1	3,5	4,3	0,42
6	506	-54,6874	-17,4045	6	116	2,8	1,3	0,9	101	19,7	3,5	3,3	0,31
6	507	-54,6848	-17,4029	7	71	1,8	0,7	1,1	102	14	3,4	3,5	0,29
6	508	-54,6824	-17,4013	9	50	2,2	0,8	1,3	135	15,6	3,1	3,8	0,33
6	509	-54,68	-17,3997	12	71	2,2	0,9	1,6	119	15,4	3,3	4,8	0,3
6	604	-54,6906	-17,41	8	83	2,5	1,1	0,9	91	14,4	3,6	3,4	0,33
6	605	-54,6881	-17,4084	4	82	2,5	1,1	0,8	87	13	4	3,2	0,31

6	606	-54,6856	-17,4068	8	98	2,8	1,4	1	124	18,6	3,8	3,1	0,37
6	607	-54,6831	-17,4053	8	78	2,2	1	1,2	90	17,1	3,5	4,7	0,3
6	608	-54,6806	-17,4037	12	85	4	2,3	1,2	99	17	4	4,7	0,3
6	609	-54,6781	-17,4021	8	66	2	0,9	1	135	19,4	4,3	3,2	0,31
6	705	-54,6865	-17,4108	7	110	3,2	1,6	0,8	82	22,3	3,9	4,3	0,29
6	706	-54,684	-17,4092	8	111	2,9	1,4	1,1	92	19,4	3,1	3,8	0,3
6	707	-54,6816	-17,4076	6	113	2,5	1,2	1	82	19,5	3,3	4	0,31
6	708	-54,679	-17,406	8	105	2,9	1,2	1,1	86	19,3	3,8	5	0,27
6	709	-54,6765	-17,4045	8	81	1,9	0,8	1,3	98	17,4	4,4	4,1	0,23
6	806	-54,6824	-17,4116	6	111	3,1	1,5	1	88	20,3	4,3	4,7	0,24
6	807	-54,6799	-17,41	6	85	2,8	1,3	1	65	19,4	3,4	4,1	0,31
6	808	-54,6773	-17,4084	8	102	2,9	1,4	1,5	79	26	6,4	5,4	0,29
6	809	-54,6754	-17,4068	9	93	2,5	1,2	1,1	106	22	4,1	4,2	0,31
6	907	-54,679	-17,4128	4	102	3,1	1,5	0,9	105	20	5,1	3,6	0,27
6	908	-54,6757	-17,4107	7	100	3,2	1,5	1,3	97	27,7	3,8	4,2	0,16
7	202	-54,6543	-17,4183	3	125	1,9	1,3	1,2	129	23,2	6,1	2,8	0,18
7	203	-54,6571	-17,4177	4	90	2,2	1,4	1,3	131	22,3	4,6	2,6	0,2
7	204	-54,66	-17,417	4	87	2,7	1,7	1,2	144	34,6	5,1	2,7	0,18
7	205	-54,6634	-17,4161	4	85	2,8	1,8	1,2	125	32,8	5,8	2,6	0,22
7	303	-54,6548	-17,4162	4	88	2,3	1,5	1,3	112	28,9	5,3	3,5	0,2
7	305	-54,6613	-17,4143	4	83	2,4	1,5	1,1	131	36,4	5,1	2,2	0,19
8	302	-54,6756	-17,4139	4	96	3	1,3	1,5	101	25,5	7,4	3,9	0,16
8	303	-54,6736	-17,4121	15	101	3,6	1,4	2,3	88	37,2	5,4	6,8	0,2
9	202	-54,6721	-17,4143	5	106	3,2	2,1	1,1	93	38	5,1	4,1	0,24
9	203	-54,6695	-17,4121	4	70	1,9	1,1	1,4	166	36,9	4,9	8,2	0,2
9	302	-54,6696	-17,4156	4	63	3	2,1	1	100	52,3	6,6	2,7	0,27
9	303	-54,6675	-17,4141	4	82	2	1,3	1	99	41,9	5,6	6,3	0,22
1	203	-54,6521	-17,3815	6	84	2,1	0,9	0,8	126	31,1	3,9	2,8	0,22
1	204	-54,653	-17,3789	8	95	2,7	1,1	1,6	91	26,1	4,6	3,1	0,24
1	205	-54,6539	-17,3762	11	157	4,2	1,5	1,3	92	20,4	4,1	4,3	0,24
1	206	-54,6547	-17,3732	8	107	3,8	1,4	1	80	22,6	4,3	4,1	0,26
1	303	-54,6492	-17,381	9	95	2,2	1	1,2	94	25,9	4,8	3,8	0,24
1	304	-54,6501	-17,3779	11	141	3,9	1,3	1	93	30,7	4,3	5,3	0,26
1	305	-54,6509	-17,3752	7	125	3,3	1,2	0,8	80	22,8	4,6	2,6	0,27
1	306	-54,6519	-17,372	10	114	3,3	1,2	0,9	72	20,9	3,9	3,2	0,22
1	403	-54,6464	-17,3797	5	89	2,5	1,1	0,8	99	24,2	3,5	2,3	0,2
1	404	-54,6472	-17,3773	9	185	4	1,3	0,8	96	28,3	3,9	3,4	0,29
1	405	-54,6479	-17,3746	9	144	3,5	1,2	1,1	92	25,2	4,3	3,6	0,22
1	406	-54,6489	-17,3716	14	152	3,1	1,1	1,1	75	28	3,9	4	0,24
1	407	-54,6497	-17,3695	8	91	2,9	1,1	1,2	92	20,6	4,8	2,9	0,2
1	504	-54,6444	-17,3769	11	140	3,9	1,3	1,2	80	33,7	4,3	4,3	0,23
1	505	-54,6452	-17,3737	9	141	3	1	1,1	101	27,8	4,3	3,7	0,29
1	506	-54,646	-17,3711	7	114	2,9	1	0,9	95	23,8	4,1	3,1	0,23
1	507	-54,6469	-17,3682	9	84	2,8	0,9	1,3	91	12,9	4,3	3,7	0,2
1	604	-54,6414	-17,3756	7	133	3,4	1,2	1	79	28,9	4,9	3,4	0,26
1	605	-54,6424	-17,3729	7	125	3	1	0,8	86	23,3	4,3	3,3	0,26
1	606	-54,6432	-17,3701	8	99	3,1	1,1	0,8	72	23	4,1	3,3	0,24

1	607	-54,644	-17,3672	8	81	3,2	1,1	0,6	76	20,9	3,9	2,8	0,24
1	704	-54,6387	-17,3744	6	136	3,5	1,2	1,1	68	25,8	4,1	3,1	0,27
1	705	-54,6394	-17,3721	8	116	3	1,1	0,8	82	24,1	5,3	3,4	0,23
1	706	-54,6403	-17,3695	9	88	2,9	1,1	0,6	83	23,8	4,9	2,7	0,26
1	707	-54,6413	-17,3665	11	122	3,3	1,2	0,7	85	22	5,5	3,4	0,3
1	708	-54,6418	-17,3645	11	109	3,6	1,3	0,7	154	26,8	4,1	3,4	0,3
1	804	-54,6352	-17,3733	8	124	3,8	1,3	0,8	74	24,8	3,5	3,8	0,29
1	805	-54,6359	-17,371	8	112	3,8	1,4	1	80	24,4	3,8	4,4	0,29
1	806	-54,6367	-17,3683	14	124	3,6	1,3	0,6	90	21,9	4,6	2,9	0,3
1	807	-54,6385	-17,3656	11	102	3,9	1,4	0,7	82	27,5	4,9	3	0,26
2	203	-54,6555	-17,3705	7	134	4,4	2,5	0,8	81	22,9	4	3,6	0,24
2	204	-54,6559	-17,368	6	131	3,9	1,7	1	95	20,1	6,1	3,6	0,27
2	205	-54,6569	-17,3652	5	148	4	1,7	1,4	75	24,5	4,1	4,1	0,3
2	206	-54,6579	-17,3626	6	110	3,4	1,3	0,9	76	27	3,8	3	0,29
2	304	-54,653	-17,3677	9	114	3,1	1,2	1	79	24,9	4,4	3,9	0,29
2	305	-54,6542	-17,3642	9	105	3,5	1,2	0,9	81	26,4	4,1	4,1	0,24
2	306	-54,655	-17,3616	8	123	3,2	1,2	0,9	79	27,4	5,5	3,6	0,27
2	307	-54,6557	-17,3591	9	120	3,5	1,2	0,7	80	27,3	4,8	3,7	0,27
2	404	-54,6503	-17,3666	8	89	2,9	1	0,8	77	22,7	4	2,9	0,29
2	405	-54,6514	-17,3636	6	81	3,6	1,2	0,8	77	23,1	3,8	3,5	0,3
2	406	-54,6523	-17,3609	9	90	3,5	1,2	0,9	87	20,9	4,1	4	0,27
2	407	-54,653	-17,3582	7	120	3,4	1,2	1,2	81	19,8	3,9	3,8	0,22
2	408	-54,6535	-17,3556	7	100	3,4	1,1	0,9	84	20,5	4,9	3,6	0,24
2	504	-54,6475	-17,3652	7	105	3,1	1,1	0,9	84	21,9	4	3,3	0,29
2	505	-54,6486	-17,3627	7	107	3,3	1,2	0,8	79	21	5,4	3,4	0,29
2	506	-54,6492	-17,3598	9	84	3,7	1,3	0,8	73	23,1	3,3	3,8	0,29
2	507	-54,6503	-17,3572	6	87	3,4	1,2	0,9	90	22,8	4,1	3,2	0,27
2	508	-54,6513	-17,3544	8	102	3,2	1,2	1,2	80	22,3	3,3	4,6	0,26
2	509	-54,6517	-17,3522	9	106	4,1	1,6	1	63	25,7	3,6	4,2	0,26
2	604	-54,6449	-17,3643	7	107	3,4	1,3	0,9	74	28,4	3,5	3,9	0,23
2	605	-54,6456	-17,3619	8	82	3,4	1,3	0,8	71	22,3	4,5	3,4	0,3
2	606	-54,6465	-17,3592	9	79	3	1,2	1	73	22,4	4,4	4,2	0,24
2	607	-54,6474	-17,3565	11	102	2,8	1,1	1,2	89	21	4,3	3,8	0,24
2	608	-54,6486	-17,354	9	86	3,8	1,6	1	63	19,5	4,5	4	0,29
2	705	-54,6425	-17,3615	8	130	3	1,2	0,8	76	24,3	5,3	3,7	0,34
2	706	-54,6436	-17,3581	10	134	3,1	1,3	0,9	74	24,6	4,3	4	0,39
2	804	-54,6379	-17,3624	13	127	3,6	1,2	1	79	27	4,6	5,6	0,29
2	805	-54,6403	-17,3602	12	86	3,3	1,2	0,8	75	22,2	4	5	0,31
3	402	-54,6344	-17,3623	15	127	3,8	1,6	1,1	83	24,5	3,6	5,7	0,27
3	403	-54,6323	-17,3605	16	97	3,4	1,2	1,3	77	25,7	4,6	5,3	0,29
3	404	-54,6298	-17,3588	14	119	3,3	1,2	0,9	75	22	4,6	4,7	0,31
3	405	-54,6275	-17,3572	14	161	3,2	1,1	0,9	71	22,1	4,4	4,7	0,23
3	406	-54,6252	-17,3555	15	135	3,3	1,5	1,2	84	21,1	5,6	5	0,3
3	407	-54,6229	-17,3537	16	121	2,9	1,2	1	88	23,1	5,3	3,9	0,33
3	408	-54,62	-17,3536	14	131	3,1	1,3	0,9	76	23,5	5,6	4,1	0,42
3	502	-54,6334	-17,3647	17	86	4,1	1,7	0,7	70	22,8	5	4,7	0,3
3	503	-54,6305	-17,3629	14	102	3,9	1,6	1,5	98	27,5	4,3	5,1	0,34

3	504	-54,6282	-17,3611	8	89	3,4	1,3	0,7	74	21	3,9	2,8	0,33
3	505	-54,6256	-17,3595	14	98	3,1	1,2	0,7	67	20,1	5,6	4,9	0,37
3	506	-54,6234	-17,3577	14	138	2,8	1,1	0,8	82	21	4,3	4,7	0,29
3	507	-54,6208	-17,3558	14	137	3,3	1,4	1,3	76	23,6	6	7,2	0,3
3	602	-54,6314	-17,3665	16	107	3,5	1,3	1,1	82	24,1	4,9	5,3	0,33
3	603	-54,6287	-17,3654	11	108	3,4	1,4	0,9	76	22,4	5,3	4,3	0,35
3	604	-54,6263	-17,3635	7	124	3	1,2	0,8	83	18,9	5,6	4,3	0,27
3	605	-54,6241	-17,3619	10	186	3,3	1,5	0,8	123	24,9	6,8	5,1	0,31
3	606	-54,6214	-17,3601	13	158	3,3	1,5	1,8	73	25,5	6,9	5	0,35
3	607	-54,6191	-17,3581	9	150	3,1	1,5	0,6	64	29,9	6,5	4,4	0,39
3	704	-54,6246	-17,3654	8	124	3	1,5	0,7	86	22,9	5,6	3,9	0,24
3	705	-54,6221	-17,3643	8	127	3	1,4	0,9	84	23,7	8	4,7	0,24
3	706	-54,6196	-17,3625	6	176	2,9	1,4	1,1	70	24,3	5,1	4,2	0,38
3	707	-54,6175	-17,3606	6	152	2,9	1,5	1	63	22,6	5,4	3,6	0,29
1	202	-54,6519	-17,3914	5	62	2,2	1	1,1	79	23,2	5,3	4,1	0,2
1	203	-54,6534	-17,3893	6	63	1,6	0,7	0,7	104	19,1	6,4	3,3	0,19
1	204	-54,6547	-17,387	10	59	1,7	0,7	0,8	99	22,9	6	3,4	0,19
1	302	-54,6491	-17,3906	4	64	1,2	0,5	1	90	15	6,5	3	0,19
1	303	-54,6507	-17,388	3	67	1,7	1	0,7	94	20,3	6,3	1,9	0,27
1	304	-54,6524	-17,386	4	72	1,9	1,2	0,5	116	24,2	6,6	1,7	0,3
1	402	-54,6478	-17,3899	4	93	2	1,2	0,7	96	17,1	5,5	2,4	0,24
2	203	-54,6456	-17,3882	5	126	2,1	1,3	0,9	144	19,1	7,8	2,3	0,27
2	204	-54,6468	-17,3855	6	75	1,7	1	1	106	26,4	6,8	2,8	0,22
2	205	-54,6465	-17,3833	9	66	1,5	0,8	1,2	108	25,8	6,9	2,4	0,23
2	302	-54,6418	-17,3909	3	92	2,3	1,2	0,7	114	21,1	6,9	2	0,2
2	303	-54,6428	-17,3876	5	115	2,7	1,7	0,9	104	29,9	6,8	2,5	0,23
2	304	-54,6433	-17,3849	9	96	2,9	1,7	1,1	91	36,3	5,6	3,1	0,2
2	305	-54,644	-17,3821	17	117	3,5	2,2	1,4	70	90	7,1	4,8	0,58
2	401	-54,6388	-17,3917	3	79	2,1	1,2	0,9	137	22,4	8,1	1,5	0,26
2	403	-54,6398	-17,3871	9	127	3,3	1,6	1,2	77	35,3	6,5	4	0,29
2	404	-54,6404	-17,3843	6	120	3,2	1,5	0,8	73	34,3	6,1	2,7	0,26
2	405	-54,6406	-17,3815	19	128	3,9	2	1,2	74	39,8	6,9	5,1	0,52
3	304	-54,6327	-17,3979	10	105	1,8	0,7	1,1	80	32,9	8,4	3,9	0,19
3	305	-54,6333	-17,395	16	107	2,2	0,8	1,1	104	24,9	8,1	3,6	0,19
3	402	-54,6281	-17,4028	18	139	2,9	1,2	1,4	99	36,8	8,3	5,4	0,24
3	403	-54,6297	-17,4003	9	124	2,4	1	1,4	91	33,1	8	4,3	0,29
3	404	-54,6299	-17,3972	7	101	2,5	1,1	0,9	92	34,6	6,9	3,6	0,3
3	405	-54,6306	-17,3946	8	98	2,3	1	0,8	100	31,2	6,6	3,7	0,42
3	205	-54,6363	-17,3951	14	87	1,6	0,7	1	84	35,3	4,8	4,2	0,22
4	503	-54,6381	-17,4133	8	63	2,6	1,2	0,8	94	19,2	6,6	3,9	0,42
4	504	-54,6396	-17,4108	5	62	2,9	1,2	0,3	84	18,9	6,5	1,9	0,37
4	505	-54,641	-17,4083	11	90	2,6	1,2	0,5	76	26,8	6,3	3,8	0,34
4	506	-54,643	-17,4059	7	68	2,8	1,2	0,3	80	24,5	5,9	2	0,38
4	507	-54,6444	-17,4033	5	75	3	1,3	0,5	83	27,3	6,1	2,7	0,29
4	508	-54,6461	-17,4009	6	63	2,7	1,2	0,7	74	27,3	6,1	2,9	0,33
4	509	-54,6476	-17,3983	9	79	3	1,4	0,5	83	29,6	6,4	3,2	0,35
4	510	-54,6493	-17,3961	8	90	2,5	1,2	0,6	62	22	7,1	3,8	0,34

4	511	-54,6506	-17,3937	8	78	2,6	1,2	0,8	86	21,6	6,3	3,8	0,37
4	603	-54,6353	-17,4114	7	90	2,7	1,2	0,9	89	18,4	6,5	3,6	0,38
4	604	-54,6369	-17,4089	7	88	2,5	1,2	0,4	90	17,5	6,3	2,6	0,42
4	605	-54,6384	-17,4069	5	80	1,7	0,7	0,5	69	24,6	6,3	2,2	0,3
4	606	-54,6401	-17,4042	4	107	2,9	1,4	0,5	68	34,9	7,1	3	0,35
4	607	-54,6417	-17,4018	8	123	2,7	1,2	0,8	77	30,6	11	3,8	0,42
4	608	-54,6435	-17,3994	5	63	2,4	1,2	0,6	93	25,1	7,5	2,6	0,41
4	609	-54,6448	-17,3969	8	57	2,7	1,2	0,6	61	21,6	7,8	3,5	0,37
4	610	-54,6467	-17,3943	9	100	2,1	0,9	0,8	88	23,8	8,1	4,2	0,38
4	703	-54,6329	-17,41	6	61	2,5	1,2	0,6	97	20,3	7,1	3	0,3
4	704	-54,6344	-17,4075	8	79	3,3	2,1	0,4	83	20,7	8,1	3,5	0,31
4	705	-54,6358	-17,4052	5	66	2,7	1,2	0,5	76	30,1	5,6	2,3	0,29
4	706	-54,6375	-17,4027	4	79	2,7	1,2	0,6	76	25,9	6,5	2,7	0,29
4	707	-54,6392	-17,4001	9	88	2,4	1,1	1	81	36,1	6,1	4,2	0,33
4	708	-54,6407	-17,3977	6	74	2,2	1,1	0,7	80	21,5	6,4	3	0,3
4	709	-54,6423	-17,3952	6	76	2,3	1,2	0,5	71	24	5,4	2,9	0,24
4	710	-54,6445	-17,3934	5	113	1,6	1	0,6	89	17,8	6,8	2	0,31
4	803	-54,63	-17,4086	6	57	2,5	1,2	0,5	72	20,3	6	3	0,24
4	804	-54,6317	-17,4061	5	80	2,6	1,2	0,8	71	29,3	6,3	2,7	0,3
4	805	-54,633	-17,4036	6	111	3,2	1,6	0,6	79	43,3	7,1	2,9	0,23
4	806	-54,6349	-17,4012	6	109	2,6	1,2	0,7	82	40,9	7	3,6	0,26
4	807	-54,637	-17,3991	5	80	2,4	1,1	0,9	82	32,1	6,3	3,2	0,37
4	808	-54,6388	-17,3965	4	50	1,9	0,9	0,8	79	23,9	6,3	2	0,3
4	903	-54,6278	-17,4073	13	94	3,1	1,5	1	68	28,3	6	4,5	0,41
4	904	-54,6295	-17,4048	5	83	3	1,3	0,8	65	35,4	7,1	2,9	0,37

7.2. Apêndice 2

SOFTWARE UTILIZADO NO TREINAMENTO DA REDE PERCEPTRON

```
% longitude latitude Variaveis
M = [Matriz de treinamento];
% matriz de teste
% longitude latitude Variaveis
T = [Matriz de teste];
%definindo os parâmetros da rede para o treinamento
x = [M(:,1)'
      M(:,2)'
      M(:,3)']; %matriz contendo as variáveis de entrada
d = [M(:,4)']; %matriz de saída
domínio = [min(x')
            max(x')]; %obtendo o domínio das entradas (utiliz.p normaliz.)
camadas = [12,1]; %especificando as camadas neurais
ativações = {'tansig','tansig'} %definindo as funções de ativação
treinamento = 'trainlm'; %definindo o algoritmo de treinamento
%criando a rede perceptron
%net=newff (dominio, camadas, ativacoes, treinamento)%função que cria a rede perceptron
net = newff (dominio, camadas, ativacoes, treinamento) %função que cria a rede perceptron
%definindo as constantes do treinamento
net.trainParam.show = 25; %mostra a performance do treinamento a cada 25 épocas
net.trainParam.epochs = 3000; %finaliza o treinamento após 3000 épocas
net.trainParam.goal = 0.5e-3; %finaliza " " quando atingir o erro atingir0.5 10-3
%pré-processando os dados de entradas e saídas (dados de treinamento)
[x, min_x, max_x, d, min_d, max_d] = premmx(x,d);
%treinando a rede
[net,erro] = train(net,x,d);
```

```

%testando a rede com os padrões de teste
x1 = [T(:,1)'
      T(:,2)'
      T(:,3)']; %matriz contendo as variáveis de entrada p. o teste
d1 = [T(:,4)']; %vetor de saída desejado
x1 = tramnmx(x1,min_x,max_x); %normaliza as entradas da matriz de teste
resposta1 = sim(net,x1)'; %simula a saída da rede-retorna os valores normalizados
%Pós-processamento os dados de saída da rede
resposta2 = postmnmx(resposta1,min_d,max_d); %retorna respostas reais
%mostra resposta da rede e resposta desejada
resposta3 = [d1' resposta2]; %primeira coluna (resp.desejada)
                        %seg. coluna (resp. da rede)
%calculando o erro relativo entre a resposta da rede e a resposta desejada
erro_relativo = abs(100*(resposta3(:,1)-resposta3(:,2))./resposta3(:,1));
%mostra=>resposta desejada, resposta da rede e erro relativo
resposta4 = [d1' resposta2 erro_relativo]
%calculando o erro relativo medio e a variancia
erro_medio = mean(erro_relativo)
desvio_padrao = std(erro_relativo)
variância = desvio_padrao^2
%plotando a curva do erro em função da epocas
plotperf(erro);
xlabel('epocas de treinamento')
ylabel('erro quadratico medio')
title('desempenho do erro')

```