

Estudo da correlação entre mapas de variabilidade de propriedades do solo e mapas de produtividade para fins de Agricultura de Precisão

Parecer

Este exemplar corresponde a redação final da dissertação de Mestrado defendida por Alberto Augusto Eichman Jakob e aprovada pela Comissão Julgadora em 10 de maio de 1993. Campinas, 10 de agosto de 1993.

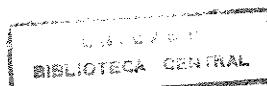
J. Jansle Vieira Rocha
Presidente da Banca

Alberto Augusto Eichman Jakob

Orientador: Prof. Dr. Jansle Vieira Rocha

Dissertação de Mestrado apresentada ao Departamento de Planejamento e Produção Agrícola da Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas

Faculdade de Engenharia Agrícola/UNICAMP
Abril/99



DADE BC
CHAMADA:
11-107
229199
Ex.
M80 BC/39107
OC. 229199
C [] D []
IECO AB 11.00
ITA 211101 99
• CPD

CM-00136415-2

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

J213e Jakob, Alberto Augusto Eichman
Estudo da correlação entre mapas de variabilidade de propriedades do solo e mapas de produtividade para fins de agricultura de precisão. / Alberto Augusto Eichman Jakob.--Campinas, SP: [s.n.], 1999.

Orientador: Jansle Vieira Rocha
Dissertação (mestrado) - Universidade Estadual de
Campinas, Faculdade de Engenharia Agrícola.

1. Sistema de informação geográfica. 2. Correlação (Estatística). 3. Análise de regressão. 4. Solos – Produtividade. I. Rocha, Jansle Vieira. II. Universidade Estadual de Campinas. Faculdade de Engenharia Agrícola. III. Título.

**“Faça o máximo do melhor
e o mínimo do pior”**

Robert Louis Stevenson

Agradeço neste trabalho:

À minha esposa, pela paciência

A meus pais, pela confiança

Ao meu orientador, pela oportunidade

À Silvana, pela disponibilidade

À Emilia, pelo apoio

Ao Sr. Carlos Burga, pela gentileza

Ao Ivanildo, pela força

À Dinamilho Carol Produtos Agrícolas ltda, pelas sementes

À COPAS - Companhia Paulista de Fertilizantes, pelo fertilizante

Ao CPQBA/UNICAMP, pela área

Ao CNPq, pelo apoio financeiro

SUMÁRIO:

Lista de Tabelas.....	viii
Lista de Figuras.....	ix
Lista de Abreviaturas.....	xi
Resumo.....	xii
Summary.....	xiii
I - Introdução.....	01
II - Revisão da Literatura.....	03
2.1. Agricultura de Precisão.....	03
2.2. Sistemas de Posicionamento Global (GPS).....	08
2.3. Sistemas de Informação Geográfica (SIG).....	11
2.4. Variabilidade Espacial.....	17
2.4.1. Variabilidade Espacial dos Atributos do Solo.....	18
2.4.1.1. A Amostragem do Solo.....	19
2.4.2. Variabilidade Espacial do Rendimento das Culturas.....	20
2.4.3. Resultados Obtidos na Literatura.....	21
2.5. A Estatística no Estudo da Variabilidade de Solos.....	23
2.5.1. A Estatística Clássica ou de Fisher.....	24
2.5.1.1. A Análise Exploratória de Dados.....	27
2.5.2. A Teoria das Variáveis Regionalizadas ou Geoestatística.....	28
2.5.2.1. O Autocorrelograma.....	29
2.5.2.2. O Variograma.....	30
2.5.2.3. A Krigagem.....	33
2.5.2.3.1. A Krigagem Simples.....	34
2.5.2.3.2. A Krigagem Ordinária.....	35
2.6. Os Nutrientes da Cultura.....	36
2.6.1. Elementos Essenciais.....	36
2.6.2. Os Macronutrientes.....	37

2.6.2.1. Fósforo.....	37
2.6.2.2. Potássio.....	38
2.6.2.3. Cálcio.....	38
2.6.2.4. Magnésio.....	39
2.6.2.5. Alumínio.....	40
2.6.3. Os Micronutrientes.....	40
2.6.3.1. Boro.....	40
2.6.3.2. Cobre.....	41
2.6.3.3. Ferro.....	41
2.6.3.4. Manganês.....	42
2.6.3.5. Zinco.....	42
2.7. O Latossolo Roxo.....	43
 III - Material e Métodos.....	45
3.1. Caracterização da área de Estudos.....	45
3.2. Tratos Culturais.....	46
3.3. Esquema Experimental de Amostragem do Solo.....	47
3.4. Atributos do Solo.....	48
3.4.1. Análise Granulométrica.....	48
3.4.2. Análise de Fertilidade.....	49
3.5. Produtividade da Cultura.....	49
3.6. Análises Estatísticas.....	51
3.6.1. Análises Descritivas.....	51
3.6.2. Teoria das Variáveis Regionalizadas.....	52
 IV - Resultados	53
4.1. Análises Descritivas e Exploratórias.....	53
4.2. Regressões Lineares Multivariadas.....	65
4.2.1. Com as variáveis mais importantes para a nutrição.....	65
4.2.2. Com todas as variáveis.....	73
 V – Discussão dos Resultados.....	79
 VI – Conclusão.....	83
 VII – Anexos.....	85
Anexo 1: Dados relativos à Análise Granulométrica.....	85
Anexo 2: Dados relativos à Análise de Fertilidade.....	86
Anexo 3: Dados relativos ao Rendimento da Cultura.....	88

Anexo 4: Análises Descritivas das variáveis de Estudo.....	89
Anexo 5: Semivariogramas das variáveis de estudo.....	103
Anexo 6: <i>Grids</i> interpolados das variáveis de estudo.....	110
Anexo 7: Mapas interpolados das variáveis de estudo.....	117
Anexo 8: Análises de Regressões Lineares Multivariadas.....	124
Referências Bibliográficas.....	132

LISTA DE TABELAS:

Tabela 1: Matriz de Correlações.....	53
Tabela 1: Matriz de Correlações (cont.).....	54
Tabela 2: Análise dos Macronutrientes.....	56
Tabela 3: Análise dos Macronutrientes sem os <i>outliers</i>	57
Tabela 4: Análise dos Micronutrientes e Granulometria.....	58
Tabela 5: Análise dos Micronutrientes e Granulometria sem os <i>outliers</i>	59
Tabela 6: Modelos de Regressão passo-a-passo.....	66
Tabela 7: Modelos de Regressão passo-a-passo com todas as variáveis.....	73
Tabela 8: Valores Limites Padrões para os Laboratórios de Análises Químicas....	80

LISTA DE FIGURAS:

Figura 1: Máquina Colhedora de Grãos com Equipamento para Mapear Rendimento de cultura.....	06
Figura 2: Mapas de Atributos de Solos.....	07
Figura 3: Sistema de Correção Diferencial de GPS.....	10
Figura 4: Sistema de Correção Diferencial em Tempo Real.....	11
Figura 5: Componentes de um SIG.....	14
Figura 6: Mapa da Área de Estudos com Pontos de Coleta e coordenadas UTM...	45
Figura 7: Mapa Geo-referenciado do Rendimento da Cultura.....	50
Figura 8: Análises Estatísticas para o Fósforo.....	60
Figura 9: Ramo-e-folhas e Box-plot para o Fósforo.....	60
Figura 10: Análises do Fósforo sem os <i>outliers</i>	61
Figura 11: Análises do Potássio sem os <i>outliers</i>	62
Figura 12: Análises Estatísticas para o Manganês.....	62
Figura 13: Ramo-e-folhas e Box-plot para o Manganês.....	62
Figura 14: Análises do Silte Grosso sem os <i>outliers</i>	63
Figura 15: Análises Estatísticas para a Argila.....	64
Figura 16: Ramo-e-folhas e Box-plot para a Argila.....	64
Figura 17: Semivariograma do Rendimento.....	67
Figura 18: <i>Grid</i> interpolado do Rendimento.....	67
Figura 19: Mapa Geo-referenciado do Rendimento.....	67
Figura 20: Semivariograma da Matéria Orgânica.....	67
Figura 21: <i>Grid</i> interpolado da Matéria Orgânica.....	67
Figura 22: Mapa Geo-referenciado da Matéria Orgânica.....	68
Figura 23: Semivariograma do Magnésio.....	68
Figura 24: <i>Grid</i> interpolado do Magnésio.....	68
Figura 25: Mapa Geo-referenciado do Magnésio.....	68
Figura 26: Semivariograma da Argila.....	69
Figura 27: <i>Grid</i> interpolado da Argila.....	69
Figura 28: Mapa Geo-referenciado da Argila.....	69
Figura 29: Semivariograma do Fósforo.....	69
Figura 30: <i>Grid</i> interpolado do Fósforo.....	69
Figura 31: Mapa Geo-referenciado do Fósforo.....	69
Figura 32: Semivariograma do Cálcio.....	70
Figura 33: <i>Grid</i> interpolado do Cálcio.....	70
Figura 34: Mapa Geo-referenciado do Cálcio.....	70

Figura 35: Semivariograma do Potássio.....	70
Figura 36: <i>Grid</i> interpolado do Potássio.....	70
Figura 37: Mapa Geo-referenciado do Potássio.....	71
Figura 38: Semivariograma do H+Al.....	71
Figura 39: <i>Grid</i> interpolado do H+Al.....	71
Figura 40: Mapa Geo-referenciado do H+Al.....	71
Figura 41: Mapa Geo-referenciado do Rendimento Observado.....	72
Figura 42: Mapa Geo-referenciado do Rendimento Esperado.....	72
Figura 43: Semivariograma do Ferro.....	74
Figura 44: <i>Grid</i> interpolado do Ferro.....	74
Figura 45: Mapa Geo-referenciado do Ferro.....	74
Figura 46: Semivariograma do Zinco.....	74
Figura 47: <i>Grid</i> interpolado do Zinco.....	74
Figura 48: Mapa Geo-referenciado do Zinco.....	75
Figura 49: Semivariograma da Soma de Bases.....	75
Figura 50: <i>Grid</i> interpolado da Soma de Bases.....	75
Figura 51: Mapa Geo-referenciado da Soma de Bases.....	75
Figura 52: Semivariograma do Cobre.....	75
Figura 53: <i>Grid</i> interpolado do Cobre.....	75
Figura 54: Mapa Geo-referenciado do Cobre.....	76
Figura 55: Semivariograma da Saturação por Bases.....	76
Figura 56: <i>Grid</i> interpolado da Saturação por Bases.....	76
Figura 57: Mapa Geo-referenciado da Saturação por Bases.....	76
Figura 58: Semivariograma da Capacidade de Troca de Cátions.....	76
Figura 59: <i>Grid</i> interpolado da Capacidade de Troca de Cátions.....	76
Figura 60: Mapa Geo-referenciado da Capacidade de Troca de Cátions.....	77
Figura 61: Mapa Geo-referenciado do Rendimento Observado.....	77
Figura 62: Mapa Geo-referenciado do Rendimento Esperado.....	77
Figura 63: Mapa dos Limites Padrões para o Fósforo.....	80
Figura 64: Mapa dos Limites Padrões para o Potássio.....	80
Figura 65: Mapa dos Limites Padrões para o Magnésio.....	81
Figura 66: Mapa dos Limites Padrões para a Saturação por Bases.....	81
Figura 67: Mapa dos Limites Padrões para o pH.....	81

LISTA DE ABREVIATURAS:

B – Boro

Ca – Cálcio

CTC – Capacidade de Troca de Cátions

Cu – Cobre

Fe – Ferro

GPS – *Global Positioning System* (Sistema de Posicionamento Global)

H+Al – Hidrogênio+Alumínio

K – Potássio

Mg – Magnésio

Mn – Manganês

MO – Matéria Orgânica

P – Fósforo resina

SBases – Soma de Bases

SFino – Silte Fino

SGrosso – Silte Grosso

SIG – Sistema de Informações Geográficas

V% – Saturação por Bases

Zn – Zinco

RESUMO:

O presente trabalho teve como objetivo principal o estudo e a avaliação de uma metodologia para análise da variabilidade espacial de atributos do solo e sua correlação com o rendimento da cultura de milho (*Zea mays L.*) para fins de agricultura de precisão.

Para isto foram utilizadas técnicas de estatística básica, geoestatística e geoprocessamento para a criação de mapas interpolados de atributos do solo e rendimento da cultura.

O ensaio foi realizado numa área de aproximadamente 4 hectares, no campo experimental do Centro de Pesquisas Químicas, Biológicas e Agrícolas (CPQBA/UNICAMP), em Paulínia (SP). Foi utilizado um grid de amostragem do solo (classificado como latossolo roxo) de 25 metros e retiradas amostras nas profundidades de 0-20cm e 20-40cm, para análise de fertilidade. O plantio de milho foi feito em janeiro de 1998 e a colheita realizada em junho de 1998.

Foram feitos semivariogramas para a criação de modelos utilizados na krigagem dos atributos do solo, e estes novos mapas de atributos interpolados foram correlacionados com o mapa interpolado de rendimento de cultura por meio de análises de regressão espacial simples multivariada.

Os resultados mostraram que o modelo obtido com os atributos mais importantes para a produção do milho explicou 82% do rendimento da cultura, utilizando como parâmetros os índices de Matéria Orgânica, Magnésio, Argila, Fósforo, Cálcio, Potássio e H+Al.

SUMMARY:

The main goal of this study was to evaluate a methodology for the analysis of soil attributes and its correlation with the corn yield for precision agriculture purpose.

Statistics, geostatistics and GIS techniques were applied to the creation of interpolated soil attribute maps and yield maps.

The experiment was carried out within a 4 há field in the experimental area of the CPQBA/UNICAMP, in Paulinia (SP, Brazil). A 25 meters sample grid was made and soil samples were taken at 0.20m and 0.40m depth. The corn was planted in january and harvested in june (1998).

Semivariograms were made in order to build the models used for kriging interpolation of soil attributes. These interpolated soil attribute maps were correlated with the interpolated yield map by mean of multivariate spatial regression.

The results showed that the model derived from the most important parameters for the corn production explained 82% of the crop yield, using the parameters organic matter, Mg, clay, P, Ca, K and H+Al.

I - INTRODUÇÃO

A globalização da economia e a competitividade de preço dos produtos têm direcionado o setor agrícola para uma busca por maior eficiência e melhor controle de informações em nível de campo. A pressão por maior conservação dos recursos naturais e menor poluição do solo é outro fator a influenciar novas mentalidades na operacionalização do processo produtivo da agricultura.

“Agricultura de precisão” é um termo usado para descrever a busca do crescimento em eficiência através do gerenciamento localizado da agricultura. Envolve a aplicação de tecnologias utilizadas para medir o rendimento, determinar as condições do solo e da cultura, estudar a topografia e reunir outras informações de cada parte do campo, associando-as a uma localização exata. Com os dados obtidos, gera-se um mapa da área no computador, permitindo que se vejam claramente as relações entre vários fatores através da espacialização das variações de atributos ao longo da área. As informações deste mapa podem ser utilizadas para se determinar a quantidade de fertilizante que deve ser aplicada num determinado local, economizando nas áreas onde não é necessário, buscando-se assim, uma uniformização de rendimento da cultura.

Agricultura de precisão não é simplesmente a aplicação de tratamentos em nível local, pois também requer monitoramento e assessoramento qualificado, que juntos são suficientes para que se entenda os processos envolvidos no campo; ela não corresponde necessariamente ao rendimento máximo, e sim à máxima vantagem financeira sem o comprometimento dos recursos naturais, tendo como ideal a eficiência na produção e conservação. Essa eficiência minimiza custos, aumenta a produção, e, recentemente, tem dado bons resultados em termos de lucro para fazendeiros americanos, que minimizaram o uso de produtos químicos.

A tecnologia envolvida na agricultura de precisão compreende o uso de receptores GPS (*Global Positioning System*), sistemas informatizados de coleta de dados, *softwares* para tratamento e mapeamento destes dados e sistemas eletrônicos de acionamento e controle de máquinas agrícolas.

Conhecer a variabilidade espacial de atributos do solo que controlam a produtividade de culturas é um fator indispensável na implantação da agricultura de precisão. Alterações mínimas nos atributos do solo podem causar grandes diferenciações na produção. Correlacionando estes atributos com a produtividade obtém-se os atributos que mais contribuem para explicar a produtividade e seu grau de importância. Existem diversos trabalhos neste sentido, mas a metodologia de processamento dos dados em agricultura de precisão ainda não está completamente entendida.

O objetivo deste trabalho é avaliar a metodologia de tratamento de dados em agricultura de precisão, por meio de um estudo de correlação entre mapas de atributos do solo e mapas de rendimento de colheita da cultura de milho (*Zea mays L.*) utilizando técnicas de estatística básica, geoestatística e geoprocessamento.

II - REVISÃO DA LITERATURA

A Agricultura de Precisão engloba várias tecnologias, descritas neste capítulo. O primeiro item nos dá uma abordagem geral sobre a agricultura de precisão, o que vem a ser, quais as vantagens e desvantagens. O segundo traz uma noção de Sistemas de Posicionamento Global (GPS), que é utilizado para a obtenção de posições em coordenadas geográficas na superfície terrestre. A seguir é tratado o tema dos sistemas de informação geográfica (SIG), que são fundamentais para o gerenciamento das informações neste trabalho. Por fim, tratamos das análises estatísticas que serão feitas com os dados obtidos das amostras coletadas e da geoestatística ou teoria das variáveis regionalizadas, o que vem a ser, por que devemos utilizá-la e sua comparação com a estatística clássica.

2.1. AGRICULTURA DE PRECISÃO

FRAISSE (1997) relata que antes da revolução industrial e do processo de mecanização da agricultura, os agricultores já eram capazes de reconhecer a variabilidade espacial de certas características físico-químicas e biológicas das áreas cultivadas. Até então, o uso do trabalho braçal e/ou tração animal permitia aos agricultores tratar de áreas com menor ou maior fertilidade ou infestação por pragas e doenças de forma diferenciada. Com o advento da mecanização e da produção em larga escala os campos cultivados passaram a ser tratados de maneira uniforme.

Esta maneira de tratar as áreas, segundo o CAAP (1997), geralmente resulta numa aplicação uniforme de fertilizantes, herbicidas e tratamentos para controle de pragas. E tal uniformidade de tratamentos ignora as variações naturais e induzidas nas propriedades do solo, e pode resultar em zonas com excesso e outras com falta de tratamentos, fazendo com que cresçam os problemas econômicos e ambientais associados a esta inefetiva aplicação de insumos no solo.

TWEETEN (1996), diz que os principais problemas ambientais da agricultura envolvem a água, o ar, a qualidade do alimento e a depreciação de recursos naturais. Aplicações convencionais de fertilizantes significam aplicações excessivas em algumas áreas e inadequadas em outras áreas do campo, e aplicações em excesso causam escorramento, que pode ser carregado por enxurradas ou percolado e atingir lençóis de água. O mesmo acontece com pesticidas. Sensores de solo e mapeamentos poderiam melhorar o tipo, volume e local das aplicações de pesticidas. A agricultura de precisão aumenta a produtividade da área, reduzindo suas necessidades para conseguir alimentos e demandas de fibras. Ela pode ajudar a adquirir uma uniformidade na produção, proporcionando uma melhor cobertura contra a erosão. A agricultura de precisão pode salvar os recursos naturais e/ou reduzir os preços dos alimentos para os consumidores finais.

É neste ínterim que surge o conceito de sustentabilidade que, segundo MORRIS et al. (1994), é o conceito de que o ambiente deveria ser tão resguardado e mantido que ele não sofreria erosão ou degradação e passaria às futuras gerações nas mesmas condições ou possivelmente melhorado ou desenvolvido. Assim, nenhuma operação deveria ser levada adiante se provocasse danos ao ambiente sem que os danos fossem reparados. A agricultura de precisão pode ajudar na restauração de um solo danificado.

A agricultura de precisão não é simplesmente a capacidade de aplicar tratamentos que são variados num nível local, mas sim a capacidade de precisamente monitorar e assessorar o empreendimento agrícola num nível local e ter entendimento suficiente dos processos envolvidos para ser capaz de otimizar a aplicação de insumos de tal maneira que maximizem a produção. Inevitavelmente ela integra uma quantidade significante de técnicas de computação e eletrônica, mas altos níveis de controle requerem sistemas mais sofisticados.

Segundo HOSKINSON (1995), o objetivo de se aumentar a eficiência da agricultura é reduzir a energia utilizada e o impacto ambiental com o uso otimizado de recursos. Este objetivo pode ser atingido integrando-se componentes tecnológicos como GPS, sensores que medem o rendimento, com uma taxa variável de aplicação de produtos químicos e irrigação, sensores no solo e no meio ambiente, mão-de-obra especializada e sistemas computadorizados para suporte.

FRAISSE (1997) diz que colheitadeiras equipadas com GPS e sensores eletrônicos (Figura 1) são usadas para mapeamento da colheita no campo, permitindo identificar áreas de maior ou menor produtividade. O geo-referenciamento dos pontos de coleta de amostras de solo permite também o mapeamento de variáveis importantes para o processo produtivo, como a disponibilidade de nutrientes, água e PH do solo. Sistemas de informação geo-referenciadas são utilizados para o armazenamento, tratamento, análise e visualização da informação espacial coletada no campo. A análise dos dados permite otimizar o uso de insumos agrícolas e criar mapas de aplicação localizada de insumos que levam em consideração a variabilidade espacial encontrada no campo. Estes, por sua vez, são armazenados em computadores instalados em tratores equipados com GPS e implementos agrícolas que permitem variar a taxa de aplicação de insumos. Desta maneira, pode-se aplicar a quantidade correta de insumos em toda a extensão do campo.

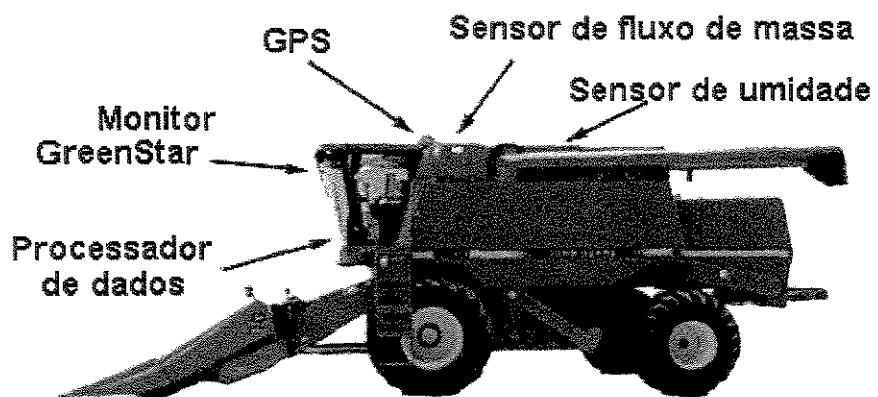


Figura 1 - Máquina colhedora de grãos com equipamentos para mapear rendimento de cultura
Fonte: Adaptado de JOHN DEERE CO (1999)

A agricultura de precisão permite ainda construir bancos de dados espaciais e temporais importantes no desenvolvimento de técnicas visando o uso racional da terra com consequente redução de custos e impactos ambientais. Destacam-se três fases principais para a implementação de um programa de agricultura de precisão:

- Coleta de dados geo-referenciados para a caracterização da variabilidade espacial e temporal dos atributos do solo das áreas cultivadas;
- Tomada de decisões com base na análise e tratamento dos dados obtidos no campo; e
- Aplicação localizada de insumos agrícolas.

BLACKMORE (1994) afirma que esta nova tecnologia não é um sonho, pois é viável economicamente e ambientalmente justificável.

Assim, segundo JOHNSON (1996), a agricultura de precisão encontra o que o solo necessita, aonde ele necessita e aplica a quantidade exata de sementes e a dosagem correta de fertilizantes e outros insumos no local exato. Seu objetivo é gastar menos e uniformizar a

produtividade, o que origina maiores lucros ao produtor. Seu ideal também é a eficiência na produção e conservação do solo.

Antes de se aplicar fertilizantes, pesticidas e outros insumos no solo, deve-se avaliar sua real necessidade. A variabilidade espacial da produtividade de uma cultura pode ser resultado de variabilidade de atributos do solo (composição, excessos e deficiências de nutrientes). A Figura 2 mostra a diferença de composição do solo de uma área agrícola. Diversos são os sistemas de manejo e os equipamentos utilizados, porém, a decisão do método de preparo a ser usado só deve ser tomada após uma análise precisa do tipo de solo e suas deficiências, do clima, do relevo e da espécie vegetal, além de fatores econômicos, tais como verbas limitadas ou inviabilidade de importação de implementos agrícolas especialmente equipados, como a máquina colhedora de grãos da Figura 1. Cabe ao produtor a melhor decisão a tomar.

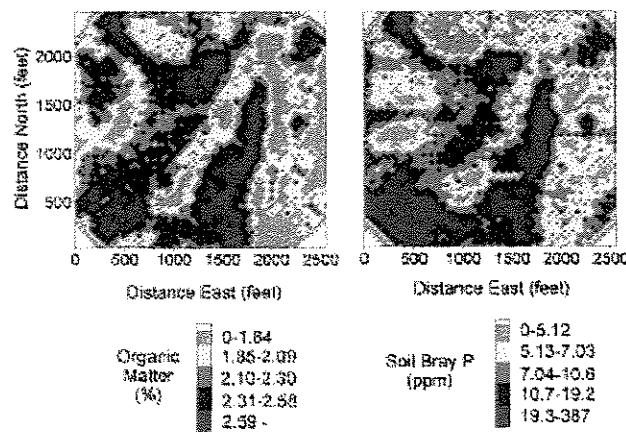


Figura 2 - Mapas de atributos do solo.
Fonte: REICHENBERGER e RUSSNOGLE (1989)

2.2. SISTEMAS DE POSICIONAMENTO GLOBAL (GPS)

Segundo McGRAW (1994), cultivar com o apoio de um mapa é melhor, porque ele considera ao mesmo tempo o tipo de solo e a história da terra.

REICHENBERGER e RUSSNOGLE (1989) relatam que é possível economizar no mínimo US\$ 5,00 por acre (0,4 hectare), quando se mapeia o campo. Mapas para a aplicação de fertilizantes podem variar tanto quanto os tipos de solo, ou ser tão bem distribuídos quanto um tabuleiro de xadrez; sendo que ao mesmo tempo que é possível aumentar a renda com uma aplicação mais eficiente de fertilizante. De acordo com estes autores fazer a calagem e a aplicação de fertilizantes no solo baseado em mapas facilita o trabalho e tem menor custo.

RUNYON (1994) relata que mapas elaborados a partir da utilização de GPS, nos permitem que os produtos químicos sejam aplicados onde realmente são necessários, sendo que o custo extra da produção do mapa é compensado com uma redução dos impactos ambientais. A despesa na coleta e análise de dados torna-se viável com a redução dos custos com produtos químicos.

Para BORGELT et al. (1996) como a estratégia da agricultura de precisão é colocar insumos de maneira variada num campo, o conhecimento preciso da posição dos operadores no campo ou pontos de coleta de dados é fundamental na implementação destes métodos. A maioria das etapas da agricultura de precisão usa a tecnologia GPS para proporcionar estes dados de posição.

FRAISSE (1997) nos diz que uma vez tomada a decisão de se iniciar um programa de agricultura de precisão, um dos primeiros passos é decidir qual a precisão requerida para o GPS. Para o posicionamento das amostras de solo e de dados de produtividade (mapas de colheita),

geralmente aceita-se uma precisão da ordem de 1 a 3 metros. No caso do posicionamento dos tratores usados na aplicação de produtos agroquímicos, é desejável uma maior precisão, evitando-se a dupla aplicação ou a aplicação em locais incorretos.

BECKER e SENFT (1992) relatam que os satélites são a nova chave para ajudar a agricultura, pois a aplicação de fertilizantes, sementes e medições de salinidade do solo, serão guiadas por computadores ligados a Sistemas de Posicionamento Global num futuro bem próximo.

Segundo JOHNSON (1996), o Sistema de Posicionamento Global (GPS) é a chave da tecnologia que faz a Agricultura de Precisão viável. O GPS usa a tecnologia de satélites para determinar uma posição, em latitude, longitude e elevação, em qualquer lugar na superfície da Terra através de um sistema que utiliza vinte e quatro satélites em órbita em torno da Terra.

Para o funcionamento do GPS são necessários no mínimo quatro satélites, pois o receptor pode calcular a distância de um satélite, mas não sua direção e também devido a fatores de elevação alguns sinais podem ser desprezados na localização do ponto exato do receptor. Na verdade os quatro satélites são necessários para se ter quatro equações com quatro incógnitas (latitude (y), longitude (x), elevação (z) e tempo (t)).

O GPS pode obter facilmente, com precisão, a posição com um erro de 10 metros de raio, entretanto, o Departamento de Defesa dos Estados Unidos introduziu propositivamente um erro no sistema, chamado Disponibilidade Seletiva (S.A.), supostamente por motivos de segurança. O erro modifica a precisão do sinal do satélite usando um código exclusivo, deslocando a posição em até 100 metros.

Apesar disso, a precisão pode passar por uma correção, a partir da utilização de 2 aparelhos GPS, um deles em local fixo de posição conhecida, que calcula e computa um fator de

correção (vetor). A correção resultante é armazenada para uso posterior e comparada com os dados do receptor móvel, corrigindo-os. Opcionalmente estas correções podem ser enviadas via rádio, corrigindo os dados do receptor móvel em tempo real. Este tipo de correção baixar o erro para uma faixa de 1 a 5 metros. Este sistema de correção é chamado de correção diferencial (Figura 3).

O erro introduzido pela Disponibilidade Seletiva (S.A.) não é continuamente o mesmo, mudando constantemente, portanto a correção é válida no período máximo de 15 segundos. Sistemas de alta qualidade de tempo real (Figura 4), podem corrigir os dados numa taxa relativamente alta. Alguns sistemas de melhor qualidade usam softwares sofisticados para prever as mudanças nas correções de dados, desde a última correção. Os sistemas de correção em tempo real são utilizados na agricultura de precisão para fornecer a posição da máquina agrícola e ser armazenada por sistemas coletores de dados.

Conceito Simplificado de Correção Diferencial

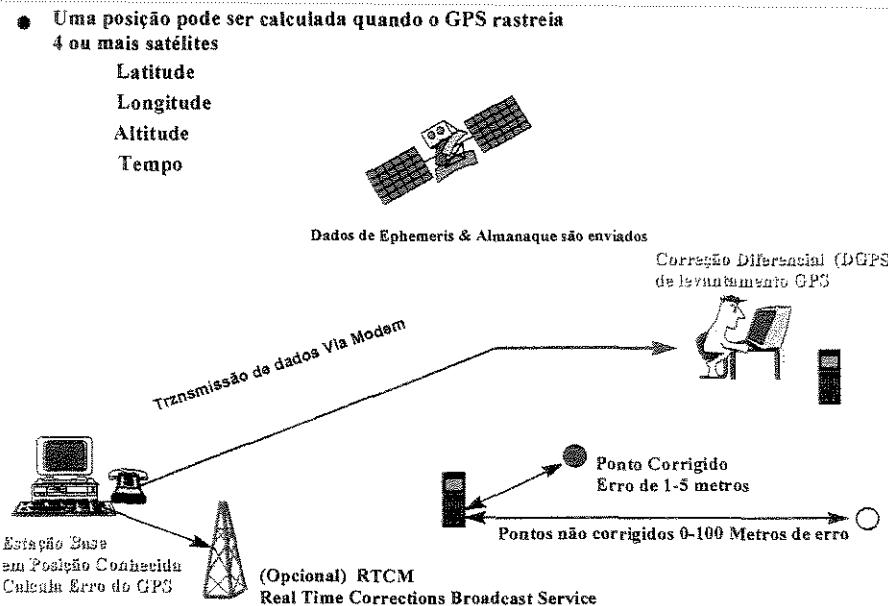


Figura 3 - Sistema de Correção Diferencial de GPS
Fonte: Adaptado de CMT (1996)

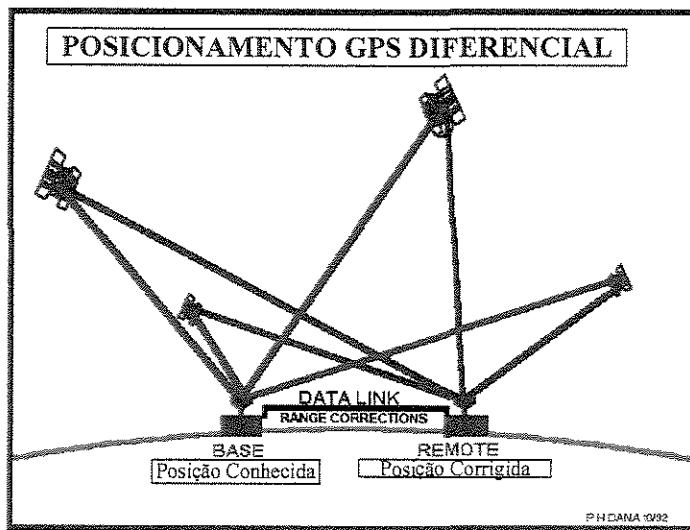


Figura 4 - Sistema de Correção Diferencial em Tempo Real
Fonte: Adaptado de DANA (1999)

Segundo uma pesquisa de FINCK (1996), apenas 19% dos fazendeiros entrevistados utilizam GPS (Sistema de Posicionamento Global), e 48 % dizem que planejam utilizá-lo. Apenas 1% dos entrevistados dizem que não têm planos para utilizar GPS. Metade dos entrevistados têm a intenção de utilizar esta tecnologia nos próximos três anos.

2.3. SISTEMAS DE INFORMAÇÃO GEOGRÁFICA (SIG)

As sociedades estão se tornando mais preocupadas com a necessidade de gerenciar informações de uma perspectiva geográfica. Esta preocupação tem sido trazida pelas tendências do século 20 em direção a uma economia e comunidade global. E com a tecnologia avançada

vem a necessidade de estudos mais próximos das fontes naturais da terra. Os sistemas de informação geográfica proporcionam as ferramentas necessárias para a solução destes desafios.

A tecnologia de gerenciamento de informações geográficas tem um vasto potencial, reconhecido mas não realizado, para solucionar problemas de gerenciamento humanos e ambientais. Ao menos no complexo social, econômico e ambiental mundial já prova ser suscetível à análise e solução.

Para CÂMARA (1994) a principal função de um SIG é armazenar, recuperar e analisar mapas num computador. Explicita as funções de um SIG como sendo:

- Integrar informações espaciais de dados cartográficos, censitários e de cadastramento, imagens de satélite, redes e modelos numéricos de terreno, numa única base de dados;
- Cruzar informações através de algoritmos de manipulação para gerar mapeamentos derivados; e
- Consultar, recuperar, visualizar e permitir saídas gráficas para o conteúdo da base de dados geocodificados.

Uma característica básica num SIG é a de tratar relações espaciais entre objetos cartográficos. Define-se por topologia a estrutura de relacionamentos espaciais que se pode estabelecer entre objetos geográficos. Armazenar a topologia de um mapa é o que difere um SIG de um CAD (*Computer Aided Design*). Outra diferença é que um SIG pode tratar diversas projeções cartográficas.

CUNHA e JAKOB (1994) mostram que a filosofia de um SIG consiste em armazenar e organizar os dados de forma a obter não apenas um mapa *stricto-sensu*, mas sim uma base de dados arranjada, de tal maneira que os dados espaciais e os atributos ligados às localizações

sejam facilmente relacionados. O SIG permite estabelecer uma ‘ligação’ direta e imediata entre um conjunto de dados e sua localização no espaço; sua essência, portanto, consiste na possibilidade de se realizar operações espaciais com as informações disponíveis.

SILVA (no prelo) propõe que um SIG é uma tecnologia que precisa usar o meio digital, deve existir um banco de dados integrado com todos os dados geo-referenciados e o SIG possuir funções de análise desses dados que variem de algébrica cumulativa (operações aritméticas) até algébrica não-cumulativa (operações lógicas), com finalidades específicas.

Isto implica na conversão de uma magnitude de dados e informações significativas. Um grupo de ferramentas básicas necessárias para suportar funções de planejamento inclui as seguintes:

- *Overlay* (sobreposição) gráfico: para produzir uma variedade de mapas;
- *Overlay* topográfico: para integrar dois ou mais arquivos para gerar modelos de ajuste de sítios e outras formas de análise de localização;
- *Geocoding* (relacionamento) de endereços: para atribuir automaticamente um ponto de coordenada ou distrito ao endereço;
- Poligonização: para formar novos distritos de um conjunto de mapas existente; e
- Ajuste relacional: a capacidade de relacionar duas entidades para propósitos funcionais, tais como parcelas para dados tabulares ou de atributos.

STAR e ESTES (1990) avisam que um SIG é um sistema complexo de *hardware* e *software*, e requer um conhecimento considerável numa grande quantidade de áreas geográficas, ciência de computação e engenharia de sistemas.

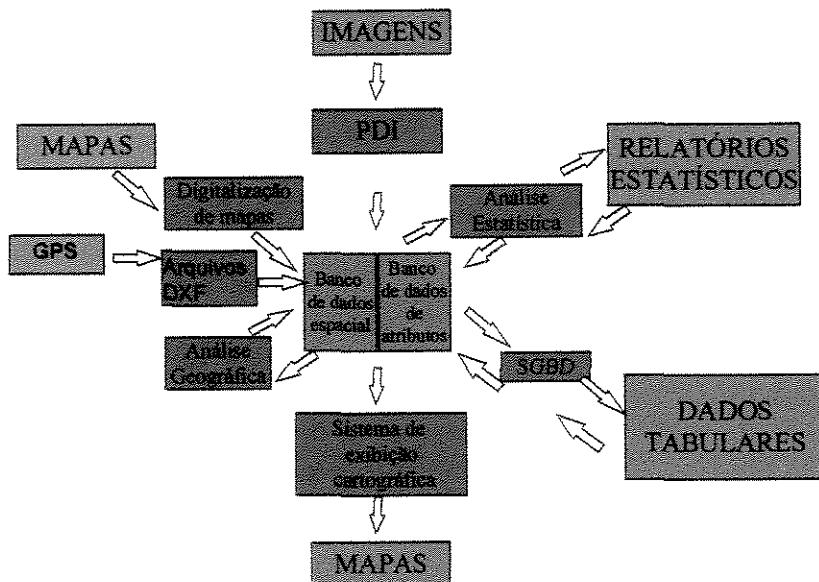


Figura 5: Componentes de um SIG
Fonte: Adaptado de EASTMAN (1992)

A Figura 5 acima mostra os componentes de um SIG vistos de maneira genérica. Imagens de satélite, mapas digitais e GPS são exemplos de entradas de dados, enquanto relatórios estatísticos e dados tabulares podem ser exemplos de entrada de dados, assim como saída de dados; e os mapas temáticos são considerados saídas de dados.

MARBLE et al.¹ (citado por COWEN, 1988) dizem que as aplicações operacionais do SIG incluem áreas como gerenciamento de terras e recursos, planejamento de tráfego, marketing, planejamento militar e uma enorme variedade de outros usos. E a implementação de tais sistemas deve ser conduzida com uma perspectiva de longo prazo.

¹ MARBLE, D.F., et al.. *Geographic Information Systems and Remote Sensing. The manual of Remote Sensing - v. I.* American Society of Photogrammetry, Falls Church, Virginia, p.923-958. 1983

CRAIN e McDONALD² (também citados por COWEN, 1988) sugerem que para que o SIG tenha sucesso ele deve evoluir de uma ferramenta de inventário para uma ferramenta de análise e então finalmente para uma ferramenta de gerenciamento. Muitas vezes os SIG's têm sido chamados de sistemas de suporte de decisões, envolvendo a integração de dados espacialmente referenciados na solução de um problema ambiental.

ABLER (1987) chega ao ponto de dizer que a tecnologia SIG é para a análise geográfica o que o microscópio, o telescópio e os computadores têm sido para as outras ciências.

STEINITZ et al. (1976) falam das vantagens da automação de mapas, sua flexibilidade na análise e a possibilidade de criar um mapa de dados novo e completo a partir de outro e a facilidade na sobreposição de mapas e na atualização de dados.

CALKINS (1975) revela que mapas são ferramentas bem conhecidas e usadas para gravar, recuperar e armazenar dados espaciais. Os mapas devem ter algumas características, tais como:

- devem poder conter grande volume de dados;
- relacionamentos espaciais entre entidades devem ser explicitamente representados na estrutura do mapa;
- dados de atributos associados a entidades espaciais devem ser representados por uma variedade de técnicas, como sombreamento, comprimento de linhas diferentes, símbolos, etc.; e
- mapas devem poder ser usados manualmente.

² CRAIN, I.K. e McDONALD, C.L. *From land inventory to land management: the evolution of an operational GIS, Proceeding, Auto Carto VI*, v.1, p 41-50. 1983

O design e implementação de técnicas de computação para substituir mapas deve considerar adequadamente os itens acima e incluir métodos para acompanhar todos os pontos implícitos nas características dos mapas como os identificados acima.

DANGERMOND (1988) mostra 4 procedimentos básicos para a automação de dados cartográficos: digitalização manual, escaneamento automático, entrada de coordenadas usando geometria de coordenadas e conversão de informação automatizada previamente. A digitalização tem muitas vantagens, como baixo custo e grande flexibilidade e adaptabilidade, e com os modernos *softwares* de checagem de erros a qualidade da informação é bem alta. O escaneamento é mais apropriado para mapas que contenham grandes volumes de dados cartográficos, com mais de 1000 polígonos, e mapas cujas definições de atributos cartográficos requeiram grandes quantidades de coordenadas (x,y), como linhas muito sinuosas. A entrada de coordenadas requer entrada de comandos usando instruções alfanuméricas. Exige um conhecimento exaustivo do sistema, proporciona níveis muito altos de precisão, mas não é muito utilizado. E a conversão de dados, que geralmente é a mais utilizada em virtude da facilidade de trocas de informações cartográficas que são padronizadas para formatos de arquivos conhecidos.

CINTRA (s.d.) define bem a automação de mapas como uma tarefa importantíssima para o desenvolvimento do país, indispensável para projetos e planejamentos, mas o verdadeiramente importante é dominar as técnicas e os conhecimentos básicos necessários para a elaboração de bons projetos. A automação é uma ferramenta útil sempre que não se perca a noção de instrumento. Deve-se salientar que essa é uma área que exige discernimento, critério e capacidade de avaliação, para que a ferramenta não se transforme em brinquedo, e o sonho em pesadelo.

Segundo FERRARI (1997), os benefícios de um SIG são a redução de custos, aumento da receita, melhores decisões, melhores serviços à população, melhor imagem para a organização,

entre outros. Mas dificilmente uma única aplicação irá produzir todos estes resultados positivos. Algumas aplicações podem gerar retorno financeiro; outras não têm retorno financeiro mas melhoram a imagem, e assim por diante. SIG foram inseridos em projetos para reduzir custos, aprimorar decisões, aprimorar serviços à população, etc. Um SIG não resolve nada sozinho: não toma decisões nem reduz custos. SIG viabilizam projetos, facilitam o trabalho, provêem subsídios a decisões. O uso de SIG sim, com propósitos bem definidos, é que gera benefícios. Em um projeto sem metas bem definidas, os benefícios demoram mais a surgir, mais recursos são consumidos e os riscos de interrupção são altos.

O SIG, desta forma, constitui-se num elemento muito importante dentro da agricultura de precisão, pois é dentro do ambiente SIG que serão realizadas toda a manipulação e cruzamento de informações. Os dados das amostras de solo serão interpolados por meio de técnicas de geoestatística neste ambiente SIG, criando mapas de atributos do solo e de produtividade, que podem ser correlacionados por meio de regressões lineares simples e multivariadas com o módulo estatístico de um *software* SIG. Com isto teremos novos mapas indicativos de tratamentos diferenciados de uma área.

2.4. VARIABILIDADE ESPACIAL

Segundo CORÁ e MARQUES JÚNIOR (1998), as áreas de produção agrícola contém um complexo arranjo de solos e paisagens, e uma extensiva variabilidade espacial nas propriedades do solo e na produtividade das culturas é regra, e não uma exceção. Os parâmetros do solo assumem uma relevante contribuição no sucesso da implantação da agricultura de precisão.

Áreas pedologicamente idênticas possuem variabilidade diferenciada quando submetidas a diferentes práticas de manejo (CORÁ, 1997).

Assim, conhecer a variabilidade espacial de atributos ou propriedades do solo que controlam a produtividade de culturas é um fator indispensável na implantação da agricultura de precisão. Para isto, este ítem foi dividido em variabilidade espacial dos atributos do solo, variabilidade espacial do rendimento das culturas, e também uma parte sobre alguns resultados apresentados na literatura.

2.4.1. Variabilidade Espacial dos Atributos do Solo

Para BOUMA (1997), é necessário um menor número de observações para se caracterizar a variabilidade espacial dos atributos dos solos em áreas mais homogêneas. Portanto, o procedimento para o estudo da variabilidade de parâmetros do solo deve partir da identificação de áreas mais homogêneas.

Algumas das mais importantes propriedades que determinam a produção das culturas incluem disponibilidade de água, drenagem, profundidade do *solum*, disponibilidade de nutrientes, textura, teor de matéria orgânica e pH (MULLA e SCHEPERS, 1997).

O manejo pode afetar propriedades químicas, físicas, mineralógicas e biológicas com impacto principalmente nas camadas superficiais do solo. Práticas como aração e gradagem são responsáveis pela alteração e até eliminação da dependência espacial de certas propriedades físicas do solo, como densidade aparente, porosidade e retenção de água. (CORÁ, 1997).

A aplicação de fertilizantes assumindo-se mesmas quantidades aplicadas em todo a área causam variabilidade adicional nos teores dos nutrientes do solo, principalmente para fósforo e potássio (BOUMA e FINKE, 1993).

Para conhecer o comportamento das características da população e descrevê-las, torna-se necessária uma abordagem estatística, onde se procura inferir, a partir de valores amostrais, sobre os parâmetros que caracterizam a sua distribuição de frequência.

2.4.1.1. A Amostragem do Solo

A análise dos dados que retratam a variabilidade espacial do solo depende essencialmente do método de amostragem empregado que, por sua vez, está ligado ao delineamento experimental escolhido e aos objetivos do experimento (CORÁ e MARQUES JÚNIOR, 1998).

Para REICHARD et al. (1986), há duas formas principais de amostragem: a coleta de amostras inteiramente casualizadas, pertencente à estatística clássica, sem levar em conta a posição relativa de cada amostra, onde a variabilidade é descrita pela estimativa da variância e pelo coeficiente de variação; e a coleta de amostras de acordo com um plano espacial determinado, sendo a amostragem segundo transecções em dada direção ou segundo um *grid* em duas direções, mantendo uma regularidade na coleta de amostras por toda a área.

Segundo HAMLETT et al. (1986), as análises estatísticas tradicionais, baseadas na independência das observações, têm sido substituídas por análises espaciais, as quais consideram as correlações entre observações vizinhas. Estas análises são baseadas na teoria das variáveis regionalizadas, base da geoestatística e, como resultado, a variabilidade espacial é caracterizada

através de autocorrelogramas, semivariogramas e métodos de interpolação, como a krigagem, que definem o grau de dependência no espaço da grandeza medida e o alcance ou domínio de cada amostragem medida (VIEIRA et al., 1997).

JOURNEL e HUIJBREGTS (1978) sugeriram pelo menos de 30 a 50 pares de pontos como mínimo para calcular cada classe de distância (*lag*) do variograma, e TRANGMAR et al.(1985) diz que a krigagem fornece a melhor estimativa de um parâmetros locais onde este não foi amostrado, utilizando os parâmetros do semivariograma.

2.4.2. Variabilidade Espacial do Rendimento das Culturas

De acordo com MULLA et al. (1990), a variabilidade espacial dos parâmetros do solo influencia a eficiência do manejo e o desenvolvimento da cultura e também o planejamento e a precisão da pesquisa no campo. A variação em propriedades do solo causa rendimento desuniforme, mesmo em parcelas pequenas, o que pode provocar confundimento de efeitos de tratamentos em investigação agrícola, diminuindo a eficiência da aplicação de fertilizantes em escala de campo.

BHATTI et al. (1991) dizem que o conhecimento da variabilidade dos parâmetros de solo é um importante passo para que se possa empregar um manejo mais adequado com relação à aplicação de fertilizantes, estratégia de amostragem e planejamento de esquema de pesquisa no campo.

Como SALVIANO (1996) diz, poucos trabalhos têm sido conduzidos sobre as relações entre a variabilidade espacial dos parâmetros de solos e a variabilidade dos atributos de produção

das culturas. O autor mostra que a erosão acelerada reduz a produtividade do solo, como consequência das modificações nas características e propriedades do solo, além da redução da profundidade de enraizamento. Diz também que o processo erosivo é muito seletivo, carreando partículas que se apresentam em grandes áreas superficiais específicas, justamente as que retêm maiores quantidades de nutrientes. A matéria orgânica é a fração perdida em maior quantidade.

FINKE e GOENSE (1993) verificaram que a variabilidade de rendimento de cevada poderia ser explicada em parte pela textura e pelo nível inicial de nitrogênio no solo. MILLER et al. (1988), estudando a relação entre propriedades do solo influenciado por erosão e rendimento do trigo, encontrou uma forte dependência espacial entre estes parâmetros.

BHATTI et al. (1991) sugeriram que os parâmetros do solo e o rendimento do trigo não seguiam modelos aleatórios e sim um modelo de dependência espacial. CAMELO et al. (1994) em estudo sobre a variabilidade de fósforo na planta e no solo concluíram que a planta contribuiria para aumentar a variabilidade do solo.

LANGDALE e SCHRADER (1982) dizem que a disponibilidade do nitrogênio está concentrada quase que totalmente na camada de 0 a 30 cm na forma de matéria orgânica, o que acontece também com 50% do fósforo disponível.

2.4.3. Resultados Obtidos na Literatura

POWER et al. (1982) encontraram uma relação direta entre o aumento da espessura da camada superficial e o conteúdo de nitrogênio e de fósforo na planta, resultando numa qualidade superior de produção de trigo.

SESSAY e STOCKING (1995) verificaram que a diminuição da produtividade das culturas estava fortemente associada à redução do horizonte A.

FOLEGATTI (1996) diz que a aplicação dos métodos da estatística clássica pressupõe a distribuição normal dos valores do parâmetro a ser avaliado. NIELSEN et al. (1973) obtiveram distribuição normal para teores de argila, areia, densidade e umidade do solo. Alguns autores, citados por SILVA (1988) confirmam a distribuição normal para dados de densidade do solo, granulometria e teor de água na saturação. Outros citados por SOUZA (1992) têm constatado a adequação da distribuição log-normal para outros parâmetros, como teor de fósforo, pH, carbono orgânico e nitrogênio total. Assim, as distribuições normal e log-normal são comumente usadas para propriedades físicas do solo.

SILVA (1988) coletou amostras segundo um *grid* de 9 X 7 pontos, distanciados entre si de 20 metros. Os semivariogramas construídos para algumas propriedades do solo em sua maioria não mostraram uma estrutura de variância, talvez porque existe estrutura apenas a uma distância menor que o espaçamento (*lag*) adotado, de 20 metros. Para teores de silte e argila, foi encontrada uma estrutura de variância, mas no entanto, não se atingiu um patamar para o semivariograma, devendo-se isto ao fato de que a distância para a qual as variáveis são independentes não foi atingida na amostragem.

VIEIRA et al. (1997) escalonaram os semivariogramas para facilitar suas comparações. A análise desses mostrou que todas as variáveis apresentaram dependência espacial, sendo bastante diferenciada para os resultados de análise granulométrica e com efeito pepita extremamente alto para os parâmetros de permeabilidade do solo, mostrando uma dependência espacial bastante errática em espaçamentos próximos à distância de amostragem. Os teores de carbono e sódio apresentaram forte dependência espacial e os semivariogramas construídos para condutividade

hidráulica mostraram efeito pepita puro, ou seja, variação espacial completamente ao acaso. O modelo esférico foi o de melhor ajuste para os semivariogramas.

2.5. A ESTATÍSTICA NO ESTUDO DA VARIABILIDADE DE SOLOS

AQUINO e DUARTE (1986) citam que a fase mais importante do trabalho científico é a do planejamento. É nesta fase que se deve pensar nas inferências que serão feitas, consultar o estatístico em caso de dúvidas e se conscientizar a respeito do método experimental e da importância de se conduzir bem os trabalhos, para que se atinjam os objetivos pretendidos. A experiência tem mostrado que pouca atenção tem sido dada ao plano experimental. Mas o sucesso de um experimento depende de suas bases e a base de um experimento é o seu projeto.

CLINE (1944) diz que a precisão com que uma amostra de solo representa a população amostrada depende da variabilidade do solo, do número de amostras obtidas e do método de amostragem.

DUNN (1997) mostra a importância da escolha certa do tamanho das células do grid para a amostragem. Cita Don Bullock³, que diz que um grid de 2,5 acres (1 hectare) utilizado em grandes propriedades não funciona bem em solos que variam muito, fazendo com que o mapa criado não tenha correlação estatística com os verdadeiros tipos de solo da área. O que é o mesmo que tirar 20 ou 30 amostras da área e utilizar a média dos dados encontrados.

³ Don Bullock, professor assistente de biometria e agronomia da Universidade de Illinois, EUA

Existem áreas em que 2,5 acres de grid podem ser mapeados, mas há casos em que serão necessários grids de 1 acre (0,4 hectare) para grandes propriedades.

FRAISSE (1997) cita que para pequenas áreas, como a utilizada no experimento, *grids* de 20-30 metros são geralmente muito bons.

2.5.1. A Estatística Clássica ou de Fisher

GARCÍA (1997) resume a estatística clássica como sendo aquela que utiliza a média e o desvio-padrão para representar um conjunto de dados, e baseia-se na hipótese principal de que as variações de um local para outro são aleatórias.

Segundo MORETTIN e BUSSAB (1987), as medidas estatísticas mais utilizadas para expressar a variabilidade de um conjunto de dados são a variância ou desvio-padrão, o coeficiente de variação e a amplitude total, por serem fáceis de se calcular e de se interpretar. Porém, estes indicadores devem ser utilizados com certas restrições.

GUIMARÃES (1993) mostra que a variância só poderá ser usada, isoladamente, se forem comparados grupos de dados que possuam unidades e médias iguais. O coeficiente de variação, que indica o grau de variabilidade do parâmetro, não reflete o seu significado físico, mas é bastante utilizado para comparar propriedades que possuam unidades diferentes. A amplitude total leva em consideração apenas os extremos, sendo portanto pouco utilizada.

SOKAL e ROHLF (1969) afirmam que os valores esperados num ponto são estimados levando-se em conta a média da população e a variabilidade dos valores medidos em torno da

média. Esta estimativa pressupõe que as amostras sejam independentes e que possuam distribuição normal.

HEATH (1981) mostra que se a distribuição de frequência for diferente da normal deve-se realizar uma transformação de dados para a normalização e o uso da estatística clássica. A normalidade dos dados é um pré-requisito básico para o uso da estatística clássica.

Um teste de verificação de normalidade dos dados obtido pelo *software* estatístico SAS é dado pela estatística W, o método de Shapiro-Wilk, apresentado em SHAPIRO e WILK (1965). Este método tem como resultado o valor da estatística W, podendo variar de 0 a 1, e o valor de probabilidade (*p-value*), que descreve quão duvidosa a idéia de normalidade é, também variando de 0 a 1. Valores para W próximos a 1 e *p-values* altos caracterizam uma normalidade. A estatística W e o *p-value* desta devem ser analisados em conjunto.

GUIMARÃES (1993) revela que outro teste de verificação de normalidade dos dados é feito por meio dos coeficientes de assimetria e curtose. Assimetria é o grau de desvio ou afastamento da simetria de uma distribuição, que pode ser dada pelo 1º coeficiente de Pearson:

$$C_s = \frac{\bar{X} - M_0}{s} \quad , \text{ onde:}$$

“ C_s ” é o coeficiente de assimetria;

“ \bar{X} ” é a estimativa da média populacional;

“ M_0 ” é a moda; e

“s” é a estimativa do desvio-padrão populacional.

Os *Softwares* em geral utilizam outra fórmula para o cálculo da assimetria, dada por:

$$a_3 = \frac{M_3}{s_3} \quad , \text{ onde:}$$

“ a_3 ” é o índice de assimetria;

“ M_3 ” é o momento de 3^a ordem, dado por: $\frac{\sum_{i=1}^n (X_i - \bar{X})^3}{n}$; e

“ s_3 ” é a estimativa do desvio-padrão populacional elevada ao cubo.

A curtose mede o grau de achatamento de uma curva em relação à distribuição normal, e é dada por:

$$c_r = \frac{M_4}{s_4^4} \quad , \text{ onde:}$$

“ c_r ” é o coeficiente de curtose;

“ M_4 ” é o momento de 4^a ordem, dado por: $\frac{\sum_{i=1}^n (X_i - \bar{X})^4}{n}$; e

“ s_4 ” é o quadrado da variância.

Os valores de $c_s = 0$ e $c_r = 3$ caracterizam uma normalidade dos dados.

No SAS, os coeficientes de assimetria e curtose próximos a ‘0’ aproximam a distribuição da Normal Padrão.

As estimativas da média e do desvio-padrão são dadas por:

$$\bar{X} = \frac{\sum X_i}{n} \quad s = \sqrt{\frac{\sum (X_i - \bar{X})^2}{n-1}}$$

A amplitude total é igual a: $R = X_{\max} (\text{valor máximo}) - X_{\min} (\text{valor mínimo})$

A variância é dada por: $s^2 = \frac{\sum (X_i - \bar{X})^2}{n-1}$

e o coeficiente de variação por: $CV = \frac{s}{\bar{X}}$; onde:

- “ \bar{X} ” é a média amostral;
- “ X_i ” é a i-ésima observação amostral;
- “s” é o desvio-padrão; e
- “n” é o tamanho da amostra.

2.5.1.1. A Análise Exploratória de Dados

GARCÍA (1997) cita duas técnicas utilizadas na análise exploratória de dados: o dispositivo de ramo e folhas e o gráfico de boxplot. O ramo e folhas nos possibilita ver quanto o grupo está próximo da simetria, como estão distribuídos os valores, se estão distanciados demais e se existe concentração dos dados ou lacunas. Ele é similar a um histograma na apresentação dos dados, e os *outliers* são imediatamente localizados.

Outliers são dados que estão afastados demais do conjunto de dados, são os pontos extremos. O boxplot é um gráfico construído desenhando-se uma caixa com extremidades nos quartos inferior e superior e com uma barra na mediana. Em seguida, traça-se uma linha até os pontos mais afastados, que são os *outliers*, os quais são representados individualmente por pontos situados além dos limites críticos para dados periféricos. Cada boxplot nos dá a mediana, a dispersão dos dados, a assimetria, a distribuição e os *outliers*.

Na distribuição dos quartos ou quartis, usada para a criação do boxplot, temos o valor do 1º quartil, que corresponde ao ponto onde estão até 25% dos dados, o 2º quartil ou mediana, com 50% dos dados e o 3º quartil, com 75% dos valores. A amplitude quartílica dos dados é definida como sendo o valor do 3º quartil menos o valor do 1º quartil, e os valores que estão abaixo do 1º

quartil menos 3/2 da amplitude quartílica ou acima do 3º quartil mais 3/2 da amplitude serão os *outliers*.

EMERSON e STRENIO (1983) mencionam que o valor 3/2 é meio arbitrário, mas se tem mostrado utilizável para a identificação dos *outliers*.

GUIMARÃES (1993) cita que a estatística clássica não permite testar a independência entre as amostras; portanto, ao se aplicar esta estatística está se assumindo independência entre amostras sem testar. Embora existam alguns testes não-paramétricos de independência amostral, estes quase não são utilizados.

A quantificação de características e propriedades do solo são influenciadas pela variabilidade espacial. Assim, existe uma certa dependência entre amostras e uma média simples não é representativa da área de estudo. Neste caso, é mais indicado o uso de estimativas que levem em consideração a posição espacial dos valores amostrados.

2.5.2. A Teoria das Variáveis Regionalizadas ou Geoestatística

Os métodos geoestatísticos conseguem integrar o aspecto espacial ou topológico com o aspecto aleatório ou probabilístico. Estes métodos levam em consideração a distribuição espacial das medidas, permitindo definir a correlação espacial entre as amostras. Se baseiam na teoria das variáveis regionalizadas, a partir da qual é possível estudar a estrutura espacial.

De acordo com MULLA (1997), após a coleta das amostras do solo e sua análise para determinadas propriedades, seus resultados são interpolados para as localidades que não foram amostradas por técnicas de geoestatística, e os valores interpolados são classificados usando

sistemas de informação geográfica para um número limitado de zonas de gerenciamento. Os contornos destas zonas são então visualizados por meio de um *software* de mapeamento, e as recomendações são firmadas para cada zona. As recomendações de gerenciamento e os limites das zonas são então armazenados num chip de computador colocado num trator, plantadeira ou adubadeira capaz de mudar as aplicações de acordo com a localização no campo e nos limites das zonas.

Segundo MATHERON (1963), a Geoestatística é uma função que varia de um lugar a outro no espaço com certa aparência de continuidade. São variáveis cujos valores estão relacionados com a posição espacial que ocupam, e já que podem tomar valores diferentes em diferentes lugares de observações demonstram uma certa independência de um lugar a outro.

FANHA (1994) diz que as variáveis regionalizadas têm características qualitativas, tais como: localização, continuidade e anisotropia que estão ligadas ao fenômeno natural que elas representam. A variável regionalizada atua num espaço geométrico em que foi definida e onde será estudada sua variação.

Na teoria das variáveis regionalizadas, as duas funções mais utilizadas para a determinação da dependência espacial ou temporal de variáveis são a autocorrelação e a semivariância.

2.5.2.1. O Autocorrelograma

VAUCLIN et al. (1982) definem a função autocorrelação como sendo a covariância entre valores amostrados em relação à variância populacional:

$$\rho(h) = \frac{\text{cov}(Z(x), Z(x+h))}{\sigma^2}, \text{ estimada por: } r(h) = \frac{\frac{(n-h)((\sum Z_i Z_{i+h}) - (\sum Z_i \sum Z_{i+h}))}{(n-h)(n-h-1)}}{s^2},$$

onde:

“h” é a distância entre amostras;
 “ Z_i ” é o valor da i -ésima observação da amostra;
 “n” é o número de observações; e
 “ s^2 ” é a estimativa da variância populacional.

O uso da autocorrelação no estudo da dependência espacial ou temporal de uma variável aleatória só é válido se a hipótese de estacionaridade de 2^a ordem for atendida, ou seja, a esperança da variável aleatória tem que ser igual à média e sua variância tem que ser finita.

2.5.2.2. O Variograma

FANHA (1994) define o variograma como a medida do grau de dissimilaridade das amostras na proporção em que a distância entre as observações aumenta. O variograma é portanto uma função que expressa a variabilidade de uma dada propriedade entre dois pontos separados por uma distância “h”, em função desta distância “h”.

A função variograma é definida como a variância do incremento $[Z(x_i) - Z(x_{i+h})]$, ou seja:

$2\gamma(x_i, x_{i+h}) = \text{var} [Z(x_i) - Z(x_{i+h})]$, e denominamos $\gamma(x_i, x_{i+h})$ de semivariograma ou semivariância.

Uma outra maneira de definir o variograma é dada por:

$$2\gamma(h) = \frac{1}{n(h)} \sum_{i=1}^{n(h)} [Z(x_i) - Z(x_{i+h})]^2, \text{ onde:}$$

“ $Z(x_i)$ ” é o valor da variável no ponto x_i ;

“ $Z(x_{i+h})$ ” é o valor da variável no ponto x_{i+h} ; e

“ $n(h)$ ” é o número de pares de pontos separados por uma distância h .

Para GUIMARÃES (1994), o semivariograma tradicional ou direto é a ferramenta básica da geoestatística e permite quantificar a continuidade espacial de variáveis regionalizadas. Representa uma variável calculada para várias distâncias e é seu comportamento que irá descrever o padrão de continuidade do fenômeno.

Segundo BRAGA (1990), a principal vantagem do variograma em relação ao autocorrelograma é a não necessidade do conhecimento de esperança da função aleatória $Z(x)$ para o conhecimento da semivariância (γ).

Por isso é muito mais comum o uso do variograma do que o uso do autocorrelograma. Podemos até dizer que a determinação do variograma é o primeiro passo no procedimento de uma estimativa através da geoestatística. E pode ser considerado como o passo mais importante, porque o modelo variográfico escolhido será utilizado através de todo o processo de estimação e influirá em todos os resultados e análises.

Em condições de distância zero entre amostras, a semivariância é zero, e cresce com o aumento da distância entre amostras, até atingir um patamar, permanecendo constante a partir deste ponto. Os parâmetros que descrevem um variograma são os seguintes:

Alcance: é a distância a partir da qual as amostras se tornam espacialmente independentes;

Patamar: é o valor do variograma correspondente ao alcance. Reflete a dispersão própria (variância) da variável para distâncias superiores ao alcance ($C = C_1 + C_0$).

Efeito pepita: é o ponto onde o variograma corta o eixo das ordenadas. Reflete microestruturas ou variabilidades de pequena escala não captadas pela amostragem. Reflete também erros relacionados à amostragem do fenômeno. Quando o efeito pepita relativo ($\varepsilon = C_0 / C$) é menor do que 0,15 a componente aleatória do fenômeno é pequena, ou seja, um valor de ε menor do que 0,15 equivale a dizer que a amostragem tem alta representatividade (ROYLE, 1979).

O ajuste do modelo de variograma aos dados experimentais é um procedimento de grande importância quando se deseja fazer interpolações na área de estudo. Vários modelos são propostos para estes ajustes. Os mais comuns são:

- Modelo Linear: $\gamma(h) = C_0 + C \cdot h$;

- Modelo Esférico: $\gamma(h) = C_0 + C \cdot \left(1,5 \left(\frac{h}{a} \right) - 0,5 \left(\frac{h^3}{a^3} \right) \right)$, $0 \leq h \leq a$

$$\gamma(h) = C_0 + C \quad , \quad h > a$$

- Modelo Exponencial: $\gamma(h) = C_0 + C \cdot \left(1 - \exp\left(\frac{-3 \cdot h}{a}\right) \right)$;

- Modelo de Gauss: $\gamma(h) = C_0 + C \cdot \left(1 - \exp\left(\frac{-(3h^2)}{a^2}\right) \right)$; onde:

“ C_0 ” é o efeito pepita;

“ $C + C_0$ ” é o patamar;

“ a ” é o alcance da dependência espacial; e

“ h ” é a distância entre amostras.

O escalonamento é uma técnica adotada para uma generalização de parâmetros e é realizado através de fatores de escala. Os variogramas podem ser escalonados se existir uma proporcionalidade entre as médias e as variâncias dos grupos de dados, ou seja, se com o aumento do valor médio ocorrer um aumento da variância dos dados. Este escalonamento pode ser feito utilizando-se a variância dos dados como fator de escala, sendo que cada $\gamma(h)$ é dividido por s^2 (GUIMARÃES, 1993; VIEIRA et al., 1997).

A função semivariância assume um papel importante na interpolação de valores através da técnica da Krigagem, que leva a erros mínimos na interpolação.

2.5.2.3. A Krigagem

O termo *Krigagem* vem do nome de K.G.Krige, um especialista em mineração que introduziu em 1951 o uso de tal procedimento em reservas minerais. O desenvolvimento formal da teoria deve-se a MATHERON (1963), para o qual a krigagem é um processo de obtenção do melhor preditor linear não viciado de uma variável desconhecida. Leva em consideração o número de dados e a qualidade destes em cada ponto, a posição dos dados com relação ao campo, a continuidade espacial das variáveis interpoladas e a distância entre os pontos e a área de interesse. Com base em tais observações, constrói-se a melhor função de predição não viciada para cada ponto não observado.

Suponhamos que $\{Z(x), x \in \mathbb{R}^p\}$ seja um processo estacionário intrínseco e isotrópico⁴.

Para ‘n’ pontos x_1, x_2, \dots, x_n , observa-se o valor de $Z(x)$, obtendo-se $z(x_1), z(x_2), \dots, z(x_n)$.

O preditor de krigagem de $Z(x_0)$ é dado por: $Z^*(x_0) = \sum_{\alpha=1}^n \lambda_\alpha Z(x_\alpha) = \lambda' \cdot \tilde{Z}(x)$, onde

$\lambda' = (\lambda_1, \lambda_2, \dots, \lambda_n)$ é tal que $Z^*(x_0)$:

- seja não viciado: $E[Z^*(x_0) - Z(x_0)] = 0$; e
- tenha Erro Quadrático Médio mínimo dentre todas as combinações lineares não viciadas de $Z(x)$.

2.5.2.3.1. Krigagem Simples

Na krigagem simples, o estimador linear é dado por:

$$Z_{ks}^*(x) = \sum_{\alpha=1}^n \lambda_\alpha Z(x_\alpha) + \left(1 - \sum_{\alpha=1}^n \lambda_\alpha\right) \bar{X} \quad ; \quad \text{“}\bar{X}\text{” é a média do modelo da função aleatória}$$

$Z(x)$.

Os pesos “ λ_α ” são determinados para minimizar a variância do erro, também chamada de variância de estimação. A variância da krigagem é dada por:

$$s_{ks}^2 = \text{cov}(0) - \sum_{\alpha=1}^n \lambda_\alpha \cdot \text{cov}(x - x_\alpha) \geq 0 \quad (\text{REMACRE, 1995})$$

⁴ Se $2\gamma(x_i, x_k)$ for uma função apenas da distância entre as localizações, isto é, $\|x_i - x_k\|$; $\forall x_i, x_k \in \mathbb{R}^p$.

2.5.2.3.2. Krigagem Ordinária

Na krigagem ordinária, que é a variação da krigagem simples mais utilizada, exigimos que a soma dos pesos, $\sum_{\alpha=1}^n \lambda_{\alpha}$ seja igual a “1”.

O estimador é dado por: $Z_{ko}^*(x) = \sum_{\alpha=1}^n \lambda_{\alpha} Z(x_{\alpha})$, que não requer o conhecimento da média estacionária \bar{X} .

A variância é definida como:

$$s_{ko}^2 = 2 \cdot \sum_{\alpha=1}^n \lambda_{\alpha} \cdot \gamma(x_0, x_{\alpha}) - \gamma(x_0, x_0) - \sum_{\alpha=1}^n \sum_{\beta=1}^n \lambda_{\alpha} \lambda_{\beta} \cdot \gamma(x_{\alpha}, x_{\beta}) \quad (\text{BRAGA, 1990})$$

A krigagem, além de ser um estimador não tendencioso, é um interpolador exato, ou seja, se o ponto a ser estimado coincidir com um dos pontos amostrados, o valor estimado será igual ao valor amostrado.

Finalizamos citando VIEIRA et al. (1997), para quem a krigagem é um processo de interpolação que estima valores de propriedades medidas em locais não amostrados, sem tendência e com variância mínima, podendo expressar os resultados em forma de mapas de isolinhas ou de superfície tridimensional. O valor da variável espacial num local não amostrado é estimado por combinação linear de valores medidos em outros locais, levando-se em conta o conhecimento espacial da variável, expressa pelo semivariograma e os locais dos valores

conhecidos. Pontos perto dos locais não amostrados têm maior peso do que pontos afastados e pontos agrupados levam mais peso do que pontos isolados.

E para CRESSIE (1993), a avaliação da krigagem é realizada utilizando-se a metodologia conhecida como validação cruzada, que consiste em estimar os valores da variável em estudo sobre os mesmos pontos amostrados e comparar os novos valores com os dados medidos.

2.6. OS NUTRIENTES DA CULTURA

2.6.1. Elementos Essenciais

Os elementos essenciais às plantas em geral são divididos em três grupos: os macronutrientes, os micronutrientes e os elementos acessórios.

Os macronutrientes são os mais vitais para a planta, os micronutrientes são tão essenciais quanto os macronutrientes, mas são absorvidos em quantidades muito pequenas, e os elementos acessórios desempenham também papéis de importância, mas não vitais para a planta. Estão neste grupo o Alumínio, Sódio, Cobalto, Chumbo, Prata, entre outros. (MALAVOLTA et al., 1974)

As análises laboratoriais de fertilidade mais comuns tratam apenas dos macro e micronutrientes, além de algumas variáveis derivadas destas, como a CTC (Capacidade de Troca de Cátions), a Soma de Bases e a Saturação por Bases, além dos índices de pH e de Matéria Orgânica. Portanto não foi tratado dos elementos acessórios, com a exceção do Alumínio no índice H+Al.

2.6.2. Os Macronutrientes

Fazem parte dos macronutrientes o Nitrogênio, Fósforo, Potássio, Cálcio, Magnésio e o índice H+Al. Não foi feito uso do Nitrogênio em virtude de este não fazer parte da análise de fertilidade.

2.6.2.1. Fósforo

Este elemento toma parte na estrutura química de compostos essenciais ao metabolismo vegetal, como ácidos nucleicos, fosfolipídeos, coenzimas e o trifosfato de adenosina, que é essencial para os processos de transferência de energia no metabolismo das plantas. O fósforo apresenta-se em maiores porcentagens nas sementes e nos frutos, sendo as folhas mais pobres neste elemento (ANDA, 1971).

O fósforo é o menos absorvido dos elementos nobres, sendo, entretanto, grandemente exigido na época do florescimento. O papel do fósforo na semente deve estar ligado ao metabolismo do amido e da matéria graxa, compostos que se acumulam e sofrem armazenamento nos grãos de milho. Está definitivamente acertado que o fósforo faz parte de compostos existentes nas células e que é necessário para a divisão celular da qual resulta o crescimento das plantas. Acha-se concentrado nos órgãos de crescimento, bem como toma parte na formação da espiga (MALAVOLTA et al., 1974).

No milho, a deficiência de fósforo origina folhas roxas no início do crescimento, maturidade atrasada e espigas pequenas com a ponta sem grãos e encurvada (MALAVOLTA, 1959).

2.6.2.2. Potássio

O Potássio está intimamente relacionado à produção de açúcar, amido, celulose e proteína nas plantas, sem, entretanto, fazer parte da constituição química dos mesmos. No milho, constitui-se elemento de grande importância, já que há apreciável armazenamento desses constituintes nos grãos (MALAVOLTA et al., 1974).

A deficiência de potássio no milho é percebida através de folhas amarelas, com as margens e as pontas queimadas, internódios curtos, pouca resistência ao acamamento, espigas sem grãos na ponta e grãos que se desprendem facilmente do sabugo (MALAVOLTA, 1959).

Um suprimento inadequado de potássio pode causar também a acumulação de ferro nos nós dos colmos de milho, o que provocaria a interrupção na translocação de materiais da folha para a raiz, tornando esta última enfraquecida e predisposta a acamamento devido a danos causados por ataque de fungos do solo (MALAVOLTA et al., 1974).

2.6.2.3. Cálcio

O cálcio é absorvido pelo milho logo após o aparecimento da radicula até por ocasião de sua polinização, mais ou menos aos 90 dias, quando alcança a totalidade exigida pela planta.

Passado este período, o vegetal não mais absorve cálcio até os 120 dias. A concentração do elemento é maior nas folhas e, dentre estas, é mais elevada nas mais velhas. Possui também certa importância na translocação do material elaborado na planta e na disponibilidade fisiológica de outros nutrientes; atua como agente neutralizante, prevenindo acúmulo de material tóxico nos tecidos (MALAVOLTA et al., 1974).

A falta de cálcio no milho faz com que as pontas das folhas mais internas, ao se desenvolver, grudem umas nas outras (MALAVOLTA, 1959), cria também atraso na emergência das folhas primárias e deterioração da brotação terminal (OLIVEIRA et al., 1991), afeta o crescimento do caule, ramos, folhas e as extremidades das raízes, retardando ou mesmo paralisando seu crescimento (ANDA, 1971).

2.6.2.4. Magnésio

O magnésio toma parte na composição química da clorofila, que é indispensável ao processo de fotossíntese. Este elemento funciona ainda como ativador de várias enzimas relacionadas com o metabolismo dos carboidratos e outras envolvidas na síntese dos ácidos nucleicos (ANDA, 1971).

Acha-se em maior concentração nas folhas, sendo, no entanto, no final do ciclo, encontrado em cerca de um terço do total absorvido, nos grãos do milho (MALAVOLTA et al., 1974).

Sua carência causa um aparecimento de estrias verdes e amareladas no sentido longitudinal das folhas mais velhas, e as áreas claras entram em necrose (MALAVOLTA, 1959).

Os casos de deficiência de magnésio estão, em geral, ligados à acidez do solo ou à correção da acidez feita através de corretivos calcíticos, em vez de corretivos magnesianos ou dolomíticos (MALAVOLTA et al., 1974).

2.6.2.5. Alumínio

O alumínio quando se encontra em excesso no solo, pode ocasionar toxidez no milho. Um teor maior do que 1 p.p.m. (parte por milhão) de Al^{+3} no solo prejudica o crescimento do milho. Aparece, em geral, em quantidades maiores quando em solos muito ácidos (acidez < 5,5) (MALAVOLTA et al., 1974).

2.6.3. Os Micronutrientes

Fazem parte dos micronutrientes o Boro, Cobre, Ferro, Manganês e Zinco.

2.6.3.1. Boro

Há indicações de que o Boro esteja ligado ao transporte de carboidratos no interior da planta, pois sua deficiência ocasiona um retardamento nesse processo ou mesmo sua paralisação, razão da morte de alguns tecidos, observada nos casos de grave deficiência (ANDA, 1971).

O milho absorve muito pouco boro, tornando sua deficiência muito rara (MALAVOLTA et al., 1974). A deficiência manifesta-se por meio de estrias aquosas, transparentes, alongadas nas folhas novas; estrias que secam e depois ficam brancas, ocasionam morte do broto terminal, muito comum à esterilidade, e quando os grãos chegam a se formar, aparecem áreas pardas na base dos mesmos (MALAVOLTA, 1959).

2.6.3.2. Cobre

O cobre desempenha no vegetal um importante papel ligado às atividades enzimáticas e em certos processos de oxidação e redução nele existentes. Apesar de exigido em quantidades muito pequenas, sua falta pode provocar na planta dificuldade no aproveitamento de macro e micronutrientes diversos (MALAVOLTA et al., 1974).

O primeiro sintoma de deficiência de cobre é uma coloração verde-escura anormal das folhas, indicando alto teor de nitrogênio. Podem também aparecer clorose e necrose nas pontas das folhas novas, que evoluem ao longo das margens (ANDA, 1971).

2.6.3.3. Ferro

O ferro, como micronutriente, é requerido em quantidades bem menores do que os macronutrientes, muito embora seja tão essencial para o desenvolvimento normal do milho quanto aqueles. É encontrado no milho acumulado nos tecidos dos nós do colmo durante o crescimento. A acumulação de ferro seria devido ao apodrecimento da parte da raiz que causa

paralização da translocação de carboidratos das folhas para as raízes (MALAVOLTA et al., 1974).

No milho, a deficiência de ferro faz aparecerem estrias cloróticas nas folhas alternadas com faixas verdes, as folhas novas ficam brancas enquanto as médias estriadas e as mais velhas permanecem verdes (MALAVOLTA, 1959).

2.6.3.4. Manganês

O manganês está ligado principalmente aos processos de respiração e do metabolismo do nitrogênio, onde funciona como ativador de enzimas.

A deficiência de manganês caracteriza-se em geral por uma clorose malhada, irregular que se apresenta nos espaços compreendidos entre as nervuras das folhas. Na maioria das plantas esses sintomas se apresentam primeiro nas folhas mais novas, mas não se restringe tanto a essas (ANDA, 1971).

2.6.3.5. Zinco

Funciona como ativador de várias enzimas e parece tomar parte no processo de síntese do ácido indol-acético (ANDA, 1971).

É um micronutriente muito exigido pelo milho. A falta de zinco no milho provoca uma série de deficiências, manifestando-se, em parte, como sintoma foliar na forma de uma clorose.

Essa carência aparece, em geral, em solos alcalinos ou solos que receberam pesadas adições de calcário, podendo, entretanto, ocorrer em solos ácidos e pobres (MALAVOLTA et al., 1974).

Constata-se a deficiência de zinco no milho alguns dias após a emergência, quando a Segunda folha começa a mostrar estrias amareladas; à medida em que a planta envelhece a clorose se torna internerval; as pontas, as margens e a bainha das folhas velhas começam a mostrar uma tonalidade arroxeadas, e há uma acentuada redução no desenvolvimento das plantas (MALAVOLTA, 1959).

2.7. O LATOSOLO ROXO

Segundo OLIVEIRA et al. (1992), essa classe é formada por solos minerais não hidromórficos, vermelho-escuros de tonalidades arroxeadas, derivados de rochas básicas e tufitos, apresentando horizonte B latossólico e teores consideravelmente elevados de Fe_2O_3 ($> 18\%$ e $< 40\%$) e MnO , com atração magnética forte e predominantemente de textura argilosa ou muito argilosa.

Apresentam sequência A-Bw-C de costumeira modesta diferenciação. A cor típica do horizonte B é bruno-avermelhado-escura. Apresentam quando secos forte atração pelo ímã. São solos bastante porosos, sendo comum porosidade total da ordem de 50%. Em áreas intensamente mecanizadas, é frequente a formação de camada adensada a 20-30cm, dificultando o enraizamento das plantas e a penetração de água da chuva ou da irrigação.

Devido aos altos teores de óxidos, normalmente de ferro, esses solos podem apresentar, nas camadas subsuperficiais, onde a matéria orgânica é baixa, predominância das cargas positivas

sobre as negativas, ocasionando baixíssimos valores de capacidade efetiva de troca de cátions. Esses solos, denominados latossolos roxos ácricos, têm comportamento bem diverso dos restantes por reterem muito pouco as bases (cálcio, magnésio e potássio) e adsorverem bastante os fosfatos e nitratos.

Em São Paulo, os solos derivados das rochas efusivas básicas, como os latossolos roxos, são os que apresentam os teores mais elevados em micronutrientes: zinco, cobre, molibdênio e manganês.

A classe latossolo roxo é formada por solos de grande significado agrícola: situados em relevo normalmente suave onulado, com declividade que raramente ultrapassa 7%, são profundos, porosos, bem permeáveis mesmo quando muito argilosos, friáveis, de fácil preparo.

Os eutróficos, especialmente os que têm soma de bases relativamente elevada, pelo menos nos 100 cm superiores, são muito férteis e dos melhores solos brasileiros. Os distróficos, e mesmo os álicos, respondem bem às aplicações adequadas de fertilizantes e corretivos, dando também boas produções. Os ácricos, devido a apresentarem no horizonte B maior capacidade de reter ânions do que cátions, requerem manejo específico. A perda por lixiviação de cálcio, magnésio e potássio neles é grande, devido à pequena capacidade de retenção.

A grande quantidade de óxidos de ferro, ou de ferro e alumínio e a textura argilosa favorecem a adsorção de fósforo, requerendo doses relativamente maiores desse elemento do que outros solos com mineralogia e textura diferentes. Apresentam também boa resistência à erosão, mas requerem, contudo, tratos convencionais adequados conforme o declive do terreno e o uso.

III - MATERIAL E MÉTODOS

3.1. CARACTERIZAÇÃO DA ÁREA DE ESTUDO

O experimento foi conduzido no Centro Pluridisciplinar de Química, Biologia e Agricultura (CPQBA) da UNICAMP, situado no distrito de Betel, próximo a Paulínia (SP), situado entre as coordenadas UTM (Zona 23) 283.264 W, 7.477.255 S e 283.684 W, 7.477.576 S.

A área de aproximadamente 4 hectares, mede cerca de 100 metros de largura por 400 metros de comprimento (Figura 6). A área útil considerada para as correlações foi a delimitada pelo *grid* de amostragem. Foi detectada erosão nas colunas 15 e 16 do *grid* de amostragem.

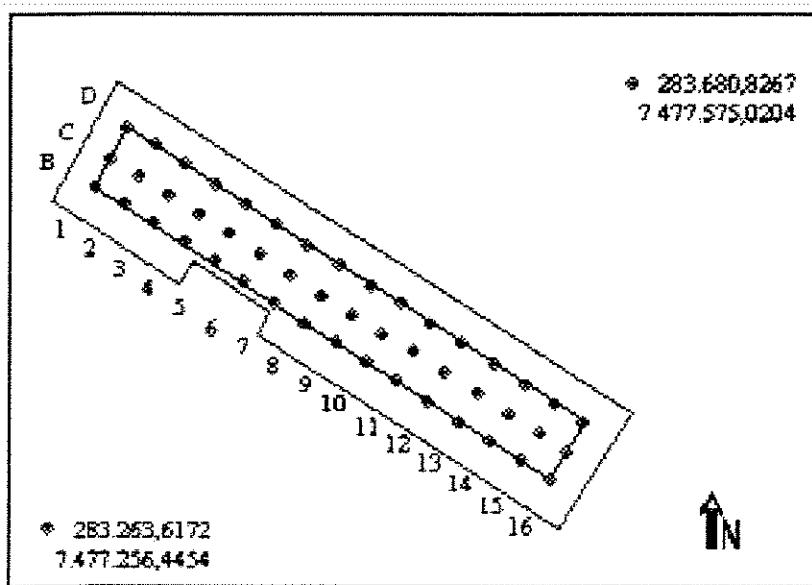


Figura 6: Mapa da área de estudo com pontos de coleta e coordenadas UTM.

O solo foi classificado como Latossolo Roxo. Este solo pertence à classe dos latossolos roxos, podendo ser comprovado a partir dos dados das análises granulométrica e de fertilidade. É um solo argiloso, apresentando uma média de argila de 53,7%, com teor de ferro alto (média de 21,06 mg/dm³), possui argila de atividade baixa, com CTC < 24meq/100g, que na média deu 9,95 meq/100cm³, e altos níveis de manganês (média de 29,55 mg/dm³). São também considerados solos eutróficos, com um índice de saturação por bases (V%) maior ou igual a 50% (média de 50,14%).

3.2. TRATOS CULTURAIS

Anteriormente a este trabalho, parte da área era usada para o plantio de café, e a maior parte não era aproveitada para nenhum tipo de cultivo. Havendo uma área ocupada por mucuna, que servia para adubo verde e alguma infestação de ervas-daninhas (especialmente do tipo braquiária), a área foi roçada e, posteriormente, foi feita também a aplicação de calcário dolomítico para a correção da acidez do solo.

A cultura cultivada na área foi a de milho, com sementes híbridas simples modificadas, Dinamilho nº 657, com ciclo precoce de 841 U.C., grão semi-duro alaranjado, altura de 2,30m e altura da espiga de 1,53m. A semeadura foi feita em janeiro de 1998 com um espaçamento de 0,90 metros entre as fileiras.

Uma primeira camada de adubo, calculada a partir de uma amostra composta de solo, foi colocada durante o plantio, com uma plantadeira e adubadeira. Em fevereiro de 1998 foi aplicado

adubo nitrogenado de cobertura numa razão de 38 gramas por metro linear utilizando-se adubadeiras manuais.

Após o plantio foi aplicado um herbicida de cobertura para controlar a presença de ervas-daninhas na área, assim como foi feito o controle de formigas por meio de aplicações de formicida com bomba manual. O alto índice de precipitação do mês de fevereiro de 1998 (283mm, quando a média é 190mm) colaborou com o controle de lagartas.

3.3. ESQUEMA EXPERIMENTAL DE AMOSTRAGEM DO SOLO

No campo experimental foi feito um grid com células quadradas de 25 metros de lado, com 4 linhas (denominadas A, B, C e D) e 16 colunas (numeradas de 1 a 16), totalizando 64 pontos de amostra (Figura 6).

A primeira linha do grid (linha A) foi desprezada por estar muito próxima à rua de acesso, havendo assim muita influência de fatores externos no solo, inclusive grande compactação. A área utilizada para o trabalho foi a demarcada pelo retângulo formado pelo *grid* de amostragem apresentado na Figura 6.

Em cada posição retiramos amostras de solo a 0,20 metros e a 0,40 metros de profundidade, perfazendo um total de 96 amostras.

O grid foi devidamente marcado com marcos indicativos e a área foi geo-referenciada por meio de GPS da marca TRIMBLE e com uma estação base na Faculdade de Engenharia Agrícola (FEAGRI/UNICAMP) para a correção diferencial das posições.

3.4. ATRIBUTOS DO SOLO

3.4.1. Análise Granulométrica

As 96 amostras foram coletadas antes da semeadura da cultura e num clima e solo bastante úmidos na ocasião. A análise foi feita utilizando-se o laboratório do Departamento de Água e Solos da FEAGRI. O procedimento adotado para a análise granulométrica de cada amostra foi o descrito a seguir:

- Foram pesados 10,0 g de solo seco ao ar e passado em uma peneira de 2,0 mm;
- O montante foi transferido para uma garrafa de Sthomann de 500 ml e agitado por 14 horas em um agitador de Wagner a 40 rpm;
- Este material foi colocado em uma proveta de 500 ml passando por uma peneira de 0,053 mm para separar a areia;
- Foi feita a pipetagem das amostras de acordo com a temperatura da solução, que na ocasião variava entre 29 e 31 graus Celsius;
- Este material disperso foi agitado por 30 segundos e após alguns minutos foi feita a pipetagem de 10 ml a 10 cm de profundidade para o cálculo do silte, e de 10 ml a 5 cm de profundidade para o cálculo da argila;
- Este material foi colocado em frasco com peso conhecido (pequenos Beckers) e levado à estufa a 105 graus Celsius;
- Após secar a mistura, foi feita a pesagem em uma balança de 4 casas decimais e calculada a porcentagem de argila e silte; e

- A areia seca foi colocada em um jogo de peneiras de 0,053 mm e 0,21 mm para a separação das areias grossa e fina.

Os resultados obtidos são apresentados no Anexo 1.

3.4.2. Análise de Fertilidade

As amostras correspondentes à camada 0-20 cm de profundidade foram separadas e enviadas ao Laboratório de Fertilidade do Instituto Agronômico de Campinas para serem analisadas. Esta camada foi separada em função de ter uma importância maior no rendimento da cultura. Foram analisadas então 48 amostras, contendo Fósforo-resina (P); Matéria Orgânica (MO); pH; os macronutrientes: Potássio (K), Cálcio (Ca), Magnésio (Mg), Hidrogênio+Alumínio (HAL), Soma de Bases (Sbases), Capacidade de Troca de Cátions (CTC) e Saturação por Bases (V%); e os micronutrientes: Boro (B), Cobre (Cu), Ferro (Fe), Manganês (Mn) e Zinco (Zn).

Os resultados obtidos são mostrados no Anexo 2.

3.5. PRODUTIVIDADE DA CULTURA

A colheita da cultura foi realizada em junho/98, quando foram colhidas manualmente todas as espigas de milho dentro das células correspondentes a 4,5m² em torno dos pontos de

coleta de amostras, abrangendo 2,5m de extensão por 1,80m de largura. O restante foi colhido com uma colheitadeira mecânica e manualmente em áreas de forte infestação de mucuna.

O montante de milho produzido em cada célula colhido na amostragem foi pesado e descontada sua umidade. Os valores de produtividade obtidos para as amostras foram colocados no banco de dados espacial e por meio de técnicas de interpolação foi criado o mapa de produtividade da cultura (Figura 7). Os resultados obtidos estão no Anexo 3.

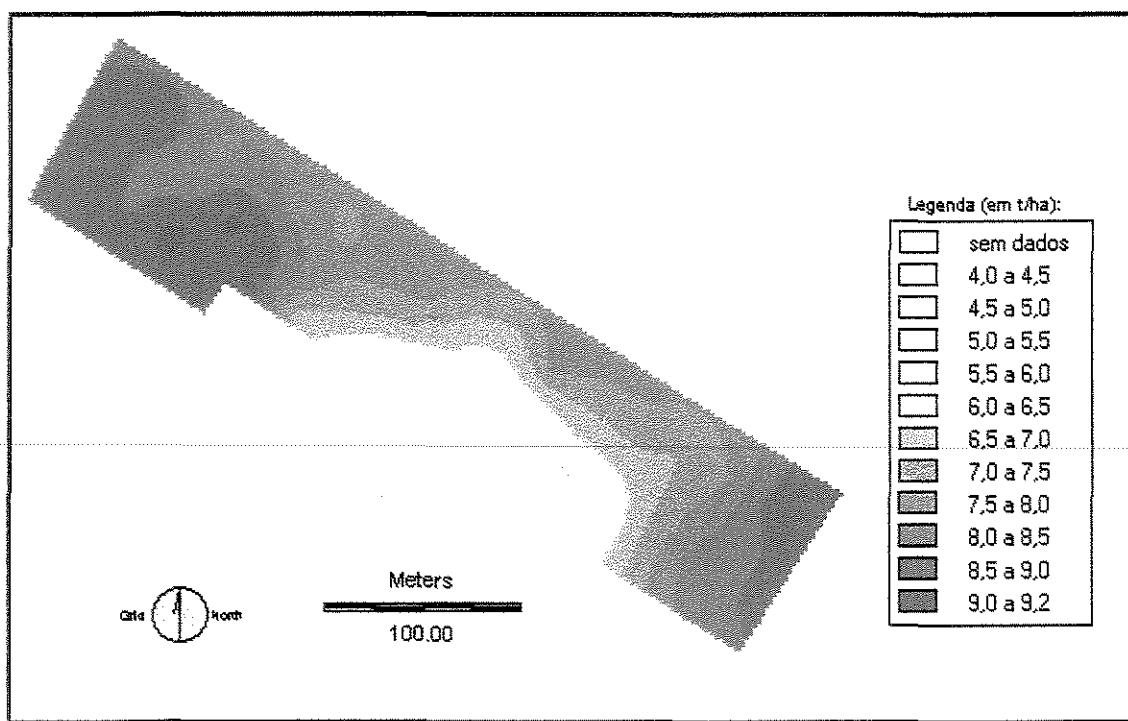


Figura 7: Mapa Geo-referenciado do Rendimento da Cultura.

3.6. ANÁLISES ESTATÍSTICAS

3.6.1. Análises Descritivas

Com os dados dos atributos do solo foi realizado um resumo estatístico, com medidas de posição e dispersão, e uma análise exploratória dos dados, utilizando a parte estatística do Software Excel for Windows e o pacote estatístico SAS (*Statistical Analysis System*).

Estas análises visam a verificação de normalidade dos dados, necessária para a aplicação de testes estatísticos convencionais. Estas hipóteses básicas de normalidade dos dados são em geral tidas como verdadeiras, sem seu teste adequado, e isto pode levar a erros de interpretação de resultados esperados.

As medidas mais utilizadas para a posição e dispersão de dados que serão usadas são a média, mediana, variância, desvio-padrão, coeficiente de variação e a amplitude.

A análise exploratória dos dados verifica a normalidade dos dados e detecta os chamados *outliers*, que nada mais são do que observações extremas que destoam do conjunto de dados, e alteram os valores de algumas medidas, como a média dos dados, e como menciona HOAGLIN (1983), é necessária uma medida de dispersão que seja insensível a essas observações o que, contrariamente à amplitude e ao desvio-padrão amostrais, a dispersão dos quartos fornece.

Sendo assim, foi feito o uso da análise da dispersão dos quartos ou quartis na análise exploratória, por meio dos gráficos do tipo *box-plot*.

3.6.2. Teoria das Variáveis Regionalizadas

Foi utilizada a teoria das variáveis regionalizadas ou geoestatística para detectar a dependência espacial dos atributos do solo e dos valores dos *pixels* nas imagens dos mapas de atributos do solo e de produtividade a partir de semivariogramas, o que não pode ser feito por meio da estatística convencional. Os semivariogramas foram criados pelo *Software Variowin*⁵ 2.2. Confirmou-se também com este programa que todos os atributos possuíram isotropia.

Foram feitas interpolações de valores de dados observados mediante amostragem com o auxílio da técnica de Krigagem para locais que apresentarem dependência espacial para a criação dos mapas de atributos de solos, por meio do *Software Surfer*⁶ 6.0, que importa os arquivos criados pelo Variowin, na forma de *grids*.

Com os mapas de atributos do solo e de produtividade prontos foram feitas regressões lineares, no ambiente do *Software Idrisi*⁷ for Windows 2.0, para cada atributo isoladamente com o mapa de produtividade e posteriormente com os atributos em conjunto com o mapa de produtividade, por meio de regressões múltiplas. Foram feitas então análises a partir destas regressões para determinar o número de variáveis presentes e sua importância no modelo de previsão do rendimento, a partir de regressões múltiplas do tipo passo a passo.

⁵ PANNATIER, Y. *Variowin – Software for Spatial Data Analysis in 2D*. Springer-Verlag, NY. 1996

⁶ KECKLER, D. *Surfer for Windows: user's guide*, v.6. Colorado: Golden Software. 1995

⁷ EASTMAN, J.R. *Idrisi for Windows*, v.2, Manual do Usuário. Centro de Recursos Idrisi, Brasil, UFRGS. 1998

IV - RESULTADOS

4.1. ANÁLISES DESCRIPTIVAS E EXPLORATÓRIAS

A Tabela 1 abaixo refere-se à matriz de correlações dos atributos do solo e o rendimento da cultura entre si, nos pontos de coleta de amostra.

Tabela 1: Matriz de Correlações:

	P	MO	pH	K	Ca	Mg	HAL
P	1.0000	0.8173	0.0893	0.5712	0.1417	0.4590	0.1299
MO	0.8173	1.0000	0.0201	0.4506	0.1724	0.4629	0.2143
pH	0.0893	0.0201	1.0000	-.2231	0.8576	0.7353	-.9268
K	0.5712	0.4506	-.2231	1.0000	-.1439	0.0094	0.3131
Ca	0.1417	0.1724	0.8576	-.1439	1.0000	0.6632	-.7768
Mg	0.4590	0.4629	0.7353	0.0094	0.6632	1.0000	-.5441
HAL	0.1299	0.2143	-.9268	0.3131	-.7768	-.5441	1.0000
SBases	0.3738	0.3818	0.8604	0.0416	0.9256	0.8776	-.7100
CTC	0.6647	0.7849	-.0610	0.4617	0.2202	0.4585	0.3556
V%	0.1140	0.0737	0.9772	-.1697	0.9174	0.7676	-.9189
B	0.4645	0.4073	-.2263	0.3851	0.0101	-.1631	0.3098
Cu	0.1149	0.1958	-.3808	0.2554	-.2956	-.1976	0.3936
Fe	0.2054	0.3333	-.3907	0.1631	-.4541	-.1251	0.5044
Mn	0.2711	0.4124	-.0977	-.0006	-.0170	-.0146	0.2146
Zn	0.6724	0.7074	0.1287	0.3197	0.2417	0.2469	-.0182
SFino	-.0045	-.0053	0.0809	-.0105	0.1202	0.1063	-.0064
SGrosso	0.2635	0.2133	-.0734	0.3070	0.0639	0.0233	0.1259
Argila	-.1659	-.1925	0.1171	-.1412	-.0007	0.1412	-.2387
Areia	-.0931	-.0040	-.1841	-.1680	-.2140	-.3279	0.2142
RENDIM	-.0421	-.1021	0.1542	-.1701	0.1528	-.1767	-.2148
	SBases	CTC	V%	B	Cu	Fe	Mn
P	0.3738	0.6647	0.1140	0.4645	0.1149	0.2054	0.2711
MO	0.3818	0.7849	0.0737	0.4073	0.1958	0.3333	0.4124
pH	0.8604	-.0610	0.9772	-.2263	-.3808	-.3907	-.0977
K	0.0416	0.4617	-.1697	0.3851	0.2554	0.1631	-.0006
Ca	0.9256	0.2202	0.9174	0.0101	-.2956	-.4541	-.0170
Mg	0.8776	0.4585	0.7676	-.1631	-.1976	-.1251	-.0146
HAL	-.7100	0.3556	-.9189	0.3098	0.3936	0.5044	0.2146
SBases	1.0000	0.4057	0.9189	-.0204	-.2431	-.2969	-.0156
CTC	0.4057	1.0000	0.0269	0.3750	0.1883	0.2606	0.2578
V%	0.9189	0.0269	1.0000	-.1923	-.3634	-.4300	-.1249
B	-.0204	0.3750	-.1923	1.0000	0.1910	0.0501	0.2959
Cu	-.2431	0.1883	-.3634	0.1910	1.0000	0.5470	0.4931
Fe	-.2969	0.2606	-.4300	0.0501	0.5470	1.0000	0.3121
Mn	-.0156	0.2578	-.1249	0.2959	0.4931	0.3121	1.0000
Zn	0.3188	0.3995	0.1504	0.5079	0.3021	0.2140	0.5407

Tabela 1: (cont.)

	Sbases	CTC	V%	B	Cu	Fe	Mn
SFino	0.1236	0.1557	0.0786	0.0354	0.0783	-.0436	-.0529
SGrosso	0.0911	0.2844	-.0202	0.1535	-.1386	-.0729	-.2644
Argila	0.0414	-.2548	0.1260	-.3851	-.0781	-.1014	-.1773
Areia	-.3012	-.1217	-.2557	0.3325	0.1976	0.2714	0.5541
RENDIM	0.0014	-.2770	0.1258	0.1402	-.0084	-.1632	0.1792
	Zn	SFino	SGrosso	Argila	Areia	RENDIM	
P	0.6724	-.0045	0.2635	-.1659	-.0931	-.0421	
MO	0.7074	-.0053	0.2133	-.1925	-.0040	-.1021	
pH	0.1287	0.0809	-.0734	0.1171	-.1841	0.1542	
K	0.3197	-.0105	0.3070	-.1412	-.1680	-.1701	
Ca	0.2417	0.1202	0.0639	-.0007	-.2140	0.1528	
Mg	0.2469	0.1063	0.0233	0.1412	-.3279	-.1767	
HAL	-.0182	-.0064	0.1259	-.2387	0.2142	-.2148	
Sbases	0.3188	0.1236	0.0911	0.0414	-.3012	0.0014	
CTC	0.3995	0.1557	0.2844	-.2548	-.1217	-.2770	
V%	0.1504	0.0786	-.0202	0.1260	-.2557	0.1258	
B	0.5079	0.0354	0.1535	-.3851	0.3325	0.1402	
Cu	0.3021	0.0783	-.1386	-.0781	0.1976	-.0084	
Fe	0.2140	-.0436	-.0729	-.1014	0.2714	-.1632	
Mn	0.5407	-.0529	-.2644	-.1773	0.5541	0.1792	
Zn	1.0000	0.0243	-.0777	-.1168	0.2443	0.2973	
Sfino	0.0243	1.0000	-.2191	-.2697	-.0501	0.0315	
SGrosso	-.0777	-.2191	1.0000	-.5499	-.3507	-.1755	
Argila	-.1168	-.2697	-.5499	1.0000	-.4171	-.1601	
Areia	0.2443	-.0501	-.3507	-.4171	1.0000	0.3817	
RENDIM	0.2973	0.0315	-.1755	-.1601	0.3817	1.0000	

Analizando a matriz de correlações acima, nota-se que o fósforo possui correlação com a MO (0,8173), Zn (0,6724), CTC (0,6647) e o K (0,5712). A matéria orgânica, além do fósforo, possui altas correlações com a CTC (0,7849) e o Zn (0,7074). O pH possui altas correlações com V% (0,9772), HAL (-0,9268), Ca (0,8576), Sbases (0,8604) e Mg (0,7353). Verifica-se que o V% pode substituir o pH nas análises dada sua alta correlação.

$$\text{Sendo } V\% = \frac{(100.Sbases)}{CTC} ; \text{ SBases} = \text{Ca} + \text{Mg} + \text{K} ; \text{ e } \text{CTC} = \text{SBases} + \text{HAL} , \text{ é}$$

esperado o fato de se relacionarem V%, SBases, Ca, Mg e HAL com o pH.

Quanto aos macronutrientes, o potássio tem razoável correlação somente com o fósforo (0,5712). O cálcio tem boa correlação com a SBases (0,9256), V% (0,9174), pH (0,8576), HAL (-0,7768) e Mg (0,6632). O magnésio tem boas correlações com a SBases (0,8776), V% (0,7676), pH (0,7353), Ca (0,6632) e HAL (-0,5441). Já o HAL tem boa correlação com o pH (-0,9268), V% (-0,9189), Ca (-0,7768), SBases (-0,71), Mg (-0,5441) e Fe (0,5044). A SBases tem boa correlação com o Ca (0,9256), V% (0,9189), Mg (0,8776), pH (0,8604) e HAL (-0,71). A CTC tem boas correlações com a MO (0,7849) e P (0,6647). Já o V% tem boas correlações com o pH (0,9772), SBases (0,9189), HAL (-0,9189), Ca (0,9174) e Mg (0,7676). Portanto, para os macronutrientes, estas correlações são mais do que esperadas. Nota-se que o cálcio e o magnésio têm mais peso na soma de bases, a soma de bases na saturação por base (V%) e o magnésio e o potássio na CTC. Chama atenção o fato da CTC se correlacionar melhor com o fósforo e a matéria orgânica do que com suas variáveis de formação.

As correlações não são tão boas para os micronutrientes. O boro possui melhor correlação com o zinco (0,5079); o cobre com o ferro (0,5470); o ferro com o cobre (0,5470) e HAL (0,5044); o manganês com a areia (0,5541) e zinco (0,5407). E o zinco surpreende mantendo boas relações com a MO (0,7074), P (0,6724), Mn (0,5407) e o B (0,5079).

Quanto às variáveis granulométricas, o silte fino não apresenta boas correlações; o silte grosso apenas com a argila (-0,5499); a argila só com o silte grosso; e a areia só com o manganês (0,5541). Nota-se também que o rendimento inicialmente não tem boa correlação com nenhuma variável.

Estas análises de correlações mostram as variáveis que podem ser representadas por outras sem muita perda de informação. Assim, as variáveis com correlação maior que 0.9 podem

Estas análises de correlações mostram as variáveis que podem ser representadas por outras sem muita perda de informação. Assim, as variáveis com correlação maior que 0.9 podem ser representadas por uma variável só, as outras podem ser desconsideradas sem perda de informação significante para o modelo.

Tabela 2: Análise dos Macronutrientes:

	P-res.	Mat.Org.	pH	K	Ca	Mg	H+Al	S.Bases	CTC	V%
Média:	15,46	3,46	4,90	0,19	2,80	2,02	4,99	5,03	10,01	50,14
Variância:	48,13	0,21	0,09	0,03	0,79	0,34	1,73	1,81	1,03	134,77
Desvio-padrão:	6,94	0,46	0,31	0,18	0,89	0,58	1,32	1,35	1,01	11,61
Valor Mínimo:	6,00	2,60	4,10	0,03	1,30	0,90	3,10	2,30	7,70	18,80
Quartil 1:	12,00	3,20	4,68	0,07	2,10	1,60	4,18	4,10	9,40	41,03
Mediana:	14,50	3,50	4,90	0,13	2,80	2,07	4,70	4,70	10,02	50,03
Quartil 3:	17,00	3,60	5,20	0,24	3,43	2,33	5,80	5,95	10,70	60,43
Valor Máximo:	51,00	5,50	5,40	0,97	4,60	3,30	9,90	8,30	13,00	70,20

	P-res.	Mat.Org.	pH	K	Ca	Mg	H+Al	S.Bases	CTC	V%
Amplitude:	5,00	0,40	0,53	0,17	1,33	0,73	1,63	1,85	1,30	19,40
Outlier Min:	4,50	2,60	3,89	-0,18	0,11	0,51	1,74	1,33	7,45	11,93
Outlier Max:	24,50	4,20	5,99	0,49	5,41	3,41	8,24	8,73	12,65	89,53
Outliers:	C15 (26) B15 (51)	B15 (5,5) -	- -	C15 (0,54) B15 (0,65) B12 (0,97)	- - -	- - -	D15 (9,9) -	- -	B15 (13) -	-

Todos estes *outliers* apontados na Tabela 2 estão nas colunas 15 e 16, exceto pelo potássio, que está na coluna 12. Como já foi dito anteriormente, nas colunas 15 e 16 detectou-se erosão. Assim sendo, a presença destes *outliers* nestas colunas provavelmente pode ser explicada pela erosão apresentada nesta área.

Como as análises apontaram diversos *outliers*, foram feitas novas análises sem estes. Os resultados são mostrados na Tabela 3 a seguir.

Tabela 3: Análise dos Macronutrientes sem os *outliers*:

	P-res.	Mat.Org.	pH	K	Ca	Mg	H+Al	S.Bases	CTC	V%
Média:	14,46	3,41	4,90	0,16	2,80	2,02	4,88	5,03	9,95	50,14
Variância:	18,70	0,12	0,09	0,01	0,79	0,34	1,24	1,81	0,85	134,77
Desvio-padrão:	4,32	0,35	0,31	0,11	0,89	0,58	1,11	1,35	0,92	11,61
Valor Mínimo:	6,00	2,60	4,10	0,03	1,30	0,90	3,10	2,30	7,70	18,80
Quartil 1:	12,00	3,20	4,68	0,07	2,10	1,60	4,05	4,10	9,40	41,03
Mediana:	14,00	3,50	4,90	0,11	2,80	2,07	4,70	4,70	10,00	50,03
Quartil 3:	17,00	3,60	5,20	0,22	3,43	2,33	5,80	5,95	10,60	60,43
Valor Máximo:	23,00	4,10	5,40	0,45	4,60	3,30	7,20	8,30	12,20	70,20
Coef. Assimetria:	-0,35	-0,25	-1,00	0,91	0,00	-0,13	-0,83	0,54	1,04	0,19
Coef. Variação:	0,30	0,10	0,06	0,71	0,32	0,29	0,23	0,27	0,09	0,23

A Tabela 3 acima mostra, além das estatísticas básicas de posição e de dispersão, os coeficientes de assimetria e de variação para os macronutrientes. Quanto mais próximo a “0,0” forem os valores do coeficiente de assimetria, maior a semelhança da distribuição com a distribuição normal, assim como quanto mais próximos forem os valores da média e da mediana, tanto mais próximo a distribuição estará da normal.

Verifica-se nesta tabela que o potássio possui alta variação (0,71) com alta assimetria (0,91), calculada segundo o 1º coeficiente de Pearson. Já o pH possui baixo coeficiente de variação (0,06) e o maior coeficiente de assimetria (-1,00). Isto é devido a uma moda bem maior que a média, e um desvio-padrão pequeno. Sendo assim, o 1º coeficiente de Pearson para o cálculo do coeficiente de assimetria não se mostrou muito adequado ao caracterizar a assimetria dos dados. Verifica-se com a fórmula utilizada pelos softwares (já citada anteriormente, que utiliza o 3º momento centrado na média), que o coeficiente de assimetria para o pH resultou em -0,31 e para o potássio em 2,32 (Anexo 4), valores bem diferentes destes, que não levam em consideração a moda da distribuição dos dados.

A seguir é apresentada a Tabela 4, que mostra a análise dos micronutrientes e dos atributos de granulometria

Tabela 4: Análise dos Micronutrientes e Granulometria:

	B	Cu	Fe	Mn	Zn	Sfino	Sgrosso	Argila	Areia
Média:	0,28	9,57	22,28	29,73	0,95	7,49	11,64	53,75	27,13
Variância:	0,004	1,47	64,65	82,55	0,20	1,24	4,49	4,72	3,13
Desvio-padrão:	0,07	1,21	8,04	9,09	0,44	1,11	2,12	2,17	1,77
Valor Mínimo:	0,19	4,40	7,80	16,80	0,30	4,9	6,9	48,1	23
Quartil 1:	0,23	9,00	18,33	21,05	0,70	6,89	10,34	52,14	26
Mediana:	0,26	9,63	20,95	28,30	0,90	7,47	11,18	54,30	27
Quartil 3:	0,29	10,15	24,60	37,29	1,10	8,26	12,31	55,46	28
Valor Máximo:	0,51	12,20	62,70	48,70	3,10	10	18,8	58,2	32

	B	Cu	Fe	Mn	Zn	Sfino	Sgrosso	Argila	Areia
Amplitude:	0,06	1,15	6,28	16,24	0,40	1,375	1,975	3,325	2
Outlier Min:	0,14	7,28	8,91	-3,31	0,10	4,825	7,375	47,15	23
Outlier Max:	0,38	11,88	34,01	61,64	1,70	10,325	15,275	60,45	31

Outliers:	C16 (0,39)	D7 (4,4)	D7 (7,8)	-	B15 (3,1)	-	C13 (16)	-	D15 (32)
	C15 (0,49)	D16 (12,2)	D12 (34,1)	-	-	-	B1 (16)	-	-
	B15 (0,51)	-	D15 (38,8)	-	-	-	B10 (19)	-	-
	-	-	D9 (62,7)	-	-	-	-	-	-

Nota-se também na tabela acima a grande concentração de *outliers* nas colunas 15 e 16 do *grid* de amostragem da área. Estes também devem ter sido ocasionados pela erosão no local. Percebe-se que os *outliers* do ferro e do cobre que não estão na área de erosão, estão localizados na linha D do *grid*, e os *outliers* do silte grosso na linha B e C.

Assim, dos 22 *outliers* detectados, 14 estavam situados na zona de erosão (colunas 15 e 16), 3 do ferro na linha D (D7, D9 e D12), 2 do silte grosso na linha B (B1 e B10), 1 do potássio também na linha B (B12), 1 do cobre na linha D (D7), e 1 do silte grosso na linha C (C13).

Como as variáveis também possuem diversos *outliers*, estes foram retirados e as análises recalculadas para este grupo também. O resultado é a Tabela 5 a seguir.

Tabela 5: Análise dos Micronutrientes e Granulometria sem os *outliers*:

	B	Cu	Fe	Mn	Zn	Sfino	Sgrosso	Argila	Areia
Média:	0,26	9,62	21,06	29,55	0,88	7,49	11,27	53,75	27,02
Variância:	0,002	0,78	16,66	80,90	0,08	1,24	2,55	4,72	2,674
Desvio-padrão:	0,04	0,88	4,08	8,99	0,27	1,11	1,60	2,17	1,635
Valor Mínimo:	0,19	7,80	12,00	16,80	0,30	4,9	6,9	48,1	23
Quartil 1:	0,23	9,03	18,33	21,05	0,70	6,89	10,30	52,14	26
Mediana:	0,26	9,60	20,70	28,30	0,90	7,47	10,85	54,30	27
Quartil 3:	0,28	10,08	24,10	36,30	1,00	8,26	12,20	55,46	28
Valor Máximo:	0,38	11,70	31,40	48,70	1,50	10,00	15,10	58,20	31
Coef. Assimetria:	-0,45	-0,43	0,26	0,39	-0,42	0,08	0,19	-0,80	-0,49
Coef. Variação:	0,16	0,09	0,19	0,30	0,31	0,15	0,14	0,04	0,061

Nota-se com a tabela acima, que os valores de coeficiente de variação são pequenos, assim como os valores dos coeficientes de assimetria. Nenhum valor se destacou do resto. Todos estes atributos apresentaram boa assimetria e bom coeficiente de variação. A maior variação foi a do zinco (0,31), seguida pelo manganês (0,30). Os outros atributos apresentaram valores de coeficiente de variação abaixo de 0,20.

Moments			
N	48	Sum Wgts	48
Mean	15.45833	Sum	742
Std Dev	6.937282	Variance	48.12589
Skewness	2.975131	Kurtosis	13.99477
USS	13732	CSS	2261.917
CV	44.8773	Std Mean	1.000131
T:Mean=0	15.4381	Pr> T	0.0001
Num == 0	48	Num > 0	48
M(Sign)	24	Pr>= M	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.772707	Pr<8	0.0001
Quantiles (Def=5)			
100% Max	51	99%	51
75% Q3	17	95%	23
50% Med	14.5	90%	23
25% Q1	12	10%	9
0% Min	6	5%	8
		1%	6
Range	45		
Q3-Q1	5		
Mode	12		

Figura 8: Análises Estatísticas para o Fósforo.

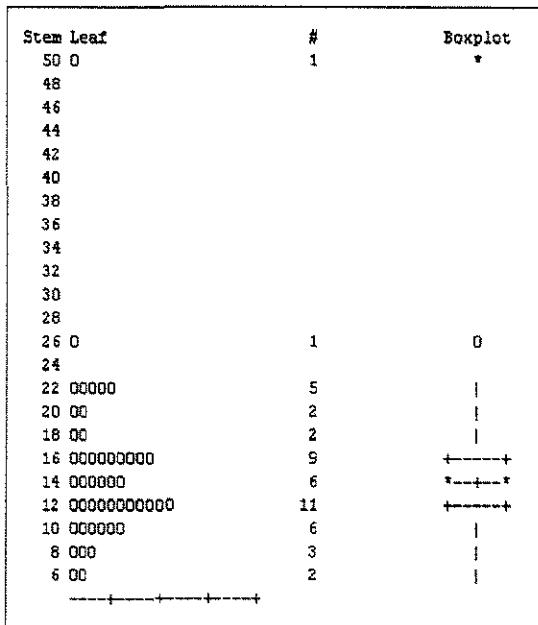


Figura 9: Ramo-e-folhas e Box-plot

Nota-se a partir das figuras acima, que o fósforo possui 2 *outliers*, claramente vistos no Box-plot no ponto 26 e no ponto 50, confirmado pela Tabela 2. Como sua média (15,46) e sua mediana (14,50) não estão muito distantes, e seu valor de coeficiente de assimetria não está distante de 0 (-0,35), esta variável poderia ser considerada como tendo distribuição normal se não fosse o valor do coeficiente de curtose (13,99). Ao se retirar os *outliers*, este coeficiente tende a diminuir (Figura 10).

Moments			
H	46	Sum Wgts	46
Mean	14.45652	Sum	665
Std Dev	4.324126	Variance	18.69887
Skewness	0.3581	Kurtosis	-0.35521
USS	19455	CSS	841.413
CV	29.91125	Std Mean	0.637558
T:Mean=0	22.67485	Pr> T	0.0001
Num > 0	46	Num > 0	46
N(Sign)	29	Pr>= H	0.0001
Sgn Rank	548.5	Pr>= S	0.0001
W:Normal	0.956254	Pr<W	0.1322
Quantiles(Def=5)			
100% Max	23	99%	23
75% Q3	17	95%	23
50% Med	14	90%	22
25% Q1	12	10%	9
0% Min	6	5%	8
		1%	6
Range	17		
Q3-Q1	5		
Mode	12		

Figura 10: Análises do P sem *outliers*

Verifica-se com a Figura 10 que a média (14,46), mediana (14) e moda (12) são muito próximas, a estatística W de SHAPIRO-WILKS (1965) tem um valor de 0,9562 e seu *p-value* possui um valor alto (0,1322), assim como os coeficientes de assimetria (0,36) e curtose (-0,35) possuem valores bem baixos, caracterizando a normalidade dos dados.

As análises referentes à Matéria Orgânica e pH resultaram também em uma normalidade dos dados, como pode ser constatado no Anexo 4.

A Figura 11 a seguir mostra as análises realizadas para o Potássio já desconsiderando os *outliers*. Nota-se a partir desta que os dados apresentam grande assimetria (1,08) e um *p-value* da estatística W próximo a 0 (0,0001), com média (0,15), mediana (0,11) e moda (0,06) diferindo bastante. Assim sendo, embora possua boa estatística W (0,87), não podemos aproximar esta distribuição da normal padrão.

Moments			
N	45	Sum Wgts	45
Mean	0.155111	Sum	6.98
Std Dev	0.118219	Variance	0.012148
Skewness	1.881435	Kurtosis	0.431879
USS	1.6172	CSS	0.534524
CV	71.05826	Std Mean	0.016431
T:Mean=0	9.448429	Pr> T	0.0001
Num ^= 0	45	Num > 0	45
M(Sign)	22.5	Pr>= M	0.0001
Sgn Rank	517.5	Pr>= S	0.0001
W:Normal	0.867991	Pr<W	0.0001
Quantiles(Def=5)			
100% Max	0.45	99%	0.45
75% Q3	0.22	95%	0.37
50% Med	0.11	90%	0.31
25% Q1	0.07	10%	0.06
0% Min	0.03	5%	0.04
		1%	0.03
Range	0.42		
Q3-Q1	0.15		
Mode	0.06		

Figura 11: Análises do K sem outliers

As análises para o Cálcio, Magnésio, H+Al, Soma de Bases, CTC, V%, Boro, Cobre, Ferro, Zinco, Silte Fino, Areia e Rendimento apresentaram distribuição aproximadamente normal dos dados (Anexo 4).

Moments			
N	48	Sum Wgts	48
Mean	29.55208	Sum	1418.5
Std Dev	8.994584	Variance	80.90255
Skewness	0.475343	Kurtosis	-0.87588
USS	45722.05	CSS	3802.42
CV	30.43638	Std Mean	1.298256
T:Mean=0	22.7629	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
M(Sign)	24	Pr>= M	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.921982	Pr<W	0.0037
Quantiles(Def=5)			
100% Max	48.7	99%	48.7
75% Q3	36.5	95%	45.9
50% Med	28.3	90%	43.3
25% Q1	20.9	10%	18.8
0% Min	16.8	5%	18.6
		1%	16.8
Range	31.9		
Q3-Q1	15.6		
Mode	26		

Figura 12: Análises do Manganês

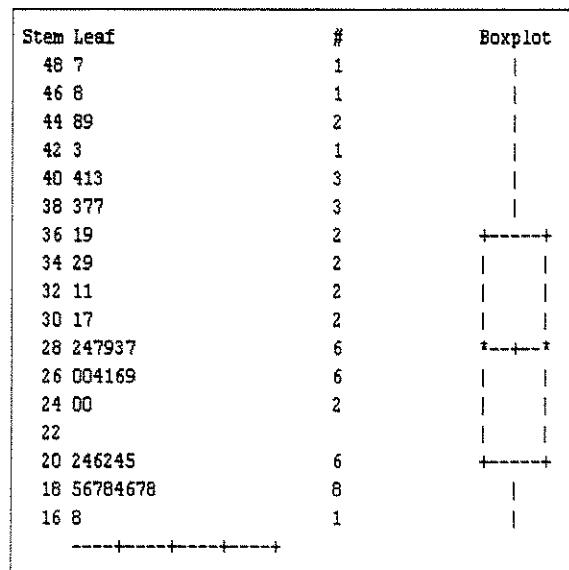


Figura 13: Ramo-e-folhas e Box-plot

Os dados do Manganês presentes na Figura 12 mostram uma alta estatística W (0,92), porém com baixo *p-value* (0,0037). A média (29,55), mediana (28,3) e moda (26) se diferenciam um pouco, e os coeficientes de assimetria (0,47) e curtose (-0,88) são bem marcantes. A partir da Figura 13 verifica-se com o gráfico de ramo-e-folhas que a distribuição não é normal, denotando um forte achatamento e assimetria positiva.

Para o Silte Grosso, com a Figura 14 verificaram-se altos índices de assimetria (0,48) e curtose (0,97) e um *p-value* de 0,0006, embora a estatística W seja de 0,8993. Só isto já desqualifica a normalidade dos dados .

Moments			
N	45	Sum Wgts	45
Mean	11.2	Sum	504
Std Dev	1.659682	Variance	2.754545
Skeuness	0.478219	Kurtosis	0.97361
USS	5766	CSS	121.2
CV	14.81859	Std Mean	0.247411
T:Mean=0	45.26883	Pr> T	0.0001
Num ^= 0	45	Num > 0	45
M(Sign)	22.5	Pr>= M	0.0001
Sgn Rank	517.5	Pr>= S	0.0001
W:Normal	0.899278	Pr<W	0.0006
Quantiles(Def=5)			
100% Max	15	99%	15
75% Q3	12	95%	15
50% Med	11	90%	14
25% Q1	10	10%	10
0% Min	7	5%	10
		1%	7
Range	8		
Q3-Q1	2		
Mode	18		

Figura 14: Análises do Silte Grosso sem *outliers*

No caso da Argila, a Figura 15 mostra que a média (53,69), mediana (54) e moda (55) da Argila estão próximas, possui uma alta estatística W (0,93), porém um baixo *p-value* (0,0092), quase sem curtose (-0,02) mas com alta assimetria (-0,65). Estes dados deixam dúvidas quanto à

normalidade, mas com a figura 16 abaixo nota-se que a distribuição é realmente bem assimétrica, e o box-plot mostra também essa assimetria, por isso, rejeita-se a normalidade dos dados.

Moments			
N	48	Sum Wgts	48
Mean	53.6875	Sum	2577
Std Dev	2.165064	Variance	4.6875
Skewness	-0.65408	Kurtosis	-0.02206
USS	138573	CSS	220.3125
CV	4.032714	Std Mean	0.3125
T:Mean=0	171.8	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
E(Sign)	24	Pr>= E	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.930691	Pr<W	0.0092
Quantiles (Def=5)			
100% Max	58	99%	58
75% Q3	55	95%	56
50% Med	54	90%	56
25% Q1	52	10%	50
0% Min	48	5%	50
		1%	48
Range	10		
Q3-Q1	3		
Mode	55		

Figura 15: Análises da Argila

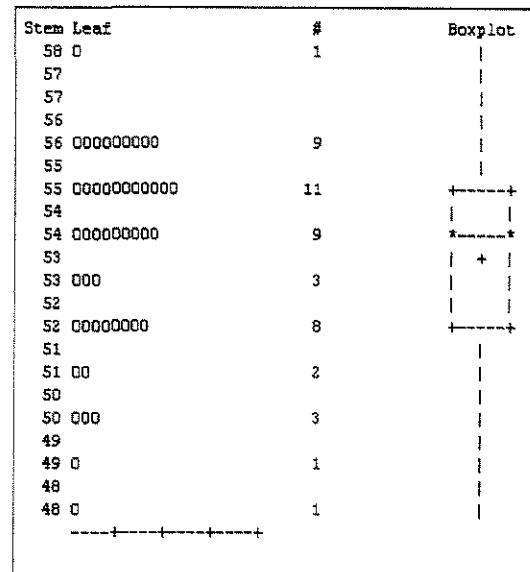


Figura 16: Ramo-e-folhas e Box-plot

Verifica-se que das 20 variáveis de estudo, 11 possuíam *outliers*, sendo 4 deles do ferro, 3 do potássio, 3 do boro, 3 do silte grosso, 2 do cobre, 2 do fósforo, 1 da matéria orgânica, do H+Al, da CTC, do zinco e da areia, totalizando 22 *outliers* em 960 dados, o que corresponde a 2,29% dos dados sendo descartados.

Uma vez comprovado que existiam variáveis sem distribuição normal dos dados, como o potássio, manganês, silte grosso e argila, é clara a importância da geoestatística no lugar da estatística convencional.

4.2. REGRESSÕES LINEARES MULTIVARIADAS

Os dados das variáveis foram analisados por meio do *software* Variowin 2.2 sem os *outliers*. Com este programa, construíram-se semivariogramas a partir do melhor ajuste de curvas obtido. Os erros dos modelos ajustados variaram de 10^{-2} a 10^{-3} pelo método dos mínimos quadrados. Os semivariogramas foram construídos considerando-se apenas o comportamento dos dados na origem, levando-se em conta estes dados apenas até a metade da área.

Das 20 variáveis, 13 obtiveram ajuste com estrutura esférica, 4 ajuste com estrutura gaussiana (MO, K, H+Al e Fe) e 3 não obtiveram estrutura de semivariograma (zincos, silte fino e silte grosso), sendo estas últimas variáveis espacialmente independentes. As outras 17 possuíram dependência espacial. Os semivariogramas são mostrados no Anexo 5.

Com as funções ajustadas a modelos, os dados foram interpolados com o *software* Surfer 6.0, criando assim *grids* de dados interpolados, apresentados no Anexo 6.

Os *grids* foram importados pelo *software* Idrisi 2.0, originando assim os 19 mapas de atributos do solo e o de rendimento da cultura. Estes foram recortados para representar apenas a área de estudo e foram feitas regressões lineares apenas nas áreas dentro dos *grids* para verificar sua correlação com o rendimento. Os mapas são apresentados no Anexo 7, e as Regressões Lineares no Anexo 8.

4.2.1. Regressões Lineares das Variáveis mais Importantes

A literatura e especialistas em nutrição de plantas definiram que as melhores variáveis para explicar o rendimento do milho dentre as 19 citadas anteriormente são o fósforo, a matéria orgânica, a CTC, a saturação por bases (V%) e a argila (por se tratar de um solo pertencente à

classe dos latossolos roxos). A CTC e a V% foram desagregadas em cálcio, magnésio, potássio e H+Al para uma melhor precisão dos resultados. Com isto, as variáveis que fizeram parte desta primeira análise de regressão linear multivariada foram: P, MO, K, Ca, Mg e H+Al, além do rendimento.

Dos micronutrientes, o mais absorvido é o zinco, mas como este não apresentou estrutura de semivariograma, achou-se por bem não colocá-lo nesta análise.

Foi feita a Tabela 6 a seguir, resumindo os modelos de regressão encontrados com o método passo-a-passo utilizado por BAKHSH (1997).

Tabela 6: Modelos de Regressão passo-a-passo

Variável a entrar	Modelo de Regressão (Y = Rendimento)	5%		
		Coef.Det.(r2)	Pr>F	F tabela
MO	Y = 28,90 - 6,31 MO	60,98%	-	-
Mg	Y = 30,74 - 2,28 Mg - 5,51 MO	79,23%	9121,20	2,9957
Argila	Y = 23,52 + 0,13 Argila - 2,75 Mg - 5,20 MO	79,74%	6276,57	2,6049
P	Y = 23,42 + 0,13 Argila - 2,65 Mg - 5,09 MO + 0,01 P	80,52%	4716,83	2,3719
Ca	Y = 13,65 + 0,29 Argila + 0,48 Ca - 3,74 Mg - 4,91 MO + 0,08 P	81,28%	4153,53	2,2141
K	Y = 5,36 + 0,31 Argila + 0,65 Ca - 5,70 K - 4,99 Mg - 2,18 MO + 0,13 P	81,56%	3526,04	2,0986
HAI	Y = -13,23 + 0,38 Argila + 0,84 Ca + 1,40 HAI - 28,30 K - 5,08 Mg + 1,29 MO + 0,09 P	82,10%	3133,35	2,0096

Com a tabela acima, verifica-se que a primeira variável a entrar no modelo é a matéria orgânica, que explica sozinha 60,98% do rendimento. A seguir entra o magnésio no modelo, explicando 79,23%. Na ordem, entram argila, cálcio, fósforo, potássio e H+Al. Portanto, considera-se o modelo final como sendo aquele com 7 variáveis:

$$\text{Rendim} = -13,23 + 0,38 \text{ Argila} + 0,84 \text{ Ca} + 1,4 \text{ H+Al} - 28,3 \text{ K} - 5,08 \text{ Mg} + 1,29 \text{ MO} + 0,09 \text{ P},$$

Explicando 82,1% do rendimento.

Verifica-se também que a estatística F (Pr>F) é sempre muito maior do que sua probabilidade da tabela de distribuição F (tabela), portanto, o modelo é sempre aceito. Deve-se tomar muito cuidado ao analisar este resultado, uma vez que estes valores enormes de F são

dados em virtude da grande quantidade de resíduos criados ao interpolar os dados. É como se comparasse F com 7 variáveis e 10365 resíduos.

Os semivariogramas, *grids* e mapas geo-referenciados destas variáveis são mostrados a seguir. Os *grids* apresentam a área extrapolada, e não apenas a área utilizada nas regressões, correspondendo à faixa diagonal do *grid*.

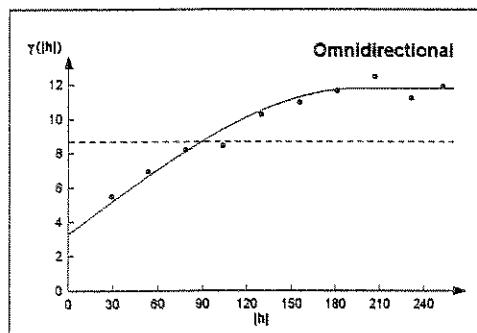


Figura 17: Semivariograma do Rendimento Esférico: $\text{Gama}(h)=3,306+8,526\text{Sph.}195(h)$

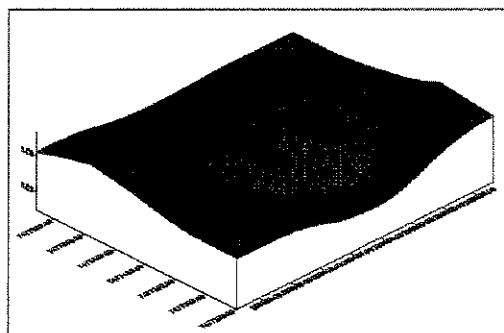


Figura 18: Grid interpolado do Rendimento

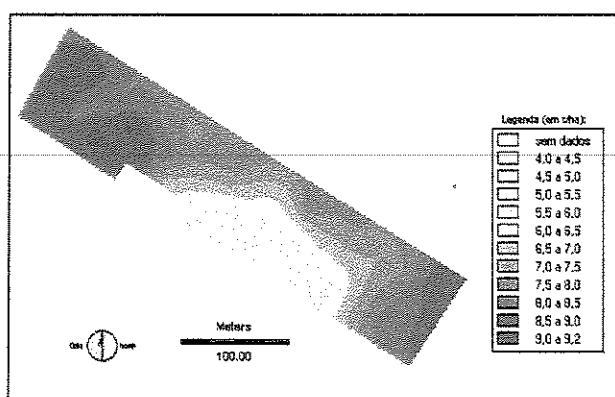


Figura 19: Mapa Geo-referenciado do Rendimento

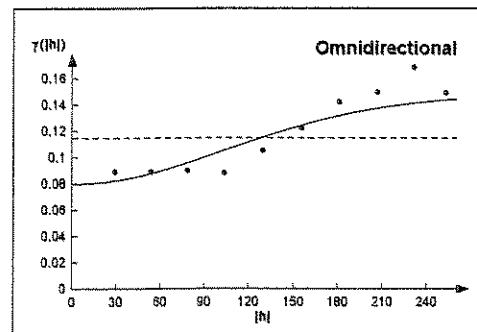


Figura 20: Semivariograma da MO Gauss: $\text{Gama}(h)=0,0799+0,068\text{Gauss.}260(h)$

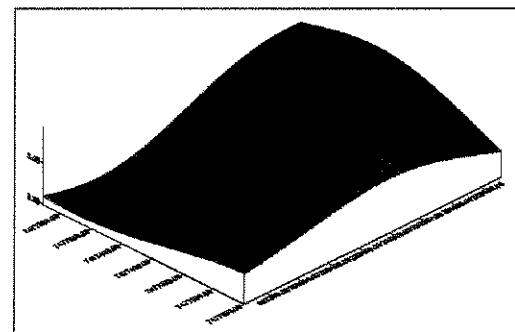


Figura 21: Grid interpolado da MO

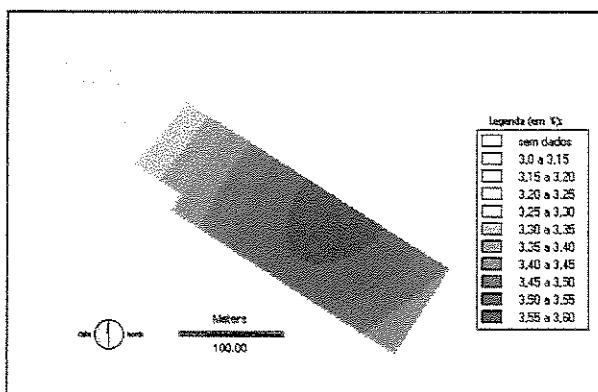


Figura 22: Mapa Geo-referenciado da MO

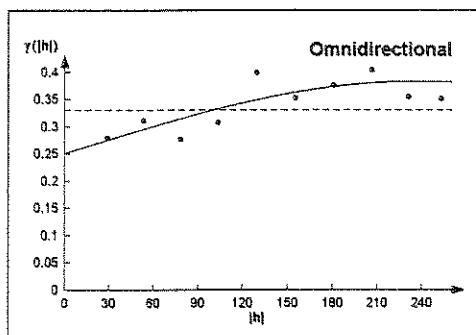


Figura 23: Semivariograma do Magnésio
Esférico: $\text{Gama}(h)=0,252+0,132\text{Sph.}234(h)$

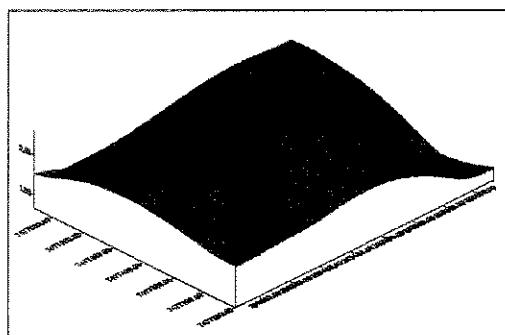


Figura 24: Grid interpolado do Magnésio

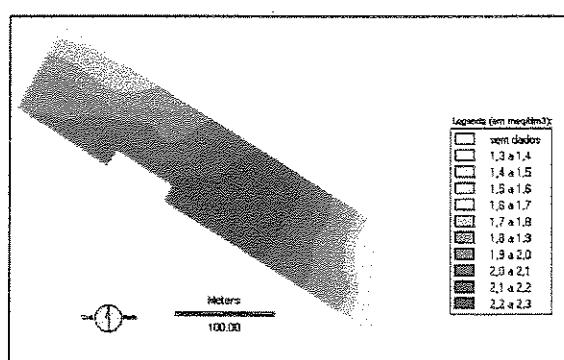


Figura 25: Mapa Geo-referenciado do Magnésio

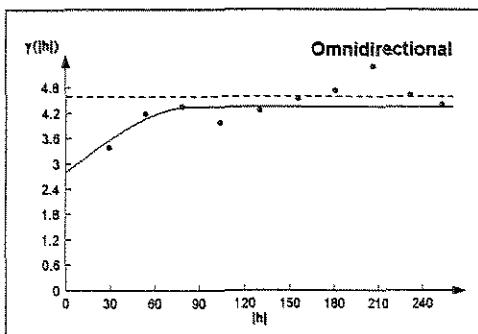


Figura 26: Semivariograma da Argila
Esférico: Gama(h)=2,82+1,551Sph.87,4(h)

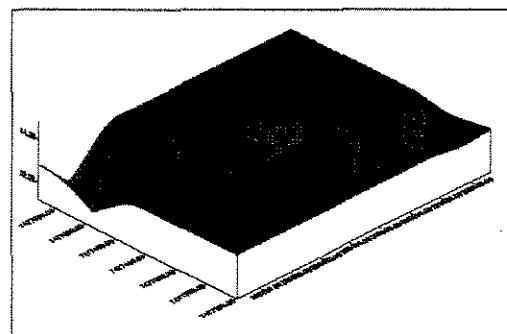


Figura 27: Grid interpolado da Argila

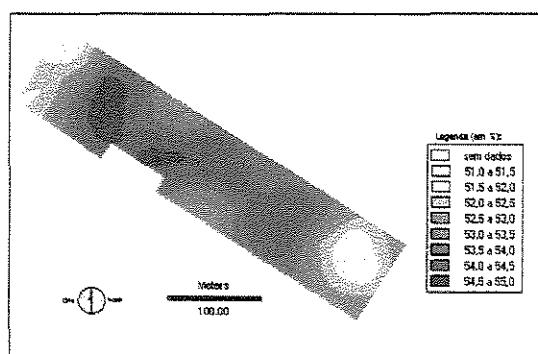


Figura 28: Mapa Geo-referenciado da Argila

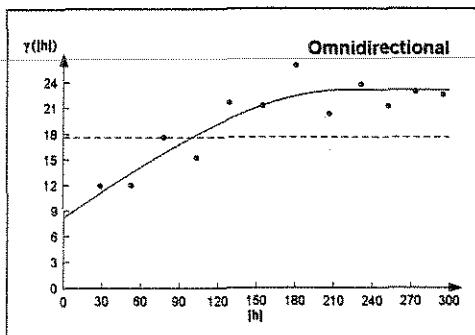


Figura 29: Semivariograma do Fósforo
Esférico: Gama(h)=8,28+14,94Sph.222(h)

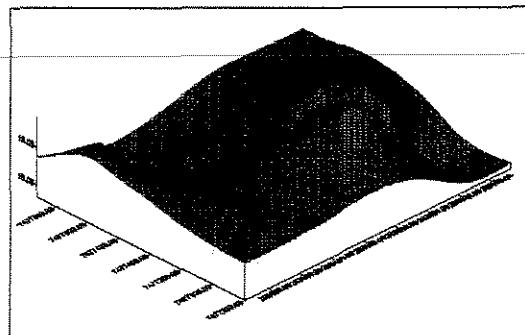


Figura 30: Grid interpolado do Fósforo

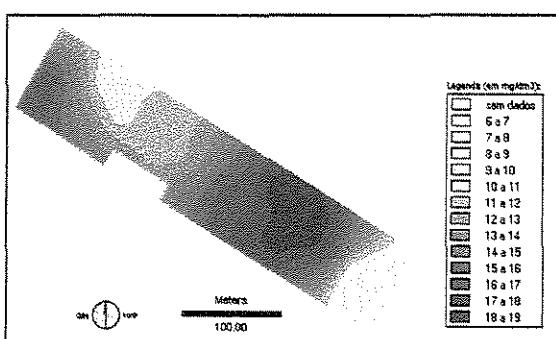


Figura 31: Mapa Geo-referenciado do Fósforo

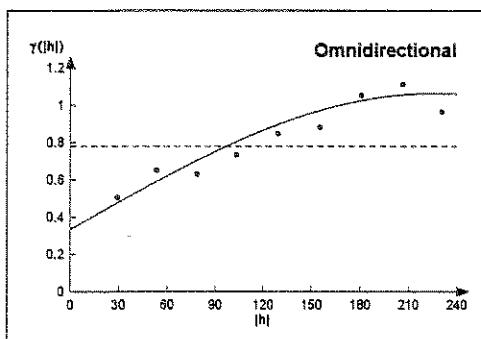


Figura 32: Semivariograma do Cálcio
Esférico: Gama(h)= $0,336+0,728\text{Sph.}223.2(h)$

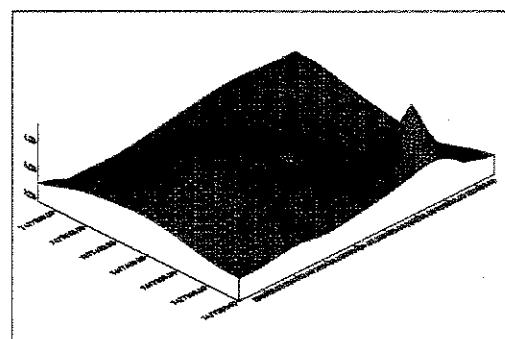


Figura 33: Grid interpolado do Cálcio

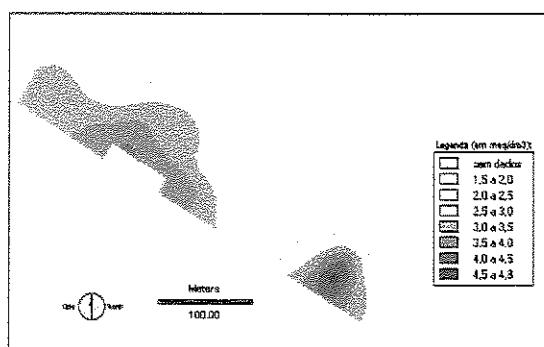


Figura 34: Mapa Geo-referenciado do Cálcio

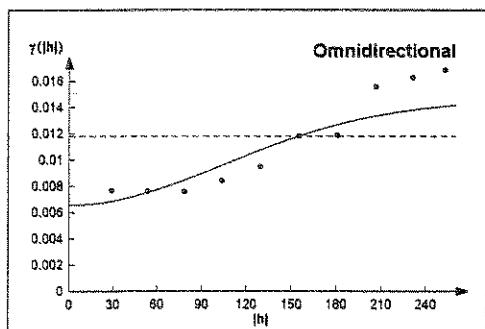


Figura 35: Semivariograma do Potássio
Gauss: Gama(h)= $0,0066+0,0084\text{Gauss.}260(h)$

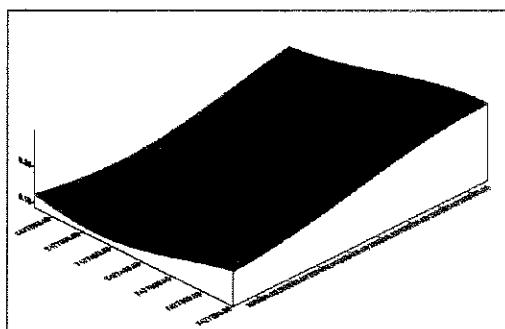


Figura 36: Grid interpolado do Potássio

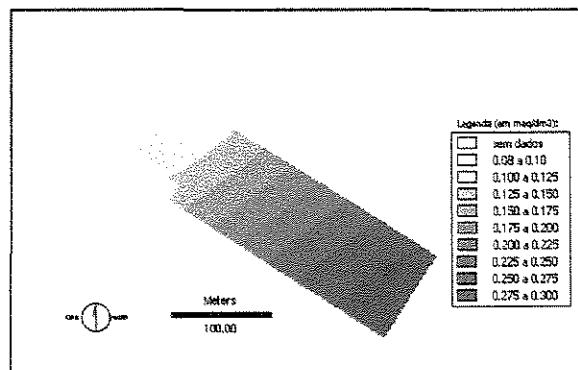


Figura 37: Mapa Geo-referenciado do Potássio

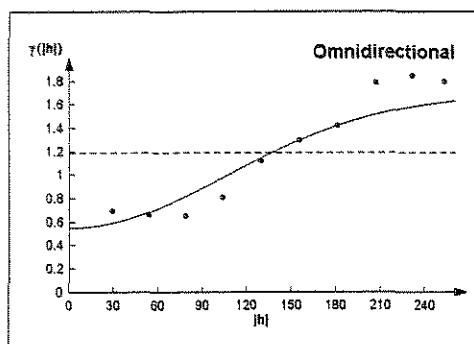


Figura 38: Semivariograma do H+Al
Gauss: $Gama(h)=0,552+1,14 \text{ Gauss}.260(h)$

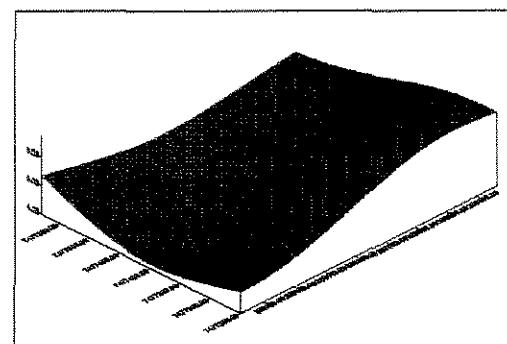


Figura 39: Grid interpolado do H+Al

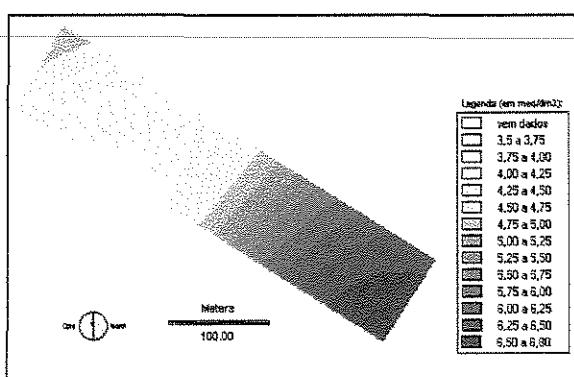


Figura 40: Mapa Geo-referenciado do H+Al

Definiu-se aqui que uma dependência espacial é forte quando o efeito pepita corresponde a um valor menor ou igual a 25% do patamar, dependência espacial moderada quando o efeito pepita corresponde a um valor maior que 25% e menor ou igual a 75% e fraca quando maior que 75% do patamar (CAMBARDELLA et al., 1985).

Verifica-se que todos os semivariogramas (Figuras 20, 23, 26, 29, 32, 35 e 38) apresentam moderada dependência espacial, com um efeito pepita variando de 32% a 66% do patamar, e seu alcance é sempre mais de 200 metros, exceto pela argila (87,4 metros). Quanto ao rendimento, seu semivariograma (Figura 17) indica dependência espacial um pouco mais forte que os demais, com um efeito pepita de 28% do patamar e um alcance de 195 metros.

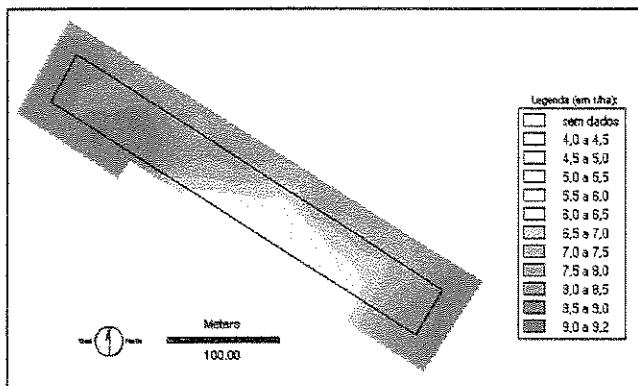


Figura 41: Rendimento Observado

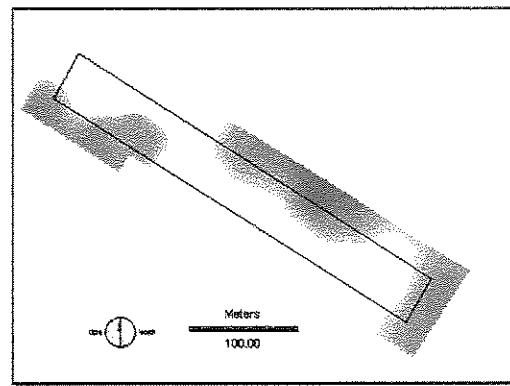


Figura 42: Rendimento Esperado com o modelo

As Figuras 41 e 42 mostram uma comparação entre o rendimento observado e o rendimento esperado a partir do modelo de regressão. Nota-se que este último apresenta algumas semelhanças com o da realidade obtido, comprovando ser este um razoável modelo de regressão.

Verifica-se com as figuras acima que os modelos se assemelham principalmente na parte mais alta à esquerda e ao longo de toda a linha lateral mais baixa (correspondente à linha B do *grid* de amostragem), assim como na parte mais baixa do mapa. A parte com pior correlação corresponde à linha D do *grid*, especialmente na mancha forte vermelha vista na Figura 42.

4.2.2. Regressões Lineares de Todas as Variáveis

Foram também feitas regressões lineares envolvendo todas as 20 variáveis de estudo. Verificou-se que o melhor coeficiente de determinação obtido para 2 variáveis foi de 83%, com os parâmetros ferro e zinco. A partir destes, o modelo foi sendo implementado, entrando a soma de bases, cobre, V% e o CTC. O Boro, embora apareça na tabela a seguir, não entra no modelo em virtude de não apresentar diferença significativa no grupo de 7 variáveis do modelo (Anexo 8).

Tabela 7: Modelos de Regressão passo-a-passo para todas as variáveis

Variável a entrar	Modelo de Regressão (Y = Rendimento)	5%		
		Coef.Det.(r2)	Pr>F	F tabela
Zn	Y = -4.55 + 13.66 Zn	28.79%	-	-
Fe	Y = -2.74 - 0.34 Fe + 19.71 Zn	83.03%	11704	2.9957
Sbases	Y = 8.00 - 0.45 Fe - 0.86 Sbases + 14.78 Zn	85.07%	9086.6	2.6049
Cu	Y = 7.18 + 0.36 Cu - 0.51 Fe - 0.93 Sbases + 14.78 Zn	87.12%	8088.3	2.3719
V%	Y = 2.71 + 0.47 Cu - 0.29 Fe - 2.78 Sbases + 0.2 V% + 11.64 Zn	89.94%	8558.2	2.2141
CTC	Y = -4.26 + 1 CTC + 0.53 Cu - 0.36 Fe - 4.85 Sbases + 0.36 V% + 11.8 Zn	91.53%	8614.8	2.0986
B	Y = -8.15 + 10.66 B + 1.19 CTC + 0.54 Cu - 0.31 Fe - 5.82 Sbases + 0.45 V% + 9.95 Zn	91.88%	7733.2	2.0096

Verifica-se com isto que o melhor modelo obtido para todas as variáveis fica sendo:

$$\text{Rendim} = -4,26 + \text{CTC} - 0,53 \text{ Cu} - 0,36 \text{ Fe} - 4,85 \text{ Sbases} + 0,36 \text{ V\%} + 11,8 \text{ Zinco ,}$$

explicando 91,53% do Rendimento.

Estatisticamente, este parece ser um ótimo modelo de regressão, mas analisando-o mais a fundo, nota-se que é formado basicamente por micronutrientes, que pouco têm a ver com o rendimento e variáveis “agrupadas”, como soma de bases, V% e CTC. Isto se deve ao fato de a regressão realizada pelo Idrisi ser espacial, e não tabular. O zinco apresentou semivariograma sem nenhuma estrutura definida (Figura 46), sendo portanto mais homogêneo e mais próximo a um valor médio parecido com o rendimento. O ferro, apesar de estar ligado ao potássio (deficiência de potássio pode causar acúmulo de ferro, citado anteriormente), possui distribuição

gaussiana, que também não deixa de ser suavizada, e moderada dependência espacial (efeito pepita=29% do patamar). A seguir são apresentados os semivariogramas, *grids* interpolados e mapas geo-referenciados destas novas variáveis do novo modelo de regressão.

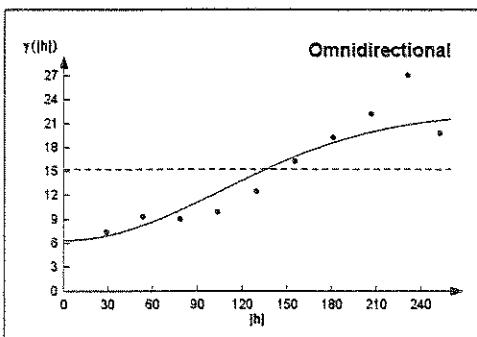


Figura 43: Semivariograma do Ferro
Gauss: $\text{Gama}(h)=6,4+16\text{Gauss}.260(h)$

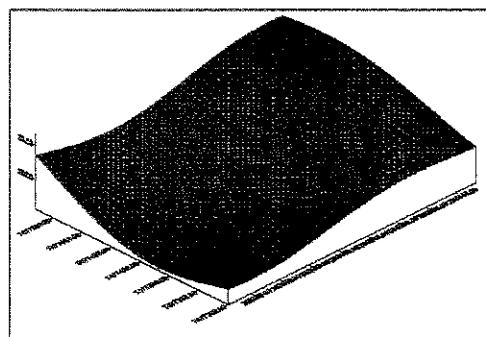


Figura 44: Grid interpolado do Ferro

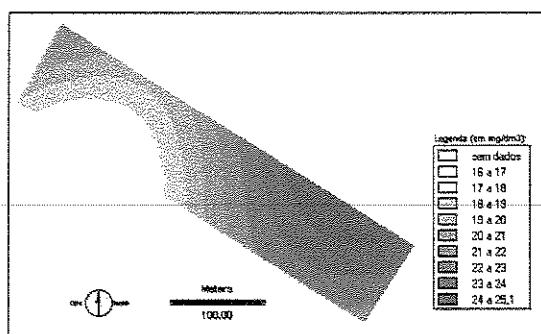


Figura 45: Mapa Geo-referenciado do Ferro

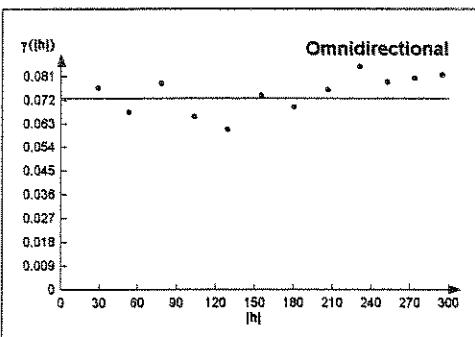


Figura 46: Semivariograma do Zinco
Sem estrutura, efeito pepita puro=0,0728

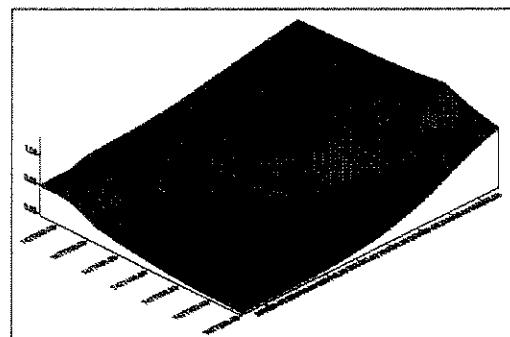


Figura 47: Grid interpolado do Zinco

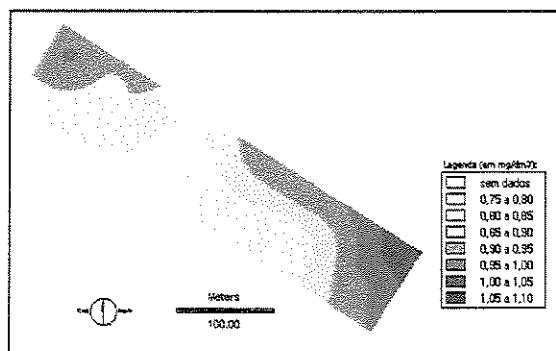


Figura 48: Mapa Geo-referenciado do Zinco

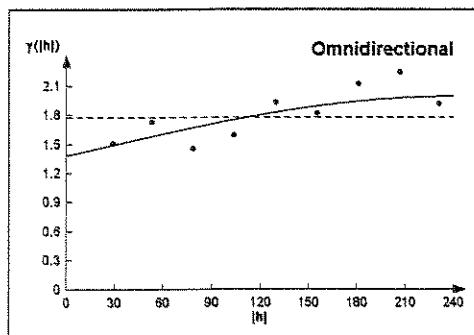


Figura 49: Semivariograma da Soma de Bases
Esférico: $\text{Gama}(h)=1,386+0,612 \text{ Sph.}240(h)$

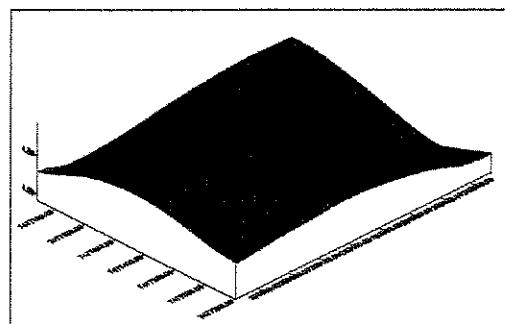


Figura 50: Grid interpolado da Soma de Bases

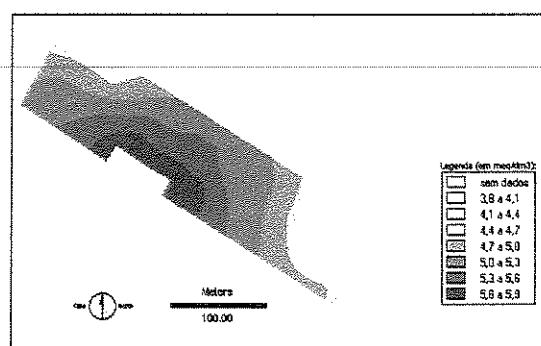


Figura 51: Mapa Geo-referenciado da Soma de Bases

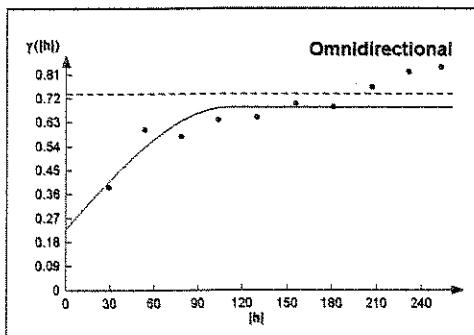


Figura 52: Semivariograma do Cobre
Esférico: $\text{Gama}(h)=0,232+0,456 \text{ Sph.}109,2(h)$

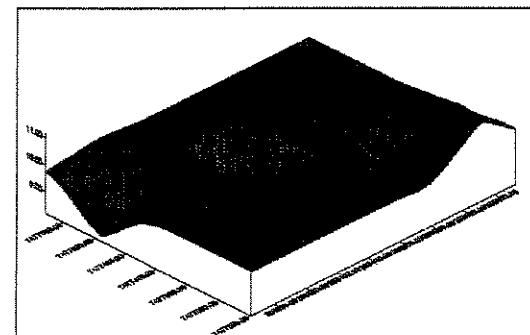


Figura 53: Grid interpolado do Cobre

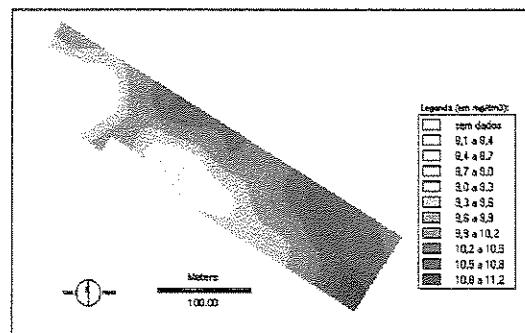


Figura 54: Mapa Geo-referenciado do Cobre

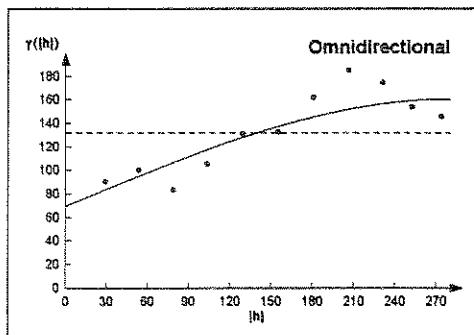


Figura 55: Semivariograma da V%
Esférico: Gama(h)=70+90,99 Sph.280(h)

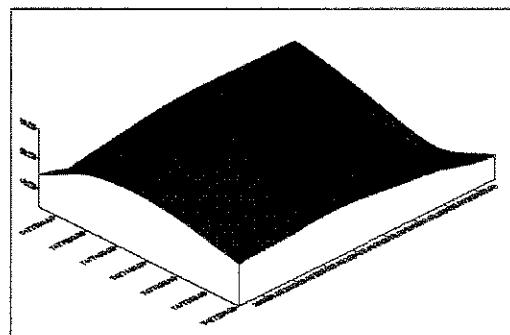


Figura 56: Grid interpolado da V%

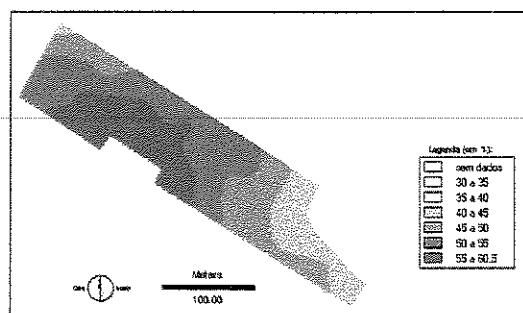


Figura 57: Mapa Geo-referenciado da V%

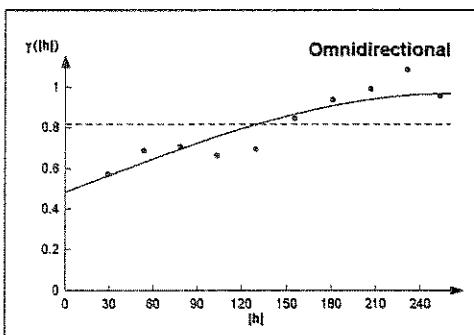


Figura 58: Semivariograma da CTC
Esférico: Gama(h)=0,486+0,486 Sph.260(h)

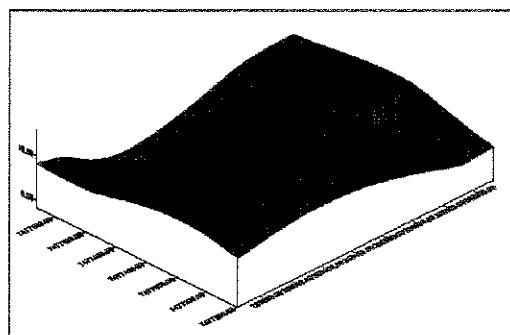


Figura 59: Grid interpolado da CTC

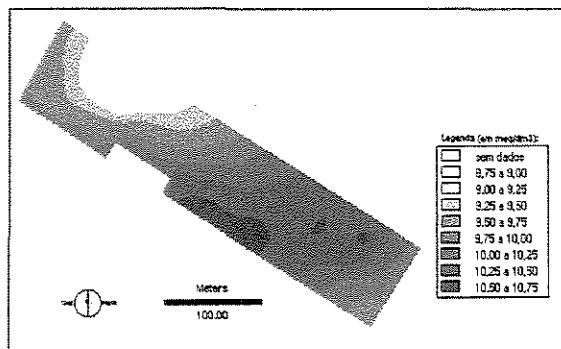


Figura 60: Mapa Geo-referenciado da CTC

Como dito anteriormente, o zinco não apresentou nenhuma dependência espacial (efeito pepita=100% do patamar).

Isto mostra que deve ser feito um estudo *a priori* das variáveis a serem analisadas sob o risco de se obter um modelo que foge um pouco da realidade desejada. A seguir são apresentados os mapas de rendimento observado (Figura 61) e de rendimento esperado (Figura 62) com o modelo de regressão ajustado.

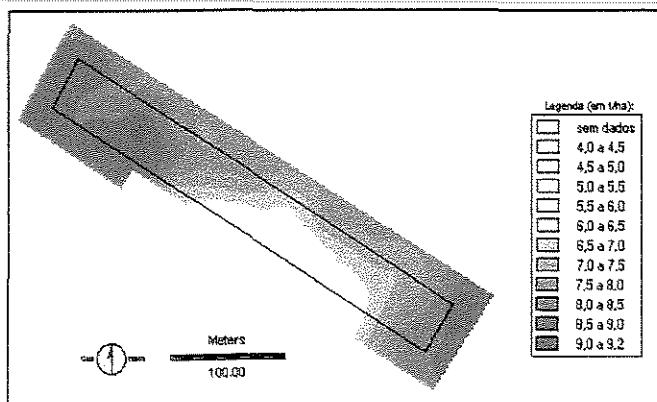


Figura 61: Mapa do Rendimento Observado

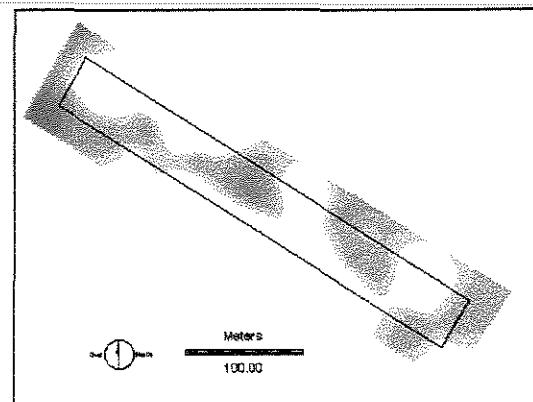


Figura 62: Rendimento Esperado

Como mostram as figuras anteriores, o modelo não traduz com fidelidade o rendimento da cultura. Apesar de um melhor coeficiente de determinação (91,53%), este modelo de regressão contendo todas as variáveis é nitidamente pior que o do item anterior, que possuía um pior coeficiente de determinação (82,10%), e era visualmente melhor que este.

O modelo obtido por meio da regressão linear de todas as variáveis (Figura 62) tem muitos picos e depressões que fogem da realidade do rendimento de cultura observado (Figura 61). O modelo interpolado com as 7 variáveis (Figura 42) não apresentava tal disparidade. Por isso ele foi considerado o melhor modelo de predição do rendimento de cultura

Novamente é comprovada a importância de um estudo mais a fundo das variáveis de estudo, juntamente com seus modelos de semivariogramas.

V – DISCUSSÃO DOS RESULTADOS

Como citado anteriormente, mesmo áreas pedologicamente idênticas possuem variabilidade diferenciada quando submetidas a diferentes práticas de manejo (CORÁ, 1997).

Assim sendo, torna-se difícil a comparação de resultados obtidos por outros autores com os dados aqui obtidos. Por exemplo, NIELSEN et al. (1973) obtiveram distribuição normal para teores de argila e areia. A distribuição encontrada para argila não foi normal. Alguns autores, citados por SILVA (1988) confirmam a distribuição normal para dados de granulometria. Foi mostrado aqui que dos dados de granulometria, somente a areia e o silte fino possuíam distribuição normal, e só o silte fino era independente espacialmente.

SILVA (1988) encontrou uma estrutura de variância para teores de silte e argila, mas no entanto, não se atingiu um patamar para o semivariograma. Constatou-se aqui que o silte fino não apresentou estrutura de variograma e a argila atingiu um patamar.

VIEIRA et al. (1997) constataram dependência espacial bastante diferenciada para os resultados de análise granulométrica e o modelo esférico foi o de melhor ajuste para os semivariogramas. Verificou-se aqui que das 20 variáveis, 13 possuíam modelo esférico, 4 modelos gaussianos e 3 independência espacial como melhor ajuste para os semivariogramas.

Existem muitos outros trabalhos realizados no exterior, mas não é possível fazer uma boa comparação, em vista dos solos serem muito diferentes dos encontrados no Brasil. Apenas pode-se valer da metodologia aplicada por estes.

Deve-se ressaltar que cada área deve ser tratada de maneira diferente. Verificou-se por exemplo que não se pode utilizar os valores limites para o fósforo, potássio, magnésio, V% e pH considerados padrões para os laboratórios de análises químicas agrícolas, com os teores muito baixo, baixo, médio, alto e muito alto.

Estes limites são apresentados na Tabela 8 abaixo:

Tabela 8: Valores Limites dos Atributos para os Laboratórios de Análises Químicas

	P-resina (mg/dm ³)	Potássio (meq/dm ³)	Magnésio (meq/dm ³)
M. baixo	0-6	0-0,07	
Baixo	7-15	0,08-0,15	0-0,4
Médio	16-40	0,16-0,30	0,5-0,8
Alto	41-80	0,31-0,60	> 0,8
M. alto	> 80	> 0,60	

	V%	Acidez	pH
M. baixo	0-25	M. alta	até 4,3
Baixo	26-50	Alta	4,4-5,0
Médio	51-70	Média	5,1-5,5
Alto	71-90	Baixa	5,6-6,0
M. alto	> 90	M. baixa	> 6,0

Foram feitos mapas geo-referenciados interpolados para estes limites padrões para o fósforo-resina (Figura 63), potássio (Figura 64), magnésio (Figura 65), saturação por bases (Figura 66) e pH (Figura 67).

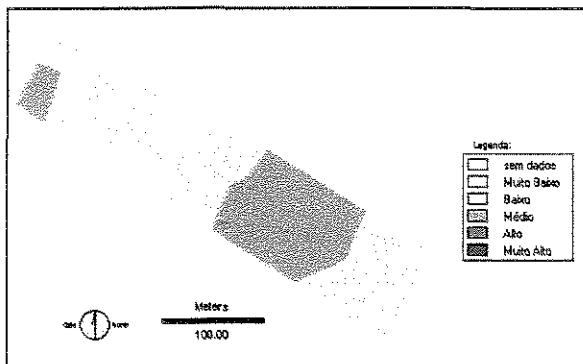


Figura 63: Mapa dos Limites Padrões para o P.

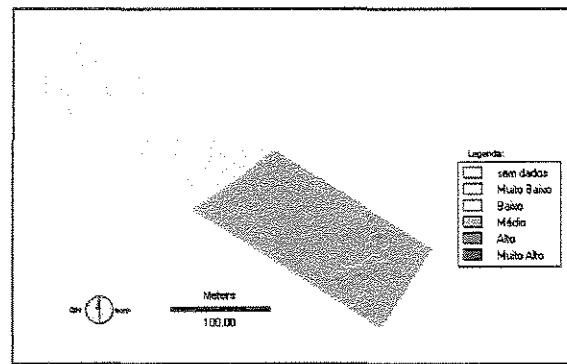


Figura 64: Mapa dos Limites Padrões para o K.

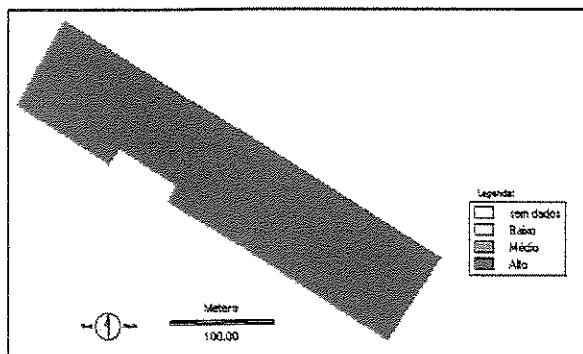


Figura 65: Mapa dos Limites Padrões para o Mg.

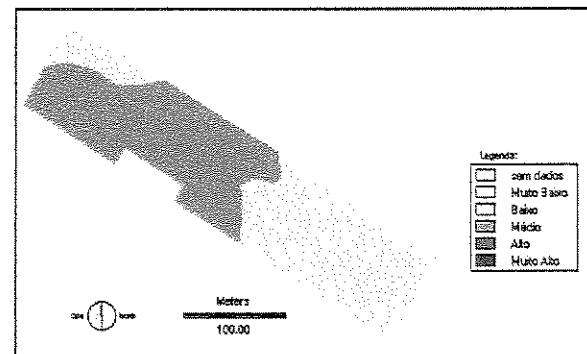


Figura 66: Mapa dos Limites Padrões para a V%.

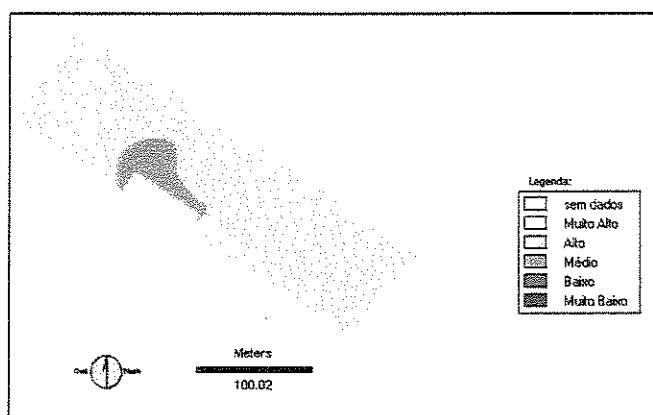


Figura 67: Mapa dos Limites Padrões para o pH.

Verifica-se pelas Figuras 63 a 67, que, utilizando-se os intervalos usados para classificar os parâmetros P, K, Mg, V% e pH, não existe uma variabilidade considerável, o que pode implicar numa inviabilidade de se aplicar o conceito de manejo diferenciado.

Como exemplo, na Figura 65 só existe uma categoria de classe, um teor alto de magnésio, correspondendo a mais de 0,8 meq/dm³. Como o valor mínimo obtido com a interpolação foi mais de 1, o mapa não acrescenta informações.

Deve-se também tomar muito cuidado quanto ao *grid* a ser definido para a interpolação dos dados. É claro que quanto menor o espaçamento, resultará em mais precisão, mas a um custo maior de análise e maior tempo de processamento, em função da quantidade de dados. Um *grid* de 5x5 metros, por exemplo, a ser interpolado no Surfer exige 46 Kb de dados para cada mapa. Já

um mapa com resolução de *pixel* de 2x2 metros exige 279 Kb de espaço, e um com resolução de 1x1 metro exige 1,1 Mb de espaço para cada mapa criado. Seriam mais de 20 Mb só de mapas-base se utilizasse esta resolução. Definiu-se assim a resolução de 2x2 metros para o tamanho do *pixel*, ficando com um volume de dados de 166 linhas por 212 colunas em cada mapa interpolado.

Também com o Variowin foi possível a escolha do melhor ajuste de modelo de semivariograma, pois o programa proporcionava o erro pelo método dos mínimos quadrados para cada modelo escolhido, permitindo a escolha do modelo com o menor erro obtido.

VI – CONCLUSÕES

De maneira geral, os resultados obtidos foram satisfatórios. Foi mostrado que a metodologia de processamento dos dados é um fator importante neste tipo de estudo. Pequenas alterações na metodologia acarretam grandes transformações nas análises finais.

O melhor modelo de regressão linear multivariada obtido foi:

Rendimento = $-13,23 + 0,38 \text{ Argila} + 0,84 \text{ Ca} + 1,4 \text{ HAl} - 28,3 \text{ K} - 5,08 \text{ Mg} + 1,28 \text{ MO} + 0,09 \text{ P}$
explicando 82,1% do rendimento da cultura de milho.

O estudo mostrou que os intervalos de classificação de P, K, Mg, V% e pH atualmente utilizados devem ser reconsiderados em função da agricultura de precisão, fazendo-se uma análise de custo-benefício de novos intervalos.

O programa Variowin facilitou a criação de semivariogramas, dada sua capacidade em mostrar o erro obtido com os ajustes de modelo, podendo-se escolher o melhor modelo ajustado e sabendo de quanto é seu erro. O Surfer 6.0 também foi um bom auxílio para a criação de *grids* de interpolação, pois possibilita a entrada do melhor ajuste de modelo, podendo-se controlar inclusive o efeito pepita, o patamar e o alcance de cada mapa a ser criado.

O Idrisi 2.0 também se mostrou adequado para as análises de regressões lineares multivariadas realizadas no estudo, uma vez que realiza regressões sem a perda da posição espacial dos dados, pois as realiza *pixel a pixel*, sendo mais adequado para processamento de dados para a agricultura de precisão do que programas de estatística convencionais, como o SAS, que não considera a posição espacial dos dados e modifica a posição dos limites dos atributos do solo.

A metodologia deste trabalho envolveu técnicas de estatística básica para análises descritivas de atributos do solo, técnicas de geoestatística para as criações de semivariogramas e interpolações de atributos, modelagem de dados por meio de correlações e regressões e Sistemas de Informação Geográfica para manipular, gerenciar e analisar os mapas geo-referenciados, técnicas estas fundamentais para a agricultura de precisão. Assim, espera-se que este trabalho contribua metodologicamente tanto para quem deseja utilizar a agricultura de precisão quanto para quem já a esteja utilizando, no sentido de apontar novos caminhos à procura de uma melhor compreensão sobre a produtividade e otimização de recursos.

A metodologia utilizada pode ainda sofrer adaptações, dependendo do estudo realizado, uma vez que o tema é relativamente novo no país. São, portanto, necessários mais estudos a este respeito, ficando a sugestão para um trabalho futuro de utilizar os pontos amostrais para a modelagem, interpolando por krigagem somente o resultado final do modelo, evitando o acúmulo de erros em cada etapa de interpolação e correlação de atributos.

Mostrou-se também que não se deve escolher o primeiro modelo que obtiver, pois a mínima variação na estrutura do modelo altera o mapa interpolado, e por conseguinte, sua relação com o modelo de regressão também se altera, podendo mudar radicalmente a análise final dos dados, e sua conclusão. Fica também a sugestão de um trabalho sobre uma análise de sensibilidade de mudança de modelo para uma melhor escolha antes de gerar o mapa final.

Outro trabalho também poderia utilizar semivariogramas robustos para as variáveis que não apresentaram uma normalidade dos dados e fazer uma comparação com os semivariogramas comuns para estes atributos, através dos mapas interpolados, verificando como muda o modelo final de regressão por meio das mudanças destes semivariogramas.

ANEXO 1: Dados de Granulometria

Amostra	% silte fino	% silte grosso	% argila	% areia total
B1	8	16	50	26
B2	7	12	54	27
B3	7	10	55	28
B4	7	11	56	25
B5	8	11	55	26
B6	8	10	56	25
B7	8	12	55	24
B8	8	14	52	26
B9	8	15	52	25
B10	7	19	51	23
B11	7	11	56	26
B12	8	11	55	26
B13	9	11	55	25
B14	7	12	54	27
B15	8	13	52	27
B16	7	11	53	29
C1	6	12	54	28
C2	7	12	52	29
C3	6	11	56	27
C4	9	10	55	25
C5	9	10	52	28
C6	5	11	56	28
C7	8	10	56	26
C8	8	10	56	26
C9	8	11	55	26
C10	6	12	56	26
C11	10	10	54	26
C12	6	14	54	26
C13	5	16	54	25
C14	8	15	50	27
C15	7	12	52	29
C16	7	15	48	30
D1	7	12	51	30
D2	9	10	50	31
D3	7	7	58	28
D4	6	11	55	28
D5	6	11	54	28
D6	7	13	52	28
D7	8	12	52	28
D8	7	10	55	28
D9	7	10	55	28
D10	8	11	54	27
D11	8	10	53	28
D12	7	8	55	29
D13	7	10	56	27
D14	7	10	54	28
D15	9	10	49	32
D16	10	10	53	27

.....

ANEXO 2: Dados de Fertilidade

Unidades	mg/dm3	%		mmol/dm3			meq/100cm3				%
Amostras	P-res.	Mat.Org.	pH	K	Ca	Mg	H+Al	S.Bases	CTC	V%	
B1	18	3,2	5,1	0,06	3,2	2,1	4,3	5,4	9,7	55,5	
B2	13	2,9	4,8	0,06	2,5	1,5	5,2	4,1	9,3	43,8	
B3	15	3,6	5,0	0,08	3,6	2,2	4,3	5,9	10,2	57,8	
B4	13	3,6	5,2	0,06	4,0	2,8	3,8	6,9	10,7	64,4	
B5	14	3,3	5,1	0,28	4,5	2,1	4,3	6,9	11,2	61,5	
B6	12	3,0	5,2	0,14	3,9	2,1	3,8	6,1	9,9	61,8	
B7	13	3,5	5,3	0,23	4,6	2,6	3,4	7,4	10,8	68,6	
B8	15	3,6	5,4	0,11	4,6	3,3	3,4	8,0	11,4	70,2	
B9	17	3,6	5,0	0,22	3,7	2,3	4,7	6,2	10,9	57,0	
B10	17	3,8	4,6	0,45	2,3	1,8	5,8	4,6	10,4	44,0	
B11	18	3,8	4,7	0,20	2,5	2,9	5,8	5,6	11,4	49,1	
B12	22	3,5	4,9	0,97	2,2	2,1	5,2	5,3	10,5	50,3	
B13	15	3,3	4,5	0,07	1,6	2,2	6,5	3,9	10,4	37,3	
B14	16	3,5	4,9	0,19	2,8	2,0	5,0	5,0	10,0	50,2	
B15	51	5,5	5,2	0,65	4,4	3,2	4,7	8,3	13,0	63,7	
B16	9	3,2	4,6	0,33	2,5	1,2	5,2	4,0	9,2	43,7	
C1	21	4,1	5,2	0,10	3,9	2,5	3,8	6,5	10,3	63,1	
C2	12	3,0	5,2	0,06	3,4	2,1	3,4	5,6	9,0	62,1	
C3	12	3,0	5,3	0,11	3,0	2,3	3,4	5,4	8,8	61,4	
C4	7	2,6	5,2	0,04	2,8	1,8	3,1	4,6	7,7	59,9	
C5	11	3,3	5,4	0,06	4,3	2,9	3,1	7,3	10,4	70,1	
C6	10	3,5	4,7	0,07	2,8	1,4	5,2	4,3	9,5	45,1	
C7	10	3,5	4,9	0,12	2,6	1,6	4,7	4,3	9,0	47,9	
C8	12	3,0	4,6	0,08	2,1	1,6	5,8	3,8	9,6	39,5	
C9	20	3,6	4,7	0,18	2,2	1,9	5,8	4,3	10,1	42,5	
C10	12	3,5	4,7	0,14	2,0	1,8	5,8	3,9	9,7	40,5	
C11	17	3,5	5,0	0,08	2,8	2,4	4,7	5,3	10,0	52,9	
C12	15	3,2	4,6	0,23	1,7	1,9	5,8	3,8	9,6	39,8	
C13	22	3,5	4,5	0,44	1,8	1,6	7,2	3,8	11,0	34,8	
C14	23	4,1	4,6	0,37	2,1	1,9	6,5	4,4	10,9	40,2	
C15	26	3,5	4,6	0,54	2,1	1,6	6,5	4,2	10,7	39,5	
C16	8	3,3	4,4	0,31	1,7	1,0	7,2	3,0	10,2	29,5	
D1	16	3,6	4,9	0,08	2,8	1,8	4,7	4,7	9,4	49,9	
D2	11	3,0	5,0	0,04	2,8	1,7	4,3	4,5	8,8	51,4	
D3	6	2,6	4,5	0,04	1,7	1,0	5,2	2,7	7,9	34,5	
D4	10	3,0	4,9	0,06	2,4	1,5	4,3	4,0	8,3	47,9	
D5	16	3,2	5,1	0,03	3,2	2,0	3,8	5,2	9,0	57,9	
D6	11	3,2	4,9	0,06	2,8	1,4	4,7	4,3	9,0	47,5	
D7	13	3,3	5,3	0,15	3,6	2,3	3,4	6,1	9,5	64,0	
D8	12	3,5	5,2	0,10	3,4	2,6	3,8	6,1	9,9	61,6	
D9	16	3,5	5,0	0,14	2,0	2,1	4,7	4,7	9,4	50,2	
D10	16	3,8	5,2	0,08	3,5	2,9	4,3	6,5	10,8	60,1	
D11	23	3,6	5,2	0,18	2,8	2,8	4,3	5,8	10,1	57,3	
D12	17	4,1	4,8	0,26	2,1	2,3	5,8	4,7	10,5	44,6	
D13	23	3,9	4,7	0,22	1,7	2,4	6,5	4,3	10,8	39,9	
D14	13	3,5	4,7	0,27	2,0	1,8	5,8	4,1	9,9	41,2	
D15	14	3,8	4,1	0,09	1,3	0,9	9,9	2,3	12,2	18,8	
D16	9	3,3	4,4	0,31	1,9	0,9	6,5	3,1	9,6	32,4	

Unidades Amostras	mg/dm ³				
	B	Cu	Fe	Mn	Zn
B1	0,26	7,9	18,0	16,8	0,7
B2	0,25	8,3	18,4	18,6	0,7
B3	0,31	9,1	20,2	20,2	1,0
B4	0,26	9,7	16,7	26,0	0,9
B5	0,27	10,3	20,1	39,3	1,3
B6	0,22	9,1	15,3	26,0	0,6
B7	0,25	8,8	16,2	20,6	0,6
B8	0,28	9,5	18,8	25,0	0,7
B9	0,31	9,2	21,3	21,5	0,7
B10	0,20	8,8	22,8	18,7	1,0
B11	0,22	9,6	25,2	24,0	0,8
B12	0,27	9,6	20,9	18,5	0,9
B13	0,24	9,2	18,4	28,2	0,7
B14	0,28	9,6	22,3	29,7	0,9
B15	0,51	10,1	24,4	48,7	3,1
B16	0,37	11,7	20,5	26,4	1,0
C1	0,27	8,0	17,3	29,3	1,4
C2	0,24	8,6	17,4	28,4	0,9
C3	0,23	7,8	13,8	21,4	0,8
C4	0,21	9,0	12,0	19,6	0,3
C5	0,20	9,7	16,4	30,1	1,0
C6	0,23	8,7	20,2	40,4	0,8
C7	0,28	9,0	18,9	27,6	1,1
C8	0,28	8,8	18,1	19,7	0,6
C9	0,34	9,3	22,5	32,1	0,9
C10	0,28	9,2	24,0	19,8	0,8
C11	0,23	9,8	21,6	20,4	0,6
C12	0,26	10,0	24,9	19,4	0,4
C13	0,24	10,0	25,1	21,2	0,5
C14	0,27	10,7	30,2	34,2	0,8
C15	0,49	10,9	24,5	36,1	1,2
C16	0,39	9,7	25,2	31,7	0,5
D1	0,29	10,0	21,9	39,7	1,5
D2	0,26	9,7	21,3	33,1	1,0
D3	0,23	8,9	20,1	28,9	0,6
D4	0,29	9,5	17,7	28,7	1,3
D5	0,29	10,4	20,1	41,1	1,0
D6	0,28	11,2	21,0	45,9	0,8
D7	0,28	4,4	7,8	18,8	0,4
D8	0,26	9,9	19,3	44,8	1,0
D9	0,21	10,9	62,7	27,9	1,1
D10	0,26	10,0	26,7	36,9	1,1
D11	0,20	9,6	21,9	34,9	1,1
D12	0,25	10,5	34,1	39,7	1,3
D13	0,22	10,7	31,4	41,3	1,0
D14	0,19	11,2	27,5	43,3	0,8
D15	0,38	10,3	38,8	46,8	1,0
D16	0,29	12,2	26,2	27,1	1,3

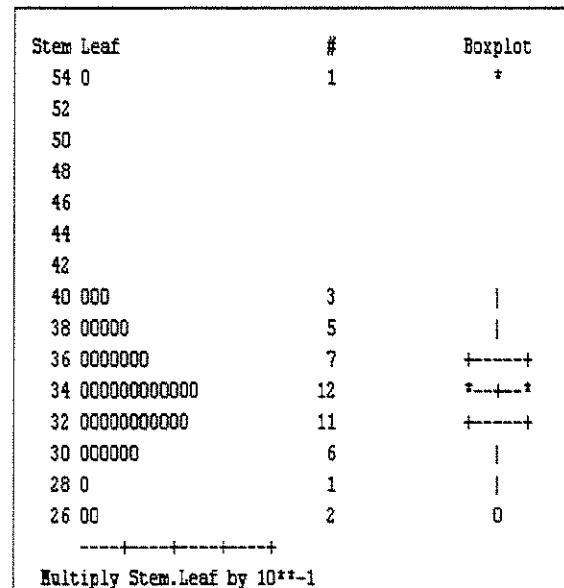
ANEXO 3: Dados de Rendimento de Cultura

Unidades	(Kg/2.5m2)	(t/ha)
Amostra	Rendim	Rendim
B1	4,19	9,30
B2	3,33	7,41
B3	4,75	10,56
B4	3,34	7,42
B5	4,75	10,55
B6	2,35	5,21
B7	2,80	6,21
B8	1,95	4,34
B9	2,00	4,43
B10	2,65	5,90
B11	1,95	4,33
B12	2,12	4,70
B13	2,13	4,74
B14	3,17	7,04
B15	3,96	8,80
B16	3,84	8,53
C1	3,82	8,48
C2	3,58	7,96
C3	3,44	7,63
C4	4,76	10,57
C5	4,03	8,95
C6	3,87	8,61
C7	3,41	7,58
C8	3,41	7,57
C9	3,16	7,01
C10	2,43	5,39
C11	2,60	5,78
C12	3,23	7,17
C13	3,09	6,87
C14	3,13	6,96
C15	3,53	7,84
C16	3,57	7,94
D1	4,28	9,50
D2	4,34	9,63
D3	2,98	6,61
D4	3,93	8,73
D5	3,05	6,78
D6	2,91	6,46
D7	3,60	8,01
D8	3,74	8,31
D9	3,04	6,76
D10	2,65	5,88
D11	4,31	9,57
D12	3,13	6,95
D13	3,47	7,71
D14	2,84	6,30
D15	3,04	6,76
D16	4,27	9,49

ANEXO 4: Análises Descritivas das Variáveis de Estudo

Moments			
N	48	Sum Wgts	48
Mean	3.458333	Sum	166
Std Dev	0.455619	Variance	0.207589
Skewness	1.747155	Kurtosis	7.711734
USS	583.84	CSS	9.756667
CV	13.17452	Std Mean	0.065763
T: Mean=0	52.58788	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
H(Sign)	24	Pr>= H	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.868523	Pr<W	0.0001
Quantiles(Def=5)			
100% Max	5.5	99%	5.5
75% Q3	3.6	95%	4.1
50% Med	3.5	90%	3.9
25% Q1	3.2	10%	3
0% Min	2.6	5%	2.9
		1%	2.6
Range	2.9		
Q3-Q1	0.4		
Mode	3.5		

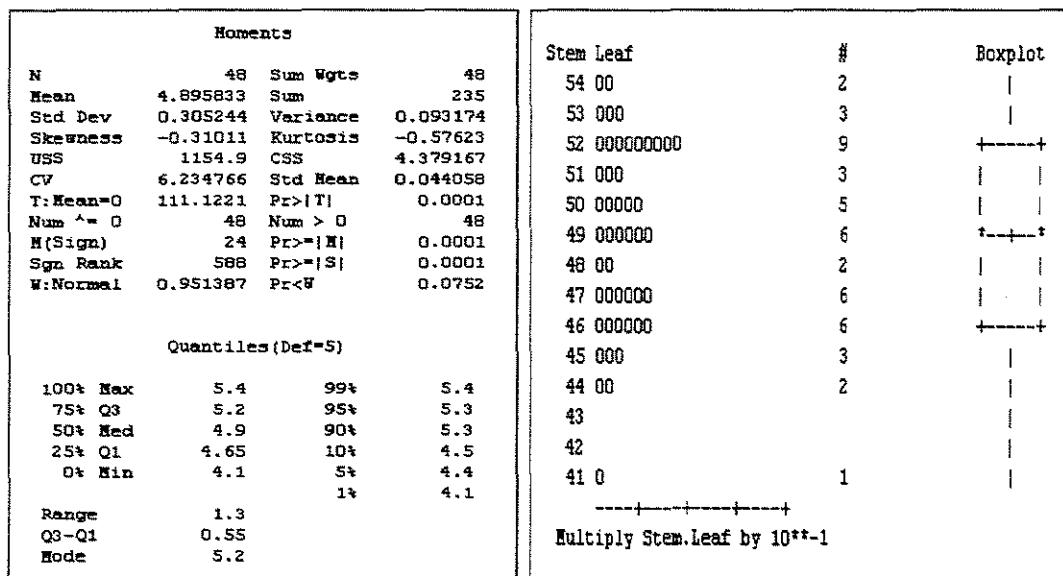
Análises da Matéria Orgânica



Ramo-e-folhas e Box-plot da Matéria Orgânica

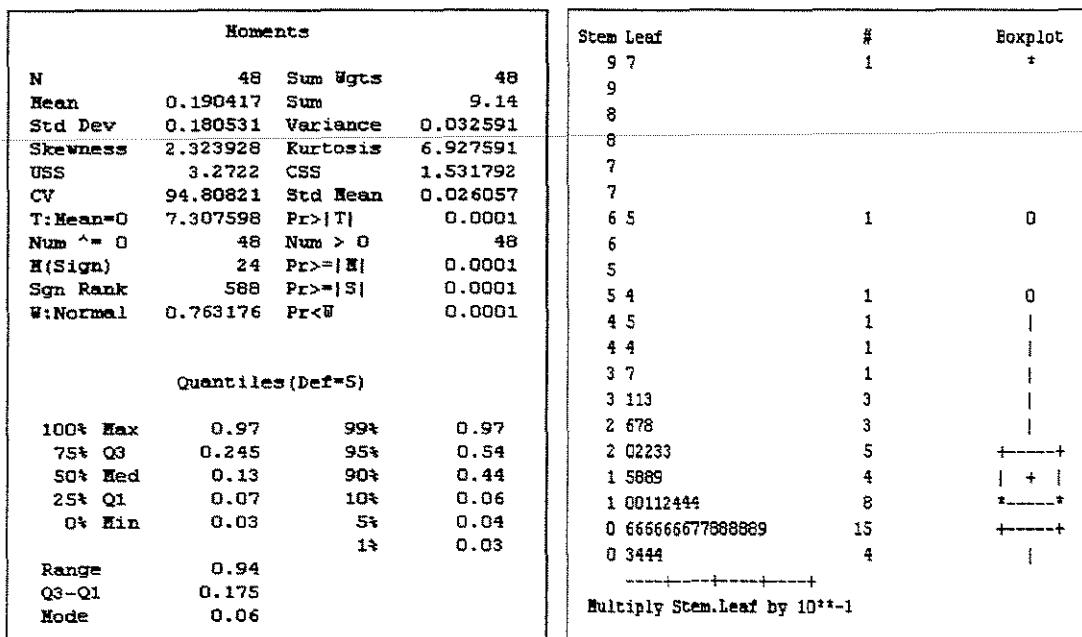
Moments			
N	47	Sum Wgts	47
Mean	3.414894	Sum	168.5
Std Dev	0.345769	Variance	0.119556
Skewness	-0.19852	Kurtosis	8.181488
USS	553.59	CSS	5.499574
CV	10.12531	Std Mean	0.058436
T: Mean=0	67.78888	Pr> T	0.0001
Num ^= 0	47	Num > 0	47
H(Sign)	23.5	Pr>= H	0.0001
Sgn Rank	564	Pr>= S	0.0001
W:Normal	8.953299	Pr<W	0.0956
Quantiles(Def=5)			
100% Max	4.1	99%	4.1
75% Q3	3.6	95%	4.1
50% Med	3.5	90%	3.8
25% Q1	3.2	10%	3
0% Min	2.6	5%	2.9
		1%	2.6
Range	1.5		
Q3-Q1	0.4		
Mode	3.5		

Análises da Matéria Orgânica sem *Outliers*



Análises do pH

Ramo-e-folhas e Box-plot do pH

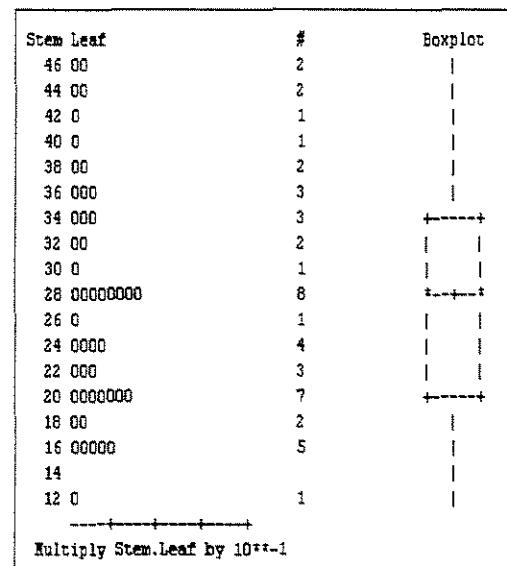


Análises do Potássio

Ramo-e-folhas e Box-plot do Potássio

Moments			
N	48	Sum Wgts	48
Mean	2.795833	Sum	134.2
Std Dev	0.891558	Variance	0.794876
Skewness	0.49483	Kurtosis	-0.69669
USS	412.56	CSS	37.35917
CV	31.88882	Std Mean	0.128685
T:Mean=0	21.72612	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
H(Sign)	24	Pr>= H	0.0001
Sgn Rank	588	Pr>= S	0.0001
U:Normal	0.936305	Pr<W	0.0164
Quantiles(Def=5)			
100% Max	4.6	99%	4.6
75% Q3	3.45	95%	4.5
50% Med	2.8	90%	4.3
25% Q1	2.1	10%	1.7
0% Min	1.3	5%	1.7
		1%	1.3
Range	3.3		
Q3-Q1	1.35		
Mode	2.8		

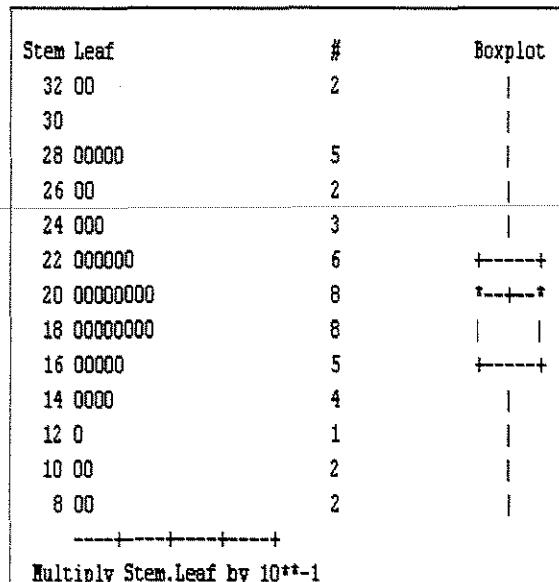
Análises do Cálcio



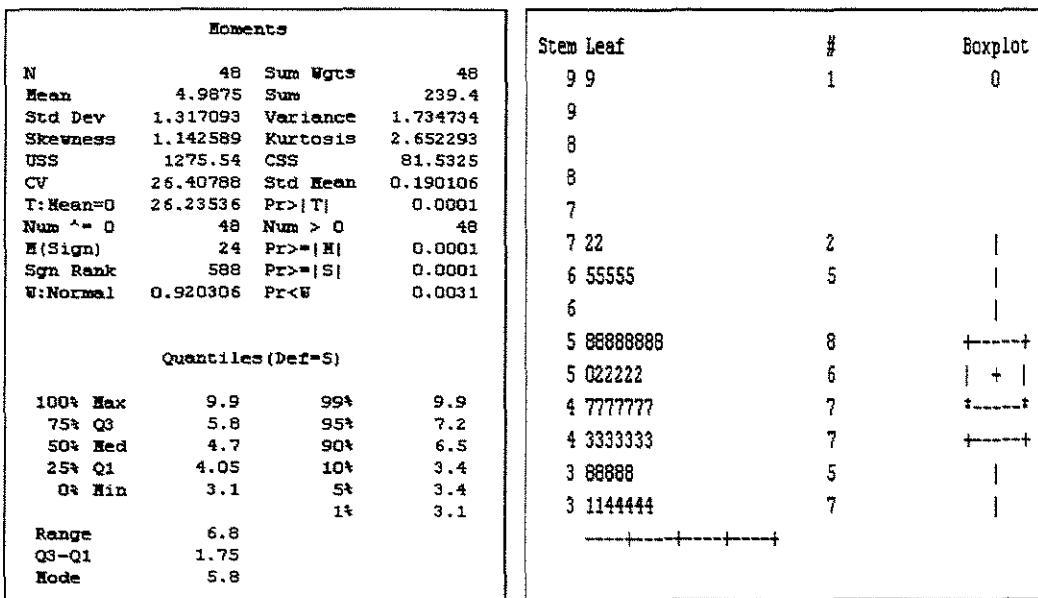
Ramo-e-folhas e Box-plot do Cálcio

Moments			
N	48	Sum Wgts	48
Mean	2.022917	Sum	97.1
Std Dev	0.580623	Variance	0.337123
Skewness	0.077025	Kurtosis	-0.25435
USS	212.27	CSS	15.84479
CV	28.70228	Std Mean	0.083806
T:Mean=0	24.13817	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
H(Sign)	24	Pr>= H	0.0001
Sgn Rank	588	Pr>= S	0.0001
U:Normal	0.973952	Pr<W	0.5216
Quantiles(Def=5)			
100% Max	3.3	99%	3.3
75% Q3	2.35	95%	2.9
50% Med	2.05	90%	2.9
25% Q1	1.6	10%	1.2
0% Min	0.9	5%	1
		1%	0.9
Range	2.4		
Q3-Q1	0.75		
Mode	2.1		

Análises do Magnésio



Ramo-e-folhas e Box-plot do Magnésio



Análises do H+Al

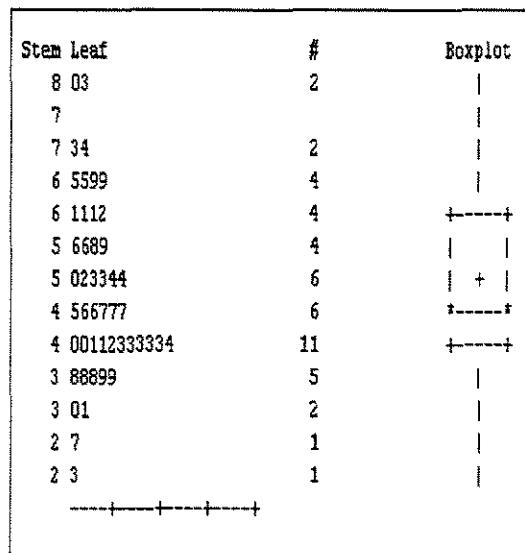
Ramo-e-folhas e Box-plot do H+Al

Moments			
N	47	Sum Wgts	47
Mean	4.882979	Sum	229.5
Std Dev	1.112852	Variance	1.23666
Skewness	0.279436	Kurtosis	-0.78268
USS	1177.53	CSS	56.88638
CV	22.77486	Std Mean	0.16221
T:Mean=0	38.18291	Pr> T	0.0001
Num ^= 0	47	Num > 0	47
M(Sign)	23.5	Pr>= M	0.0001
Sgn Rank	564	Pr>= S	0.0001
W:Normal	0.943143	Pr<W	0.0357
Quantiles(Def=5)			
100% Max	7.2	99%	7.2
75% Q3	5.8	95%	6.5
50% Med	4.7	90%	6.5
25% Q1	3.8	10%	3.4
0% Min	3.1	5%	3.4
		1%	3.1
Range	4.1		
Q3-Q1	2		
Mode	5.8		

Análises do H+Al sem outliers

Moments			
N	48	Sum Wgts	48
Mean	5.025	Sum	241.2
Std Dev	1.346785	Variance	1.81383
Skewness	0.452565	Kurtosis	-0.08583
USS	1297.28	CSS	85.25
CV	26.80169	Std Mean	0.194392
T:Mean=0	25.84967	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
H(Sign)	24	Pr>= H	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.965773	Pr<W	0.2809
Quantiles (Def=5)			
100% Max	8.3	99%	8.3
75% Q3	6	95%	7.4
50% Med	4.7	90%	6.9
25% Q1	4.1	10%	3.8
0% Min	2.3	5%	3
		1%	2.3
Range	6		
Q3-Q1	1.9		
Mode	4.3		

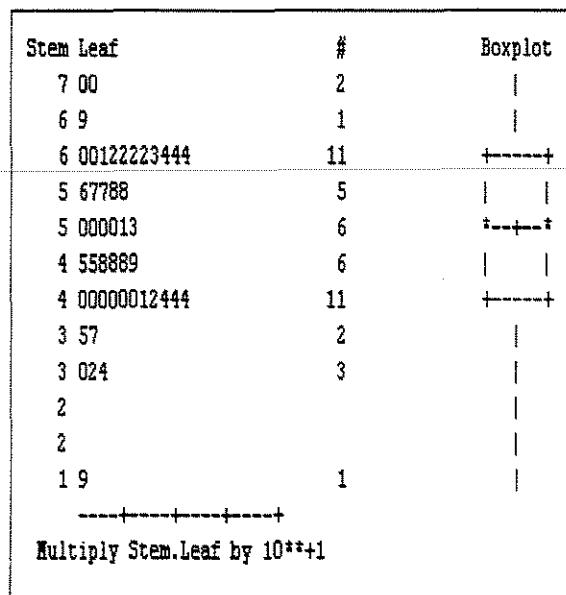
Análises da Soma de Bases



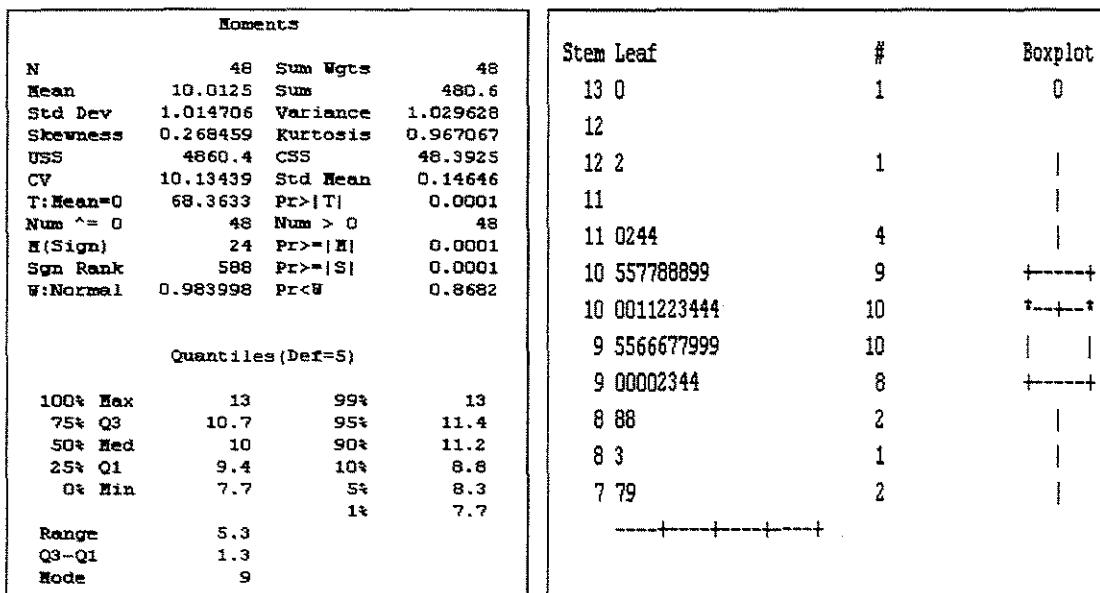
Ramo-e-folhas e Box-plot da Soma de Bases

Moments			
N	48	Sum Wgts	48
Mean	50.14375	Sum	2406.9
Std Dev	11.60906	Variance	134.7702
Skewness	-0.27754	Kurtosis	-0.31542
USS	127025.2	CSS	6334.198
CV	23.15155	Std Mean	1.675623
T:Mean=0	29.92544	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
H(Sign)	24	Pr>= H	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.967231	Pr<W	0.3166
Quantiles (Def=5)			
100% Max	70.2	99%	70.2
75% Q3	60.75	95%	68.6
50% Med	50.05	90%	64
25% Q1	40.85	10%	34.8
0% Min	18.8	5%	32.4
		1%	18.8
Range	51.4		
Q3-Q1	19.9		
Mode	39.5		

Análises da V%



Ramo-e-folhas e Box-plot da V%



Análises da CTC

Ramo-e-folhas e Box-plot da CTC

Moments				
N	47	Sum Wgts	47	
Mean	9.948936	Sum	467.6	
Std Dev	0.924844	Variance	0.853858	
Skewness	-0.18788	Kurtosis	0.209241	
USS	4691.4	CSS	39.27745	
CV	9.287869	Std Mean	0.134786	
T:Mean=0	73.813	Pr> T	0.8881	
Num ^= 0	47	Num > 0	47	
M(Sign)	23.5	Pr>= M	0.8881	
Sgn Rank	564	Pr>= S	0.8881	
W:Normal	0.988272	Pr<W	0.9613	
Quantiles(Def=5)				
100% Max	12.2	99%	12.2	
75% Q3	10.7	95%	11.4	
50% Med	10	90%	11	
25% Q1	9.4	10%	8.8	
0% Min	7.7	5%	8.3	
		1%	7.7	
Range	4.5			
Q3-Q1	1.3			
Mode	9			

Análises da CTC sem outliers

Moments			
N	48	Sum Wgts	48
Mean	0.273333	Sum	13.12
Std Dev	0.06508	Variance	0.004235
Skewness	1.959928	Kurtosis	4.853383
USS	3.7652	CSS	0.199067
CV	23.80991	Std Mean	0.009394
T:Mean=0	29.09798	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
M(Sign)	24	Pr>= M	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.815353	Pr<W	0.0001
Quantiles(Def=5)			
100% Max	0.51	99%	0.51
75% Q3	0.285	95%	0.39
50% Med	0.26	90%	0.37
25% Q1	0.23	10%	0.21
0% Min	0.19	5%	0.2
		1%	0.19
Range	0.32		
Q3-Q1	0.055		
Mode	0.28		

Stem Leaf	#	Boxplot
50 0	1	*
48 0	1	*
46		
44		
42		
40		
38 00	2	0
36 0	1	0
34 0	1	
32		
30 00	2	
28 0000000000	11	+---+
26 0000000000	10	*+--*
24 000000	6	
22 000000	7	+---+
20 00000	5	
18 0	1	
-----+-----+-----+		
Multiply Stem.Leaf by 10**-2		

Análises do Boro

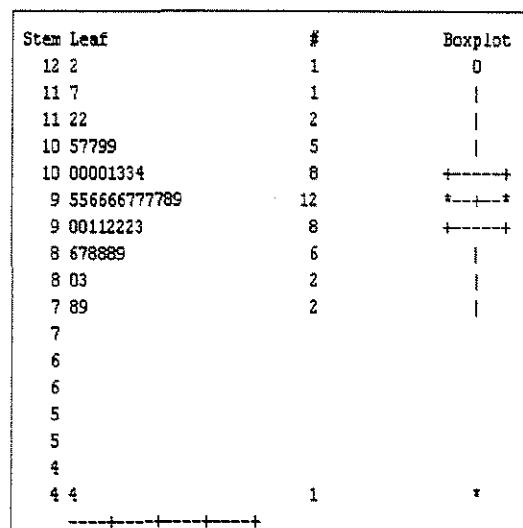
Ramo-e-folhas e Box-plot do Boro

Moments			
N	45	Sum Wgts	45
Mean	0.260667	Sum	11.73
Std Dev	0.041363	Variance	0.001711
Skewness	0.76386	Kurtosis	1.164143
USS	3.1329	CSS	0.07528
CV	15.86821	Std Mean	0.006166
T:Mean=0	42.27448	Pr> T	0.0001
Num ^= 0	45	Num > 0	45
M(Sign)	22.5	Pr>= M	0.0001
Sgn Rank	517.5	Pr>= S	0.0001
W:Normal	0.941864	Pr<W	0.0370
Quantiles(Def=5)			
100% Max	0.38	99%	0.38
75% Q3	0.28	95%	0.34
50% Med	0.26	90%	0.31
25% Q1	0.23	10%	0.21
0% Min	0.19	5%	0.2
		1%	0.19
Range	0.19		
Q3-Q1	0.05		
Mode	0.28		

Análises do B sem outliers

Moments			
N	46	Sum Wgts	46
Mean	9.619565	Sum	442.5
Std Dev	8.884589	Variance	8.782498
Skewness	0.100741	Kurtosis	-0.12388
USS	4291.87	CSS	35.21239
CU	9.195727	Std Mean	0.130426
T:Mean=0	73.75524	Pr> T	0.0001
Num ^= 0	46	Nur > 0	46
M(Sign)	23	Pr>= M	0.0001
Sgn Rank	548.5	Pr>= S	0.0001
W:Normal	0.982924	Pr<W	0.8444
Quantiles(Def=5)			
100% Max	11.7	99%	11.7
75% Q3	10.1	95%	11.2
50% Med	9.6	90%	10.9
25% Q1	9	10%	8.6
0% Min	7.8	5%	8
Range	3.9	1%	7.8
Q3-Q1	1.1		
Mode	9.6		

Análises do Cobre



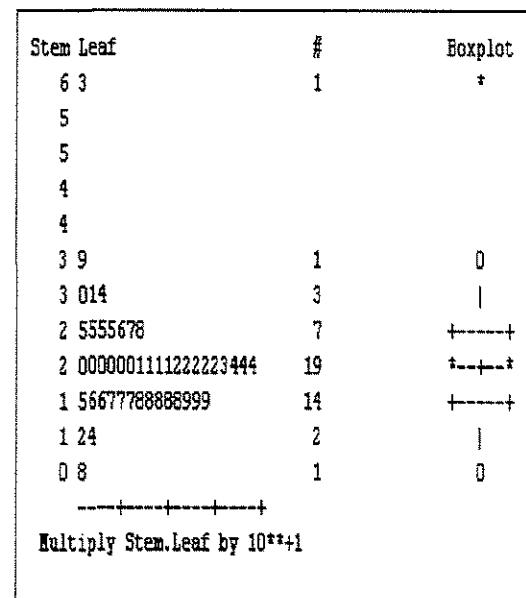
Ramo-e-folhas e Box-plot do Cobre

Moments			
N	46	Sum Wgts	46
Mean	9.619565	Sum	442.5
Std Dev	8.884589	Variance	8.782498
Skewness	0.100741	Kurtosis	-0.12388
USS	4291.87	CSS	35.21239
CU	9.195727	Std Mean	0.130426
T:Mean=0	73.75524	Pr> T	0.0001
Num ^= 0	46	Nur > 0	46
M(Sign)	23	Pr>= M	0.0001
Sgn Rank	548.5	Pr>= S	0.0001
W:Normal	0.982924	Pr<W	0.8444
Quantiles(Def=5)			
100% Max	11.7	99%	11.7
75% Q3	10.1	95%	11.2
50% Med	9.6	90%	10.9
25% Q1	9	10%	8.6
0% Min	7.8	5%	8
Range	3.9	1%	7.8
Q3-Q1	1.1		
Mode	9.6		

Análises do Cobre sem outliers

Moments			
N	48	Sum Wgts	48
Mean	22.29375	Sum	1070.1
Std Dev	8.03962	Variance	64.63549
Skewness	2.874723	Kurtosis	13.24099
USS	26894.41	CSS	3037.868
CV	36.06222	Std Mean	1.160419
T:Mean=0	19.21181	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
H(Sign)	24	Pr>= H	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.775498	Pr<W	0.0001
Quantiles (Def=5)			
100% Max	62.7	99%	62.7
75% Q3	24.7	95%	34.1
50% Med	20.95	90%	30.2
25% Q1	18.25	10%	16.2
0% Min	7.8	5%	13.8
		1%	7.8
Range	54.9		
Q3-Q1	6.45		
Mode	20.1		

Análises do Ferro



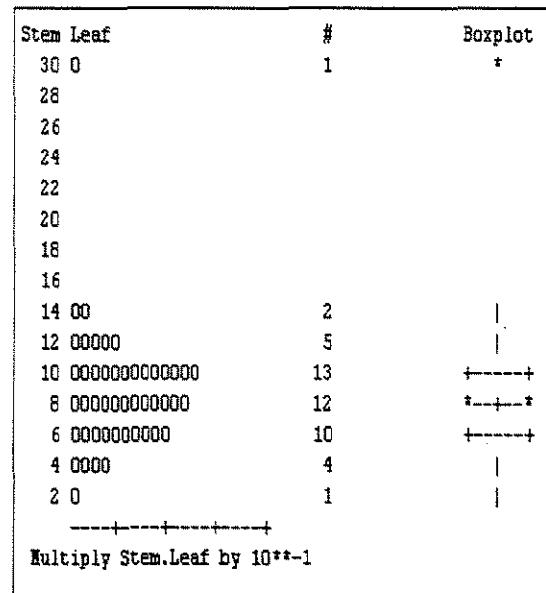
Ramo-e-folhas e Box-plot do Ferro

Moments			
N	44	Sum Wgts	44
Mean	21.86136	Sum	926.7
Std Dev	4.081907	Variance	16.66196
Skewness	0.339582	Kurtosis	8.256841
USS	28234.03	CSS	716.4643
CV	19.38182	Std Mean	0.615371
T:Mean=0	34.2255	Pr> T	0.0001
Num ^= 0	44	Num > 0	44
H(Sign)	22	Pr>= H	0.0001
Sgn Rank	495	Pr>= S	0.0001
W:Normal	0.984333	Pr<W	0.0001
Quantiles (Def=5)			
100% Max	31.4	99%	31.4
75% Q3	24.2	95%	27.5
50% Med	20.7	90%	26.2
25% Q1	18.25	10%	16.4
0% Min	12	5%	15.3
		1%	12
Range	19.4		
Q3-Q1	5.95		
Mode	20.1		

Análises do ferro sem outliers

Moments				
N	48	Sum Wgts	48	
Mean	0.927083	Sum	44.5	
Std Dev	0.420101	Variance	0.176485	
Skewness	2.953203	Kurtosis	14.63914	
USS	49.55	CSS	8.294792	
CV	45.31428	Std Mean	0.060636	
T:Mean=0	15.28923	Pr> T	0.0001	
Num ^= 0	48	Num > 0	48	
H(Sign)	24	Pr>= H	0.0001	
Sgn Rank	566	Pr>= S	0.0001	
W:Normal	0.776947	Pr<W	0.0001	
Quantiles(Def=5)				
100% Max	3.1	99%	3.1	
75% Q3	1.05	95%	1.4	
50% Med	0.9	90%	1.3	
25% Q1	0.7	10%	0.5	
0% Min	0.3	5%	0.4	
		1%	0.3	
Range	2.8			
Q3-Q1	0.35			
Mode	1			

Análises do Zinco



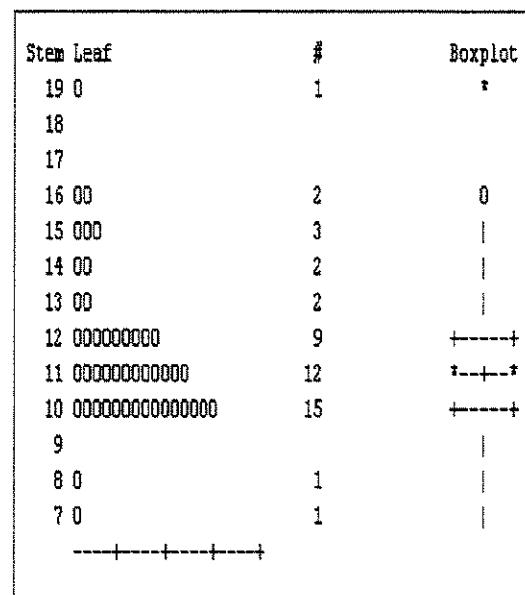
Ramo-e-folhas e Box-plot do Zinco

Moments				
N	47	Sum Wgts	47	
Mean	0.888851	Sum	41.4	
Std Dev	0.274763	Variance	0.075495	
Skewness	0.897232	Kurtosis	-0.32813	
USS	39.94	CSS	3.472766	
CV	31.19294	Std Mean	0.848878	
T:Mean=0	21.97822	Pr> T	0.0001	
Num ^= 0	47	Num > 0	47	
H(Sign)	28.5	Pr>= H	0.0001	
Sgn Rank	564	Pr>= S	0.0001	
W:Normal	0.975555	Pr<W	0.5861	
Quantiles(Def=5)				
100% Max	1.5	99%	1.5	
75% Q3	1	95%	1.3	
50% Med	0.9	90%	1.3	
25% Q1	0.7	10%	0.5	
0% Min	0.3	5%	0.4	
		1%	0.3	
Range	1.2			
Q3-Q1	0.3			
Mode	1			

Análises do zinco sem outliers

Moments				
N	48	Sum Wgts	48	
Mean	11.5625	Sum	555	
Std Dev	2.172421	Variance	4.719415	
Skewness	1.17834	Kurtosis	2.245954	
USS	6639	CSS	221.8125	
CV	18.78851	Std Mean	0.313562	
T:Mean=0	36.87468	Pr> T	0.0001	
Num ^= 0	48	Num > 0	48	
M(Sign)	24	Pr>= M	0.0001	
Sgn Rank	588	Pr>= S	0.0001	
W:Normal	0.88099	Pr<W	0.0001	
Quantiles(Def=5)				
100% Max	19	99%	19	
75% Q3	12	95%	16	
50% Med	11	90%	15	
25% Q1	10	10%	10	
0% Min	7	5%	10	
	1%	?	?	
Range	12			
Q3-Q1	2			
Mode	10			

Análises do Silte Grosso



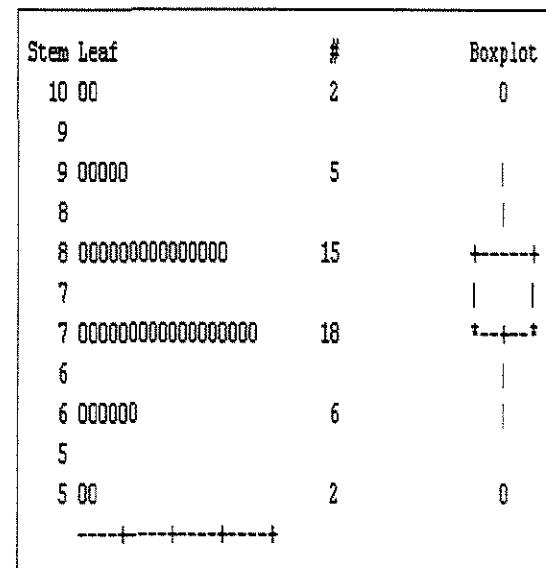
Ramo-e-folhas e Box-plot do Silte Grosso

Moments				
N	45	Sum Wgts	45	
Mean	11.2	Sum	584	
Std Dev	1.659682	Variance	2.754545	
Skewness	0.478219	Kurtosis	8.97361	
USS	5766	CSS	121.2	
CV	14.81859	Std Mean	0.247411	
T:Mean=0	45.26883	Pr> T	0.0001	
Num ^= 0	45	Num > 0	45	
M(Sign)	22.5	Pr>= M	0.0001	
Sgn Rank	517.5	Pr>= S	0.0001	
W:Normal	0.899278	Pr<W	0.0006	
Quantiles(Def=5)				
100% Max	15	99%	15	
75% Q3	12	95%	15	
50% Med	11	90%	14	
25% Q1	10	10%	10	
0% Min	7	5%	10	
		1%	7	
Range	8			
Q3-Q1	2			
Mode	10			

Análises do Silte Grosso sem outliers

Moments			
N	48	Sum Wgts	48
Mean	7.4375	Sum	357
Std Dev	1.109078	Variance	1.290053
Skewness	0.115572	Kurtosis	0.22454
USS	2713	CSS	57.8125
CV	14.91197	Std Mean	0.160082
T:Mean=0	46.46069	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
E(Sign)	24	Pr>= E	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.922663	Pr<W	0.0040
Quantiles (Def=5)			
100% Max	10	99%	10
75% Q3	8	95%	9
50% Med	7	90%	9
25% Q1	7	10%	6
0% Min	5	5%	6
		1%	5
Range	5		
Q3-Q1	1		
Mode	7		

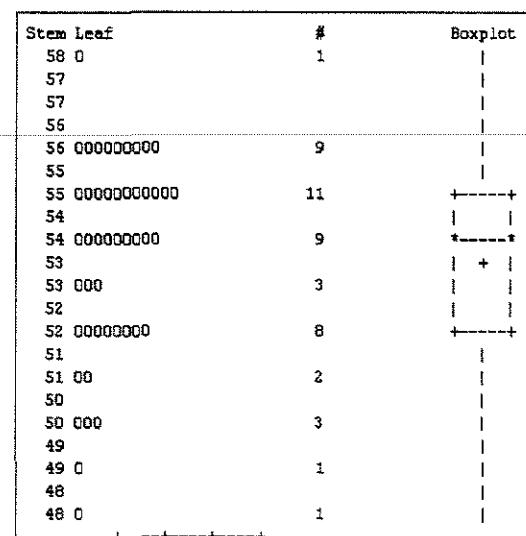
Análises do Silte Fino



Ramo-e-folhas e Box-plot do Silte Fino

Moments			
N	48	Sum Wgts	48
Mean	53.6675	Sum	2577
Std Dev	2.165064	Variance	4.6875
Skewness	-0.65408	Kurtosis	0.02208
USS	138573	CSS	220.3125
CV	4.032714	Std Mean	0.3125
T:Mean=0	171.8	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
E(Sign)	24	Pr>= E	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.930691	Pr<W	0.0092
Quantiles (Def=5)			
100% Max	58	99%	58
75% Q3	55	95%	56
50% Med	54	90%	56
25% Q1	52	10%	50
0% Min	48	5%	50
		1%	48
Range	10		
Q3-Q1	3		
Mode	55		

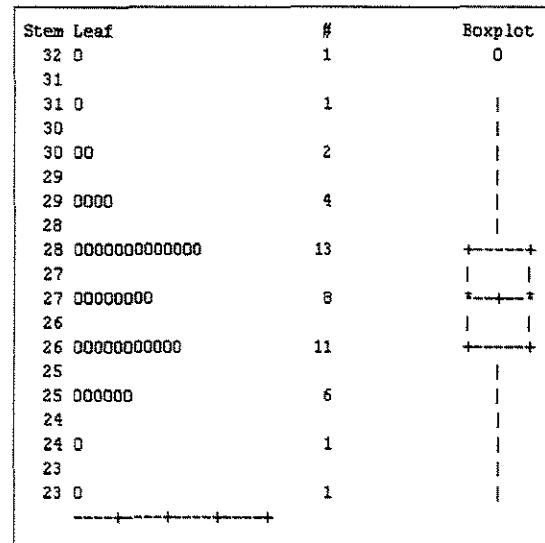
Análises da Argila



Ramo-e-folhas e Box-plot da Argila

Moments			
N	48	Sum Wgts	48
Mean	27.125	Sum	1302
Std Dev	1.770022	Variance	3.132979
Skewness	0.331047	Kurtosis	0.514736
USS	35464	CSS	147.25
CV	6.525428	Std Mean	0.255481
T:Mean=0	106.1724	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
H(Sign)	24	Pr>= H	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.961376	Pr<W	0.1921
Quantiles(Def=5)			
100% Max	32	99%	32
75% Q3	28	95%	30
50% Med	27	90%	29
25% Q1	26	10%	25
0% Min	23	5%	25
		1%	23
Range	9		
Q3-Q1	2		
Mode	28		

Análises da Areia



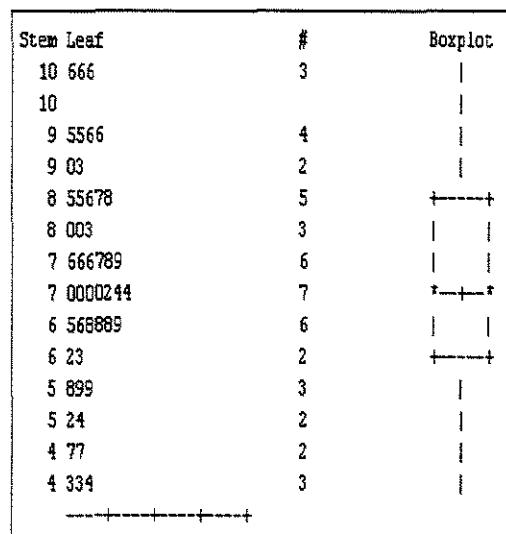
Ramo-e-folhas e Box-plot da Areia

Moments			
N	47	Sum Wgts	47
Mean	27.82128	Sum	1278
Std Dev	1.635869	Variance	2.673451
Skewness	0.826749	Kurtosis	0.845411
USS	34448	CSS	122.9787
CU	6.051843	Std Mean	0.238499
T:Mean=0	113.2971	Pr> T	0.0001
Num ^= 0	47	Num > 0	47
H(Sign)	23.5	Pr>= H	0.0001
Sgn Rank	564	Pr>= S	0.0001
W:Normal	0.962642	Pr<W	0.2226
Quantiles(Def=5)			
100% Max	31	99%	31
75% Q3	28	95%	30
50% Med	27	90%	29
25% Q1	26	10%	25
0% Min	23	5%	25
		1%	23
Range	8		
Q3-Q1	2		
Mode	28		

Análises da Areia sem outliers

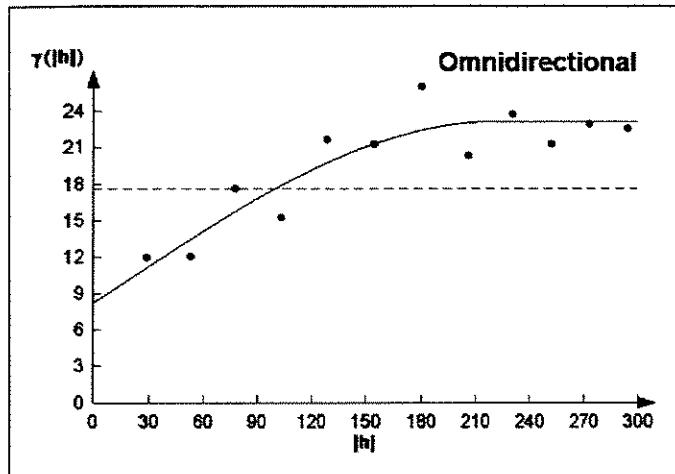
Moments			
N	48	Sum Wgts	48
Mean	7.400625	Sum	355.23
Std Dev	1.654269	Variance	2.736606
Skewness	-0.00917	Kurtosis	-0.50274
USS	2757.545	CSS	128.6205
CV	22.3531	Std Mean	0.238773
T:Mean=0	30.99437	Pr> T	0.0001
Num ^= 0	48	Num > 0	48
E(Sign)	24	Pr>= E	0.0001
Sgn Rank	588	Pr>= S	0.0001
W:Normal	0.966346	Pr<W	0.2945
Quantiles(Def=5)			
100% Max	10.57	99%	10.57
75% Q3	8.57	95%	10.55
50% Med	7.415	90%	9.57
25% Q1	6.38	10%	4.74
0% Min	4.33	5%	4.43
		1%	4.33
Range	6.24		
Q3-Q1	2.19		
Mode	6.76		

Análises do Rendimento

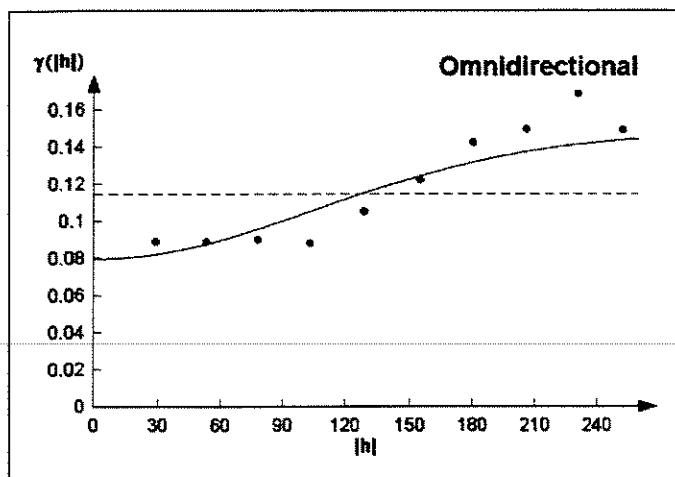


Ramo-e-folhas e Box-plot do Rendimento

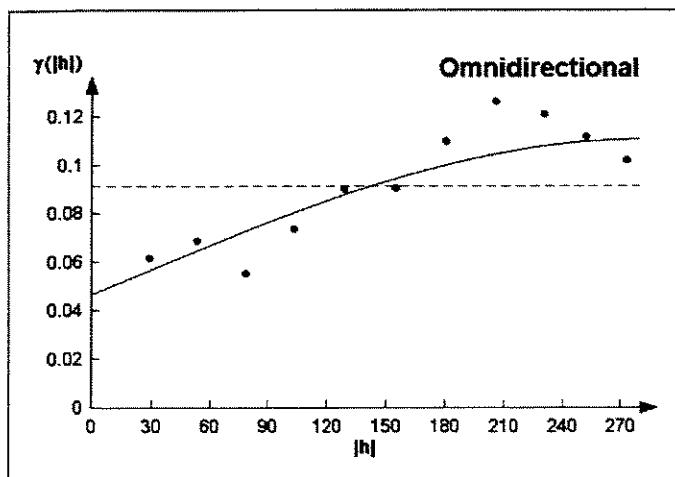
ANEXO 5: Semivariogramas das Variáveis



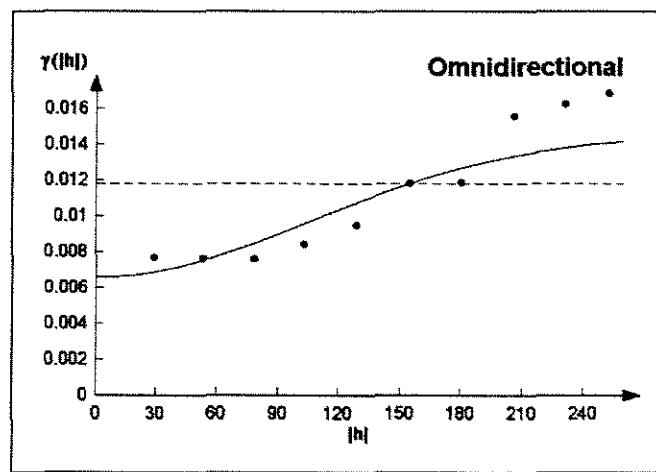
Semivariograma do Fósforo
 $\text{Gamma}(h)=8,28+14,94 \text{ Sph.}222 (h)$



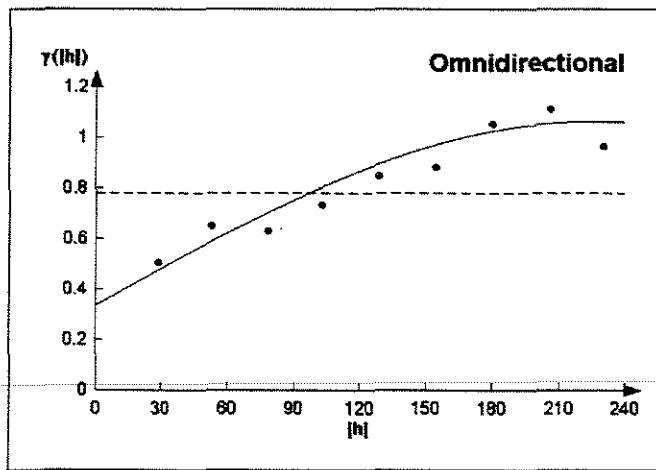
Semivariograma da Matéria Orgânica
 $\text{Gamma}(h)=0,0799+0,068 \text{ Gauss.}260 (h)$



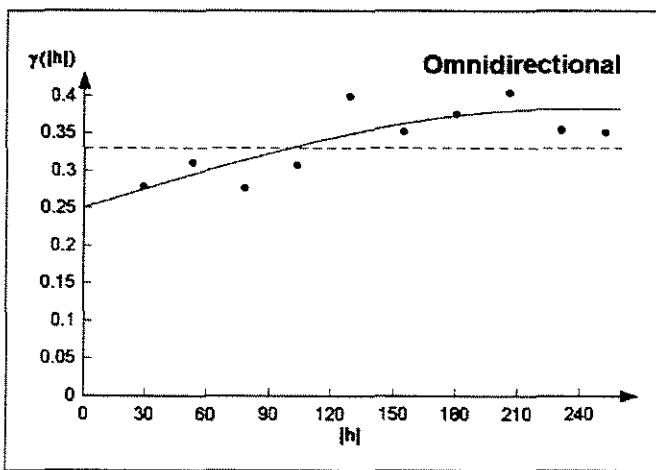
Semivariograma do pH
 $\text{Gamma}(h)=0,047+0,064 \text{ Sph.}280 (h)$



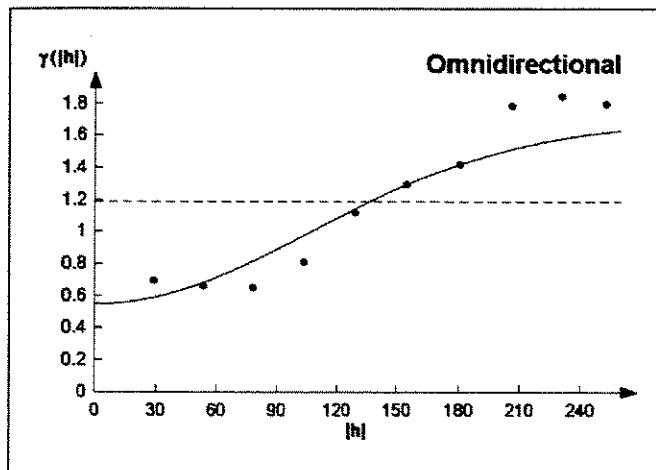
Semivariograma do Potássio
 $\text{Gamma}(h)= 0,0066+0,0084 \text{ Gauss.}260 \text{ (h)}$



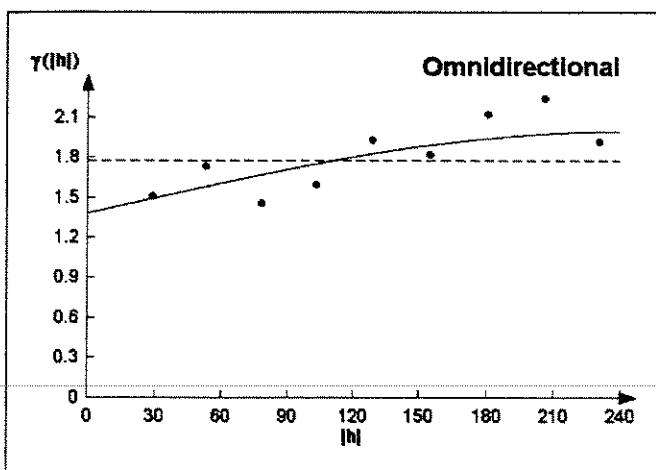
Semivariograma do Cálcio
 $\text{Gamma}(h)= 0,336+0,728 \text{ Sph.}223,2 \text{ (h)}$



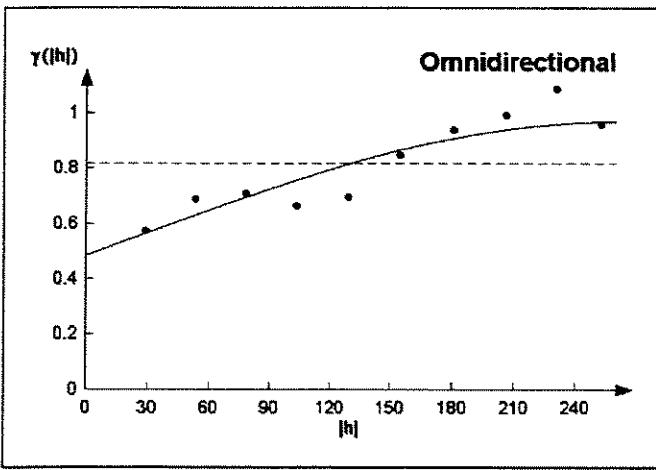
Semivariograma do Magnésio
 $\text{Gamma}(h)= 0,252+0,132 \text{ Sph.}234 \text{ (h)}$



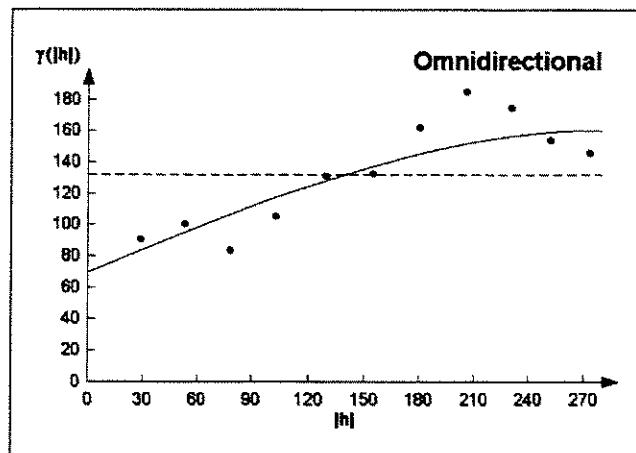
Semivariograma do H+Al
 $\text{Gamma}(h) = 0,55196 + 1,13992 \text{ Gauss.}260 (h)$



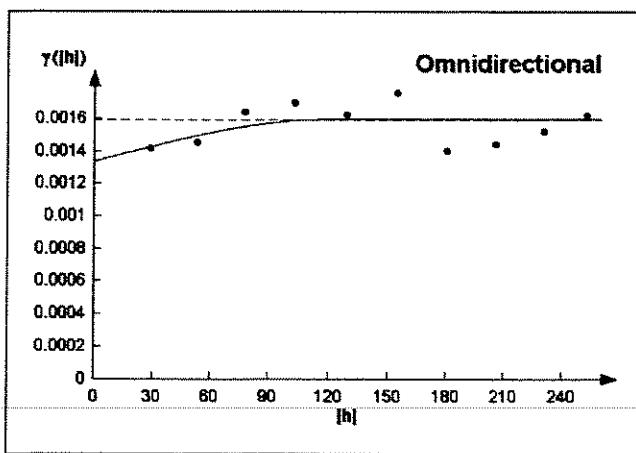
Semivariograma da Soma de Bases
 $\text{Gamma}(h) = 1,386 + 0,612 \text{ Sph.}240 (h)$



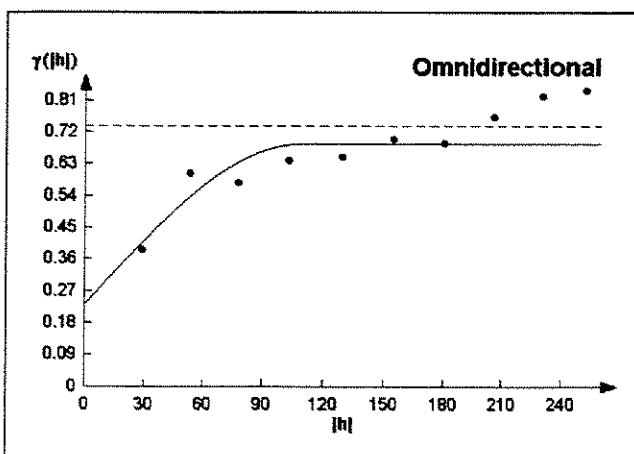
Semivariograma da Capacidade de Troca de Cátions
 $\text{Gamma}(h) = 0,486 + 0,486 \text{ Sph.}260 (h)$



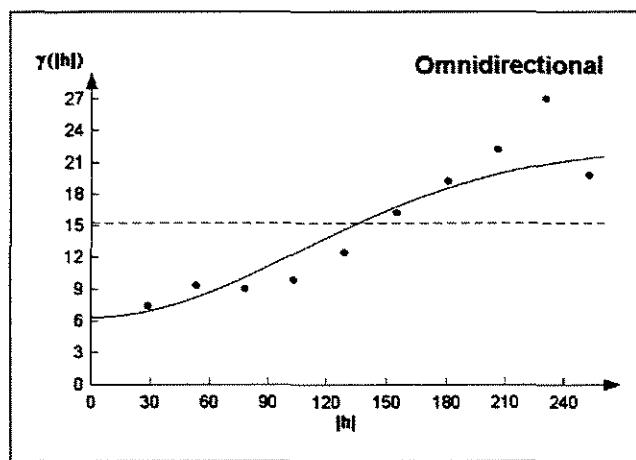
Semivariograma da Saturação por Bases
 $\text{Gamma}(h) = 70 + 90,99533 \text{ Sph.}280 (h)$



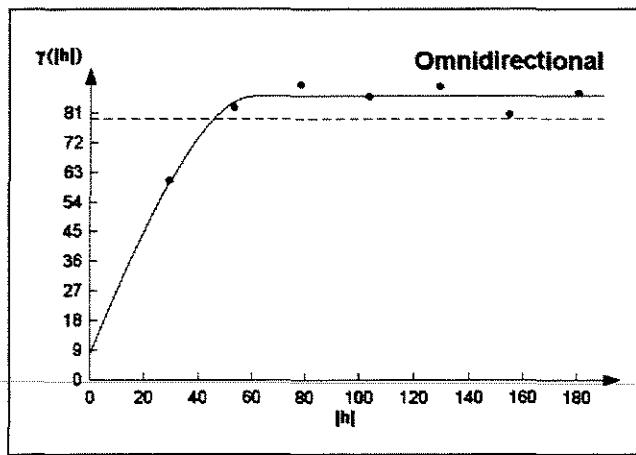
Semivariograma do Boro
 $\text{Gamma}(h) = 0,00134 + 0,00026 \text{ Sph.}122,2 (h)$



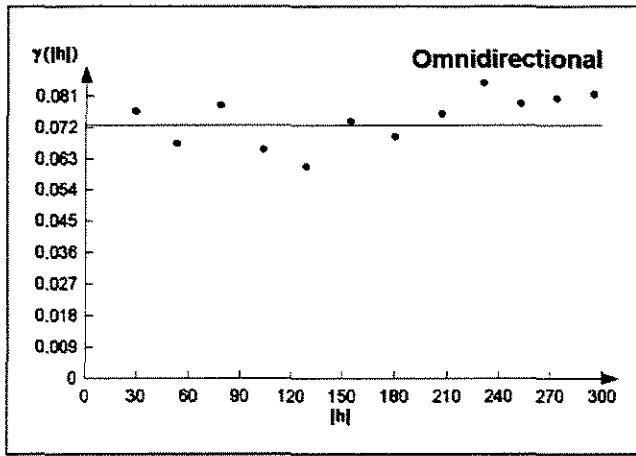
Semivariograma do Cobre
 $\text{Gamma}(h) = 0,2319733 + 0,4559733 \text{ Sph.}109,2 (h)$



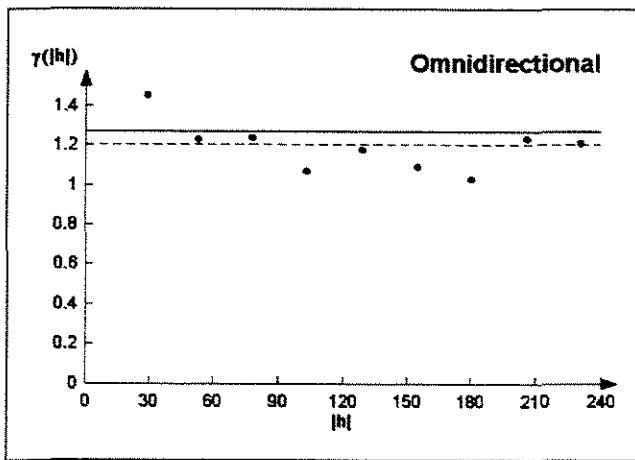
Semivariograma do Ferro
 $\text{Gamma}(h) = 6,4 + 16 \text{ Gauss.}260 (h)$



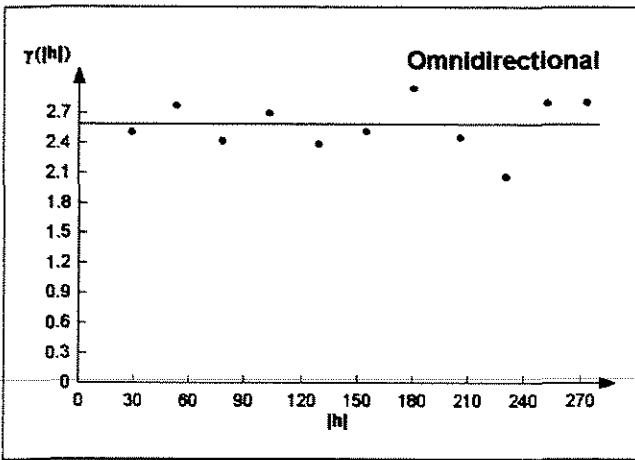
Semivariograma do Manganês
 $\text{Gamma}(h) = 8 + 78,4 \text{ Sph.}60,8 (h)$



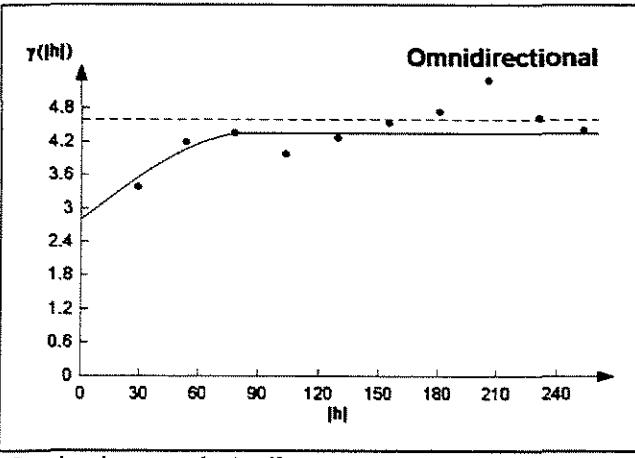
Semivariograma do Zinco
 $\text{Gamma}(h) = 0,0728$



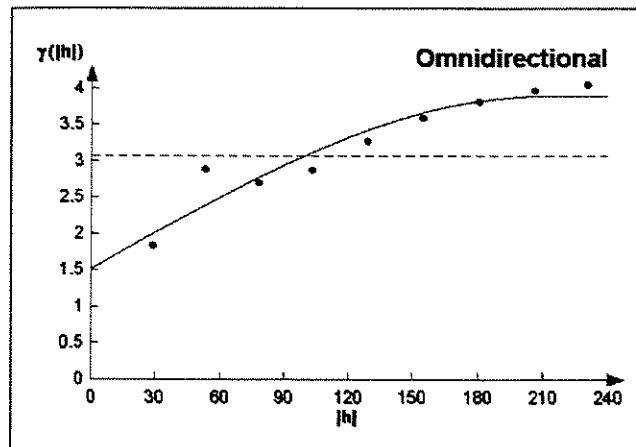
Semivariograma do Silte Fino
 $\text{Gamma}(h) = 1,274$



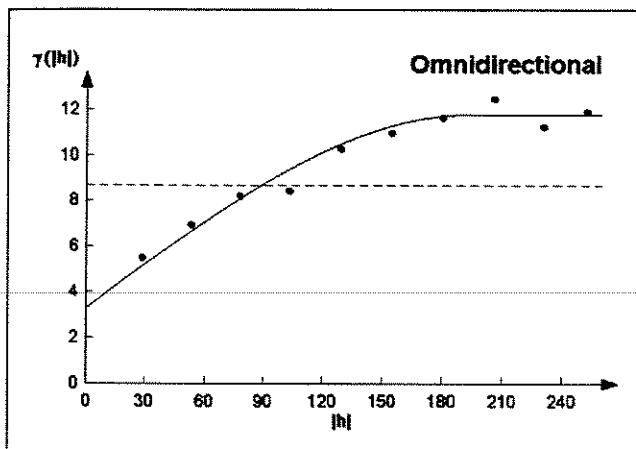
Semivariograma do Silte Grosso
 $\text{Gamma}(h) = 2,6$



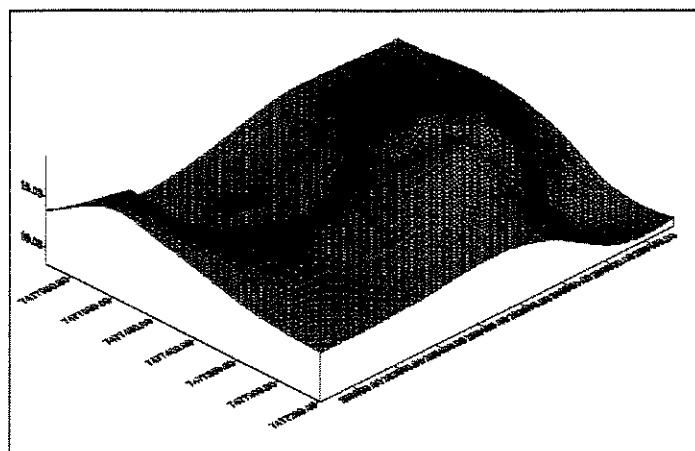
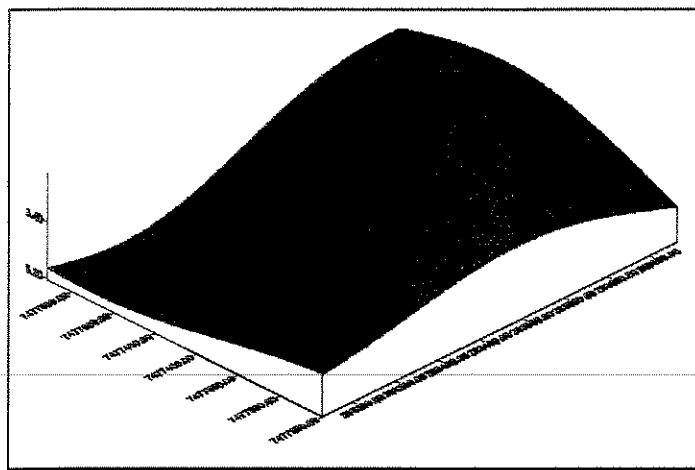
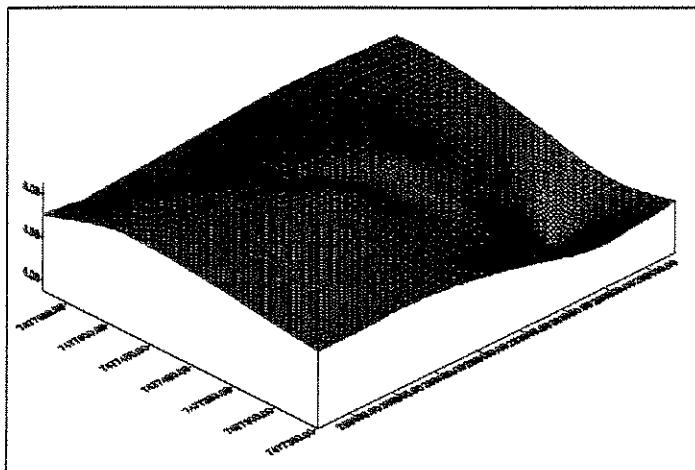
Semivariograma da Argila
 $\text{Gamma}(h) = 2,82 + 1,551 \text{ Sph.} 87,4 \text{ (h)}$

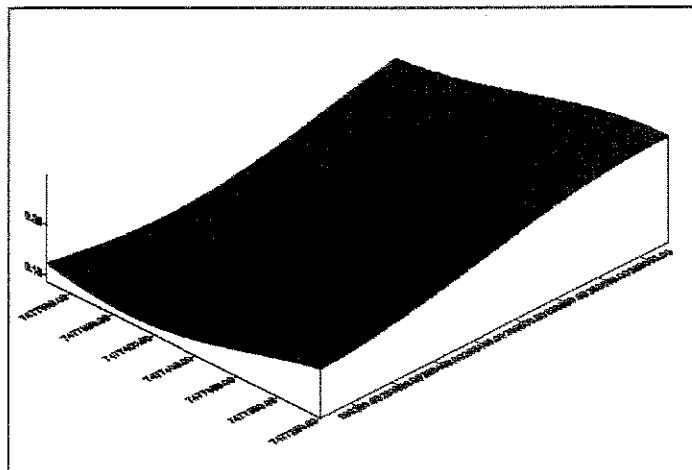


Semivariograma da Areia
Gamma(h) = $1,518793 + 2,387 \text{ Sph.} 212,672$ (h)

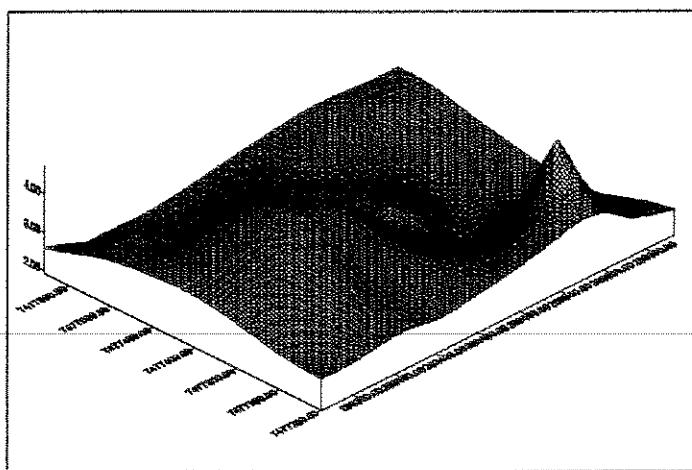


Semivariograma do Rendimento
Gamma(h) = $3,306 + 8,526 \text{ Sph.} 195$ (h)

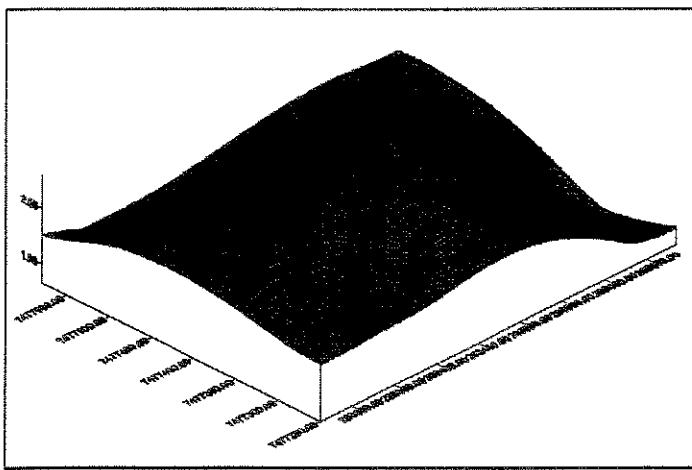
ANEXO 6: Grids Interpolados das Variáveis*Grid Interpolado do Fósforo**Grid Interpolado da Matéria Orgânica**Grid Interpolado do pH*



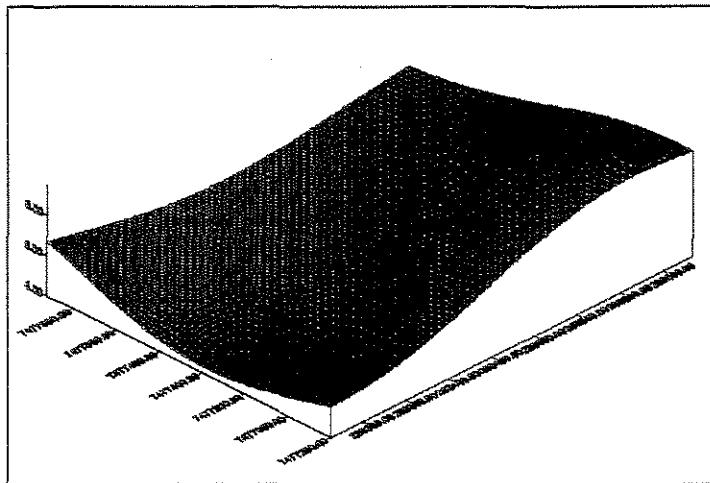
Grid Interpolado do Potássio



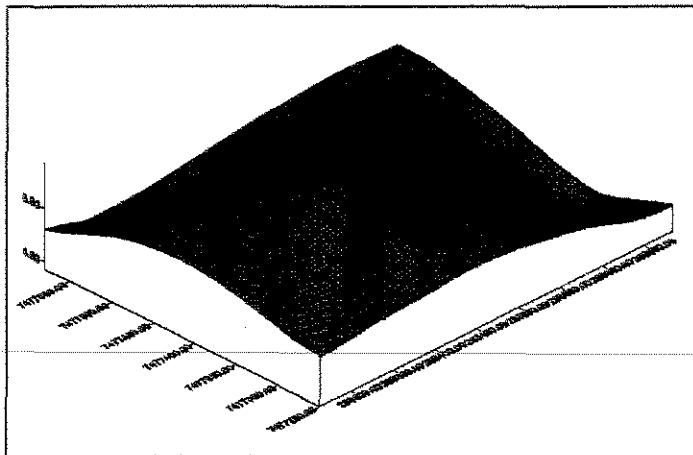
Grid Interpolado do Cálcio



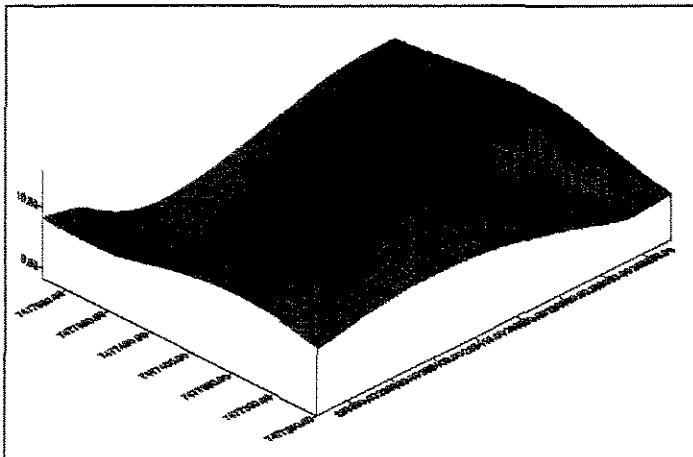
Grid Interpolado do Magnésio



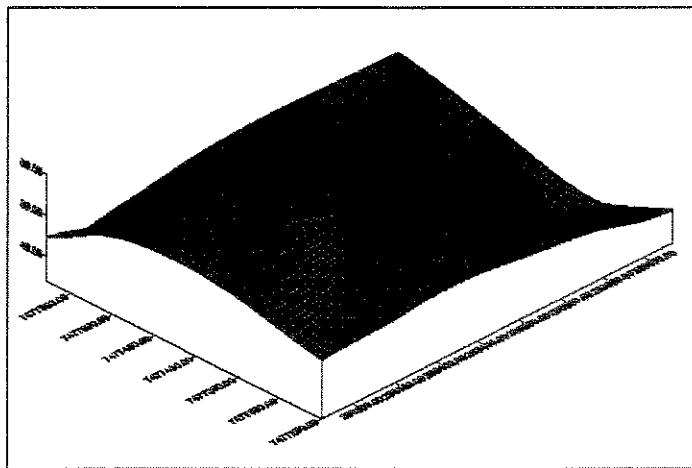
Grid Interpolado do H+Al



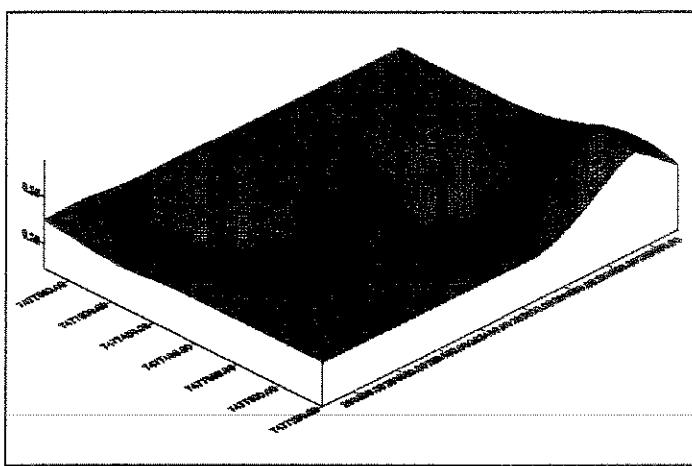
Grid Interpolado da Soma de Bases



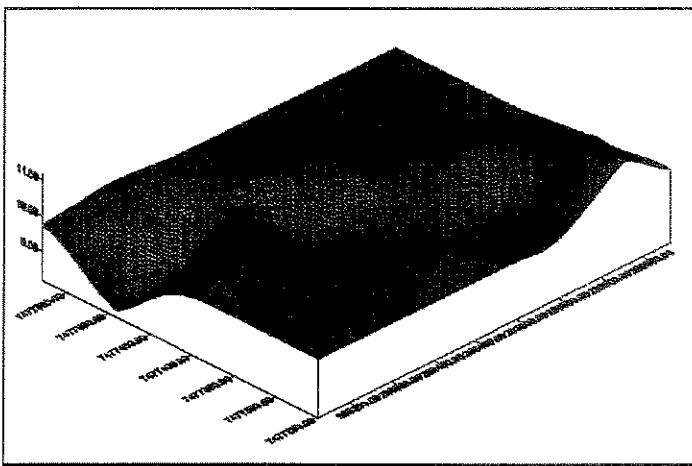
Grid Interpolado da Capacidade de Troca de Cátions



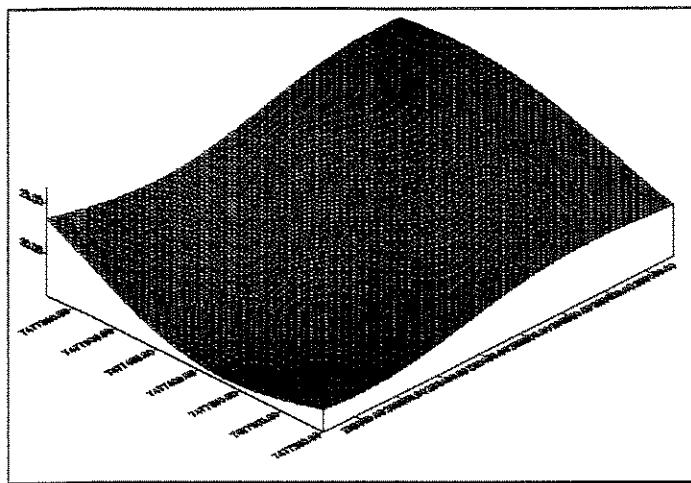
Grid Interpolado da Saturação por Bases



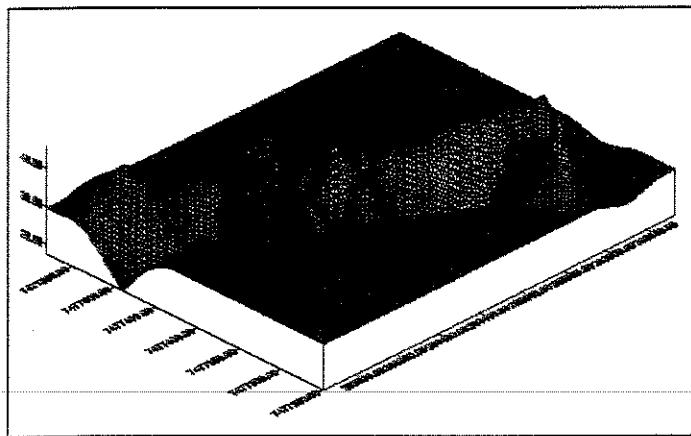
Grid Interpolado do Boro



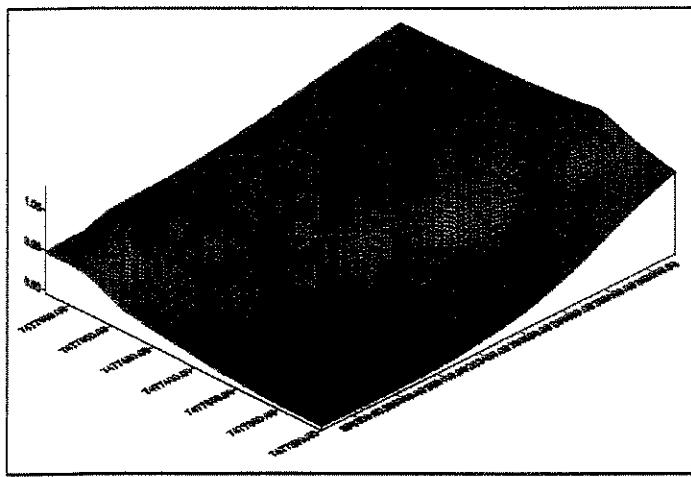
Grid Interpolado do Cobre



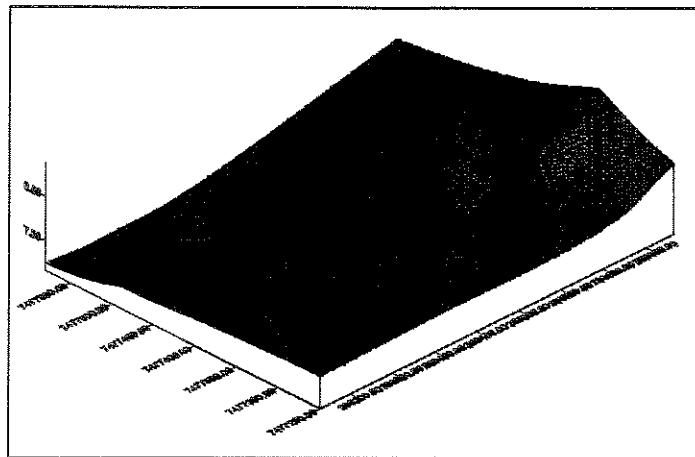
Grid Interpolado do Ferro



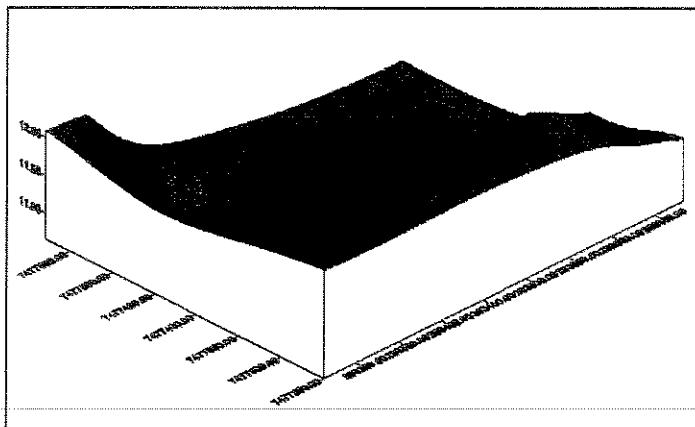
Grid Interpolado do Manganês



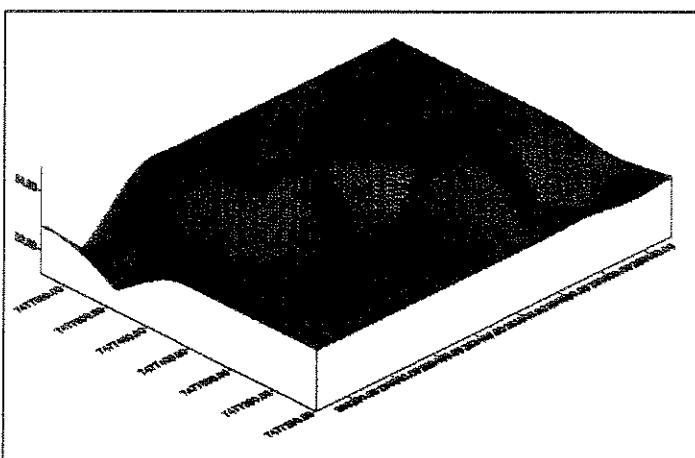
Grid Interpolado do Zinco



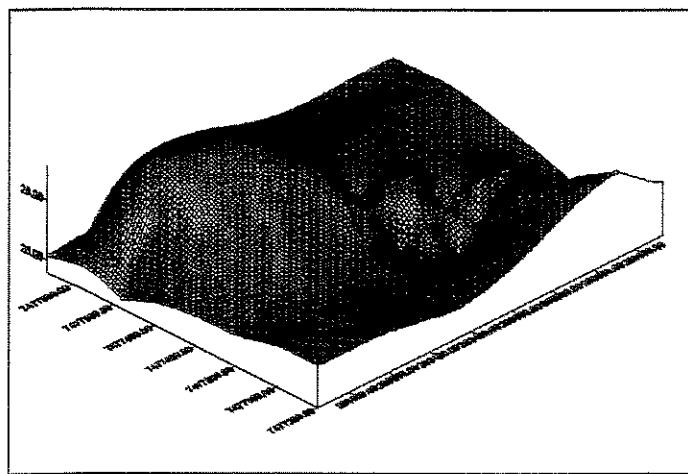
Grid Interpolado do Silte Fino



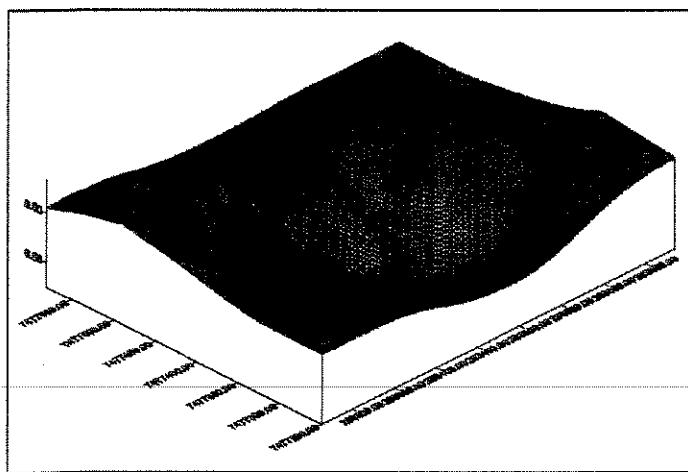
Grid Interpolado do Silte Grosso



Grid Interpolado da Argila

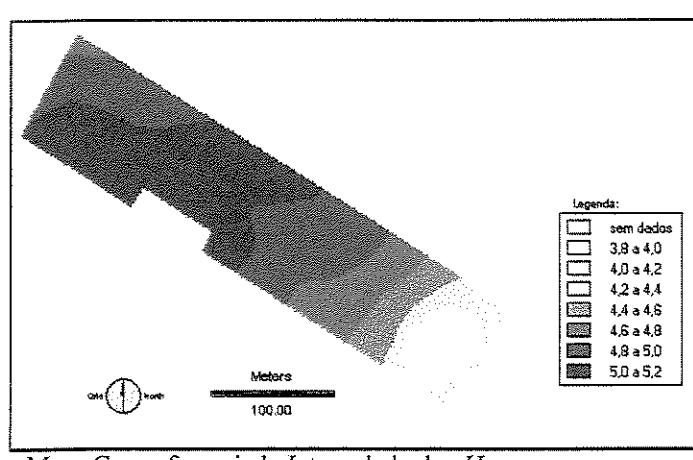
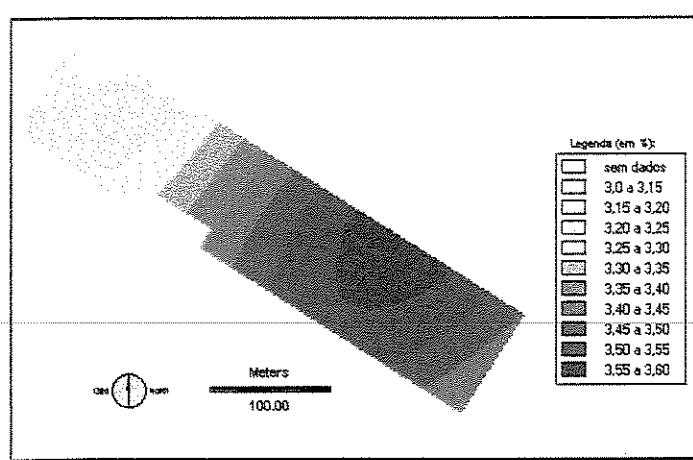
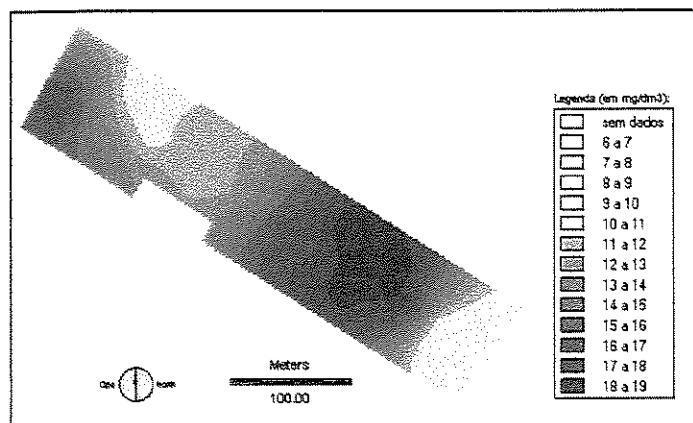


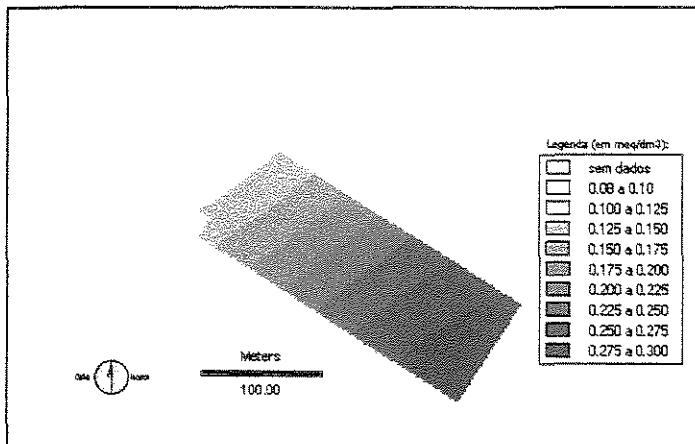
Grid Interpolado da Areia



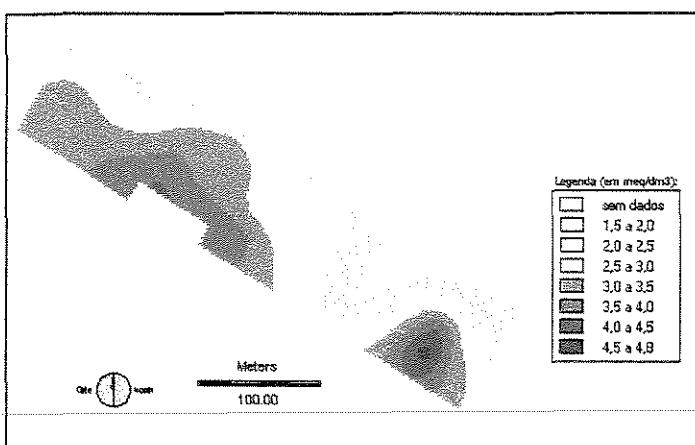
Grid Interpolado do Rendimento da Cultura

ANEXO 7: Mapas Geo-referenciados Interpolados das Variáveis

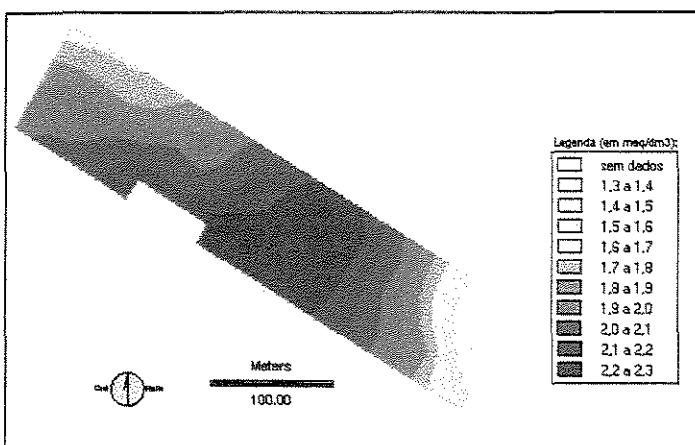




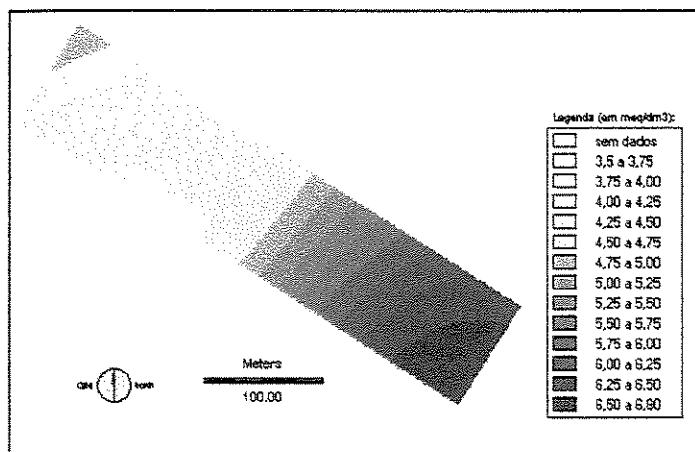
Mapa Geo-referenciado Interpolado do Potássio



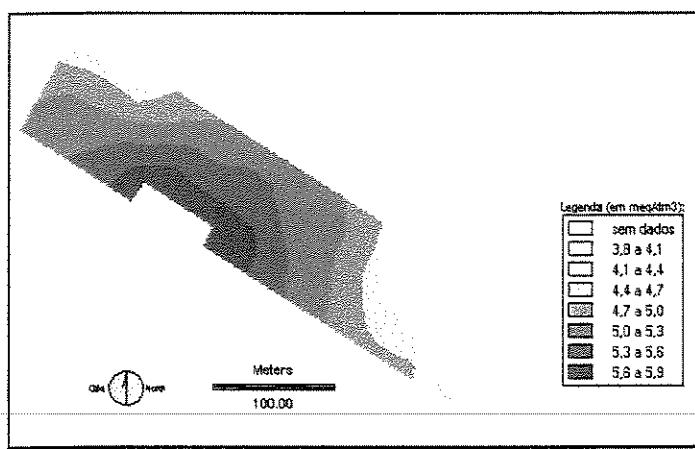
Mapa Geo-referenciado Interpolado do Cálculo



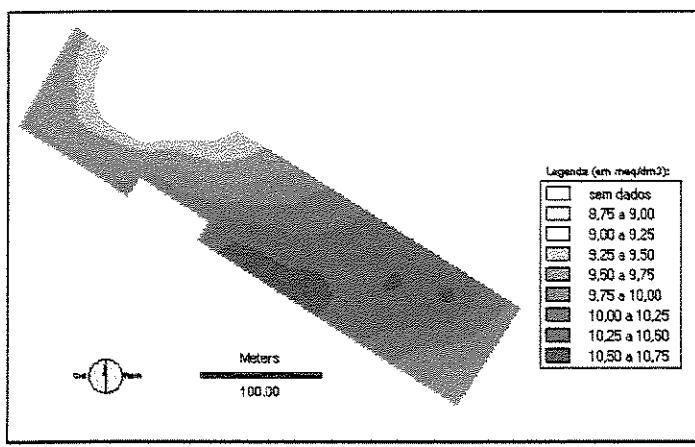
Mapa Geo-referenciado Interpolado do Magnésio



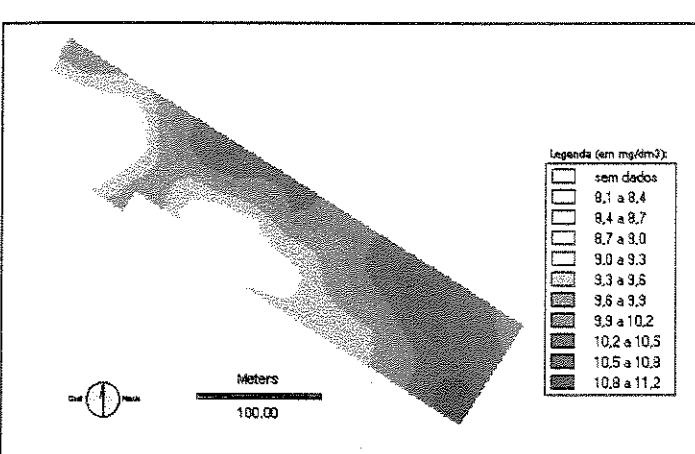
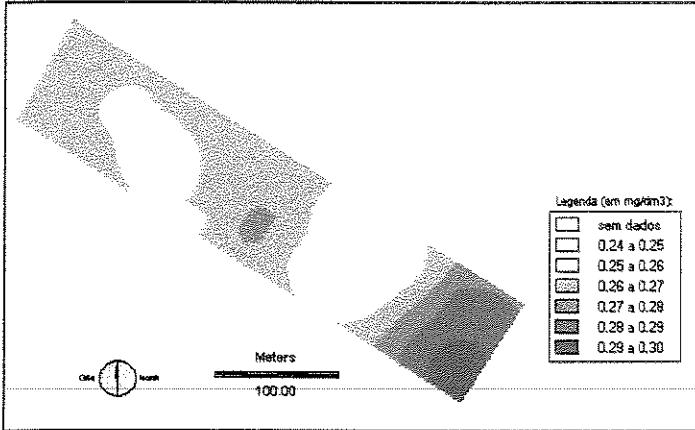
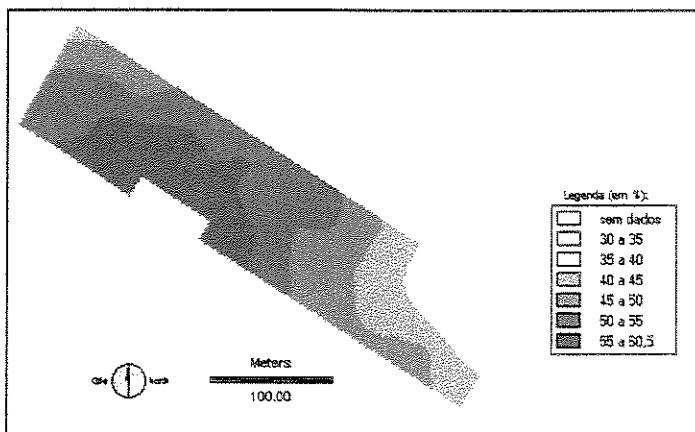
Mapa Geo-referenciado Interpolado do H+Al

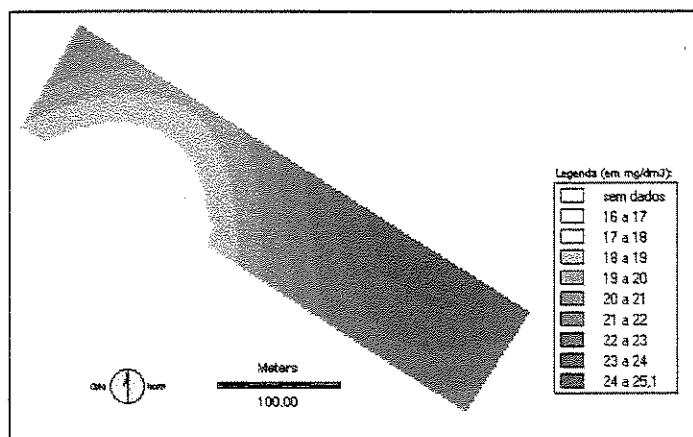


Mapa Geo-referenciado Interpolado da Soma de Bases

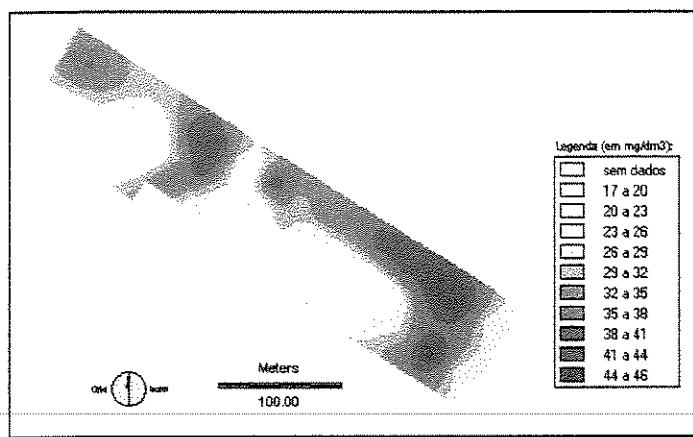


Mapa Geo-referenciado Interpolado da CTC

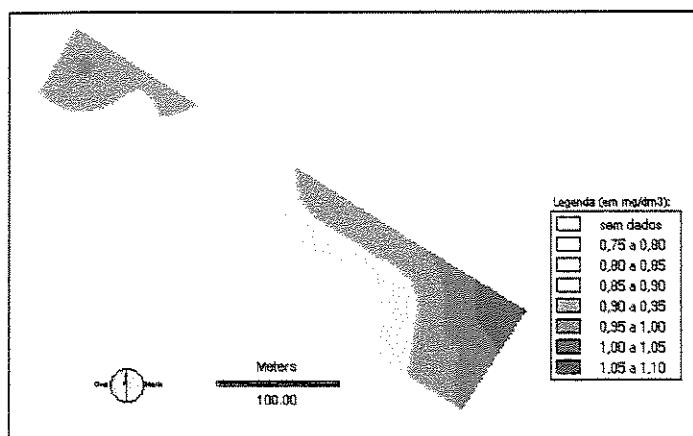




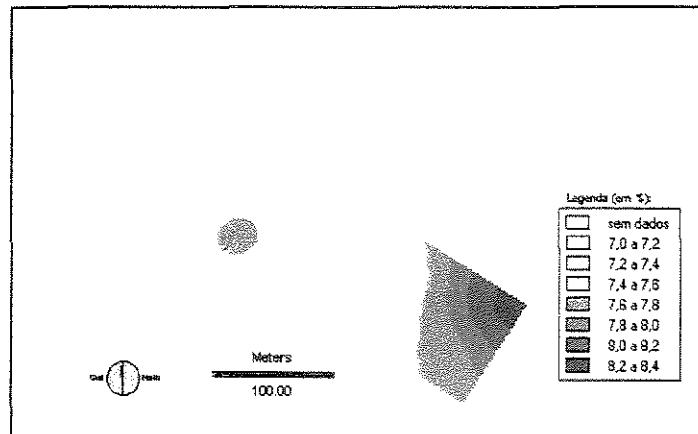
Mapa Geo-referenciado Interpolado do Ferro



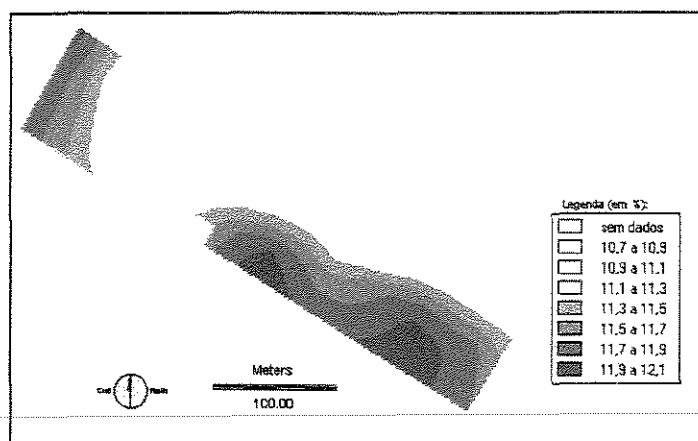
Mapa Geo-referenciado Interpolado do Manganês



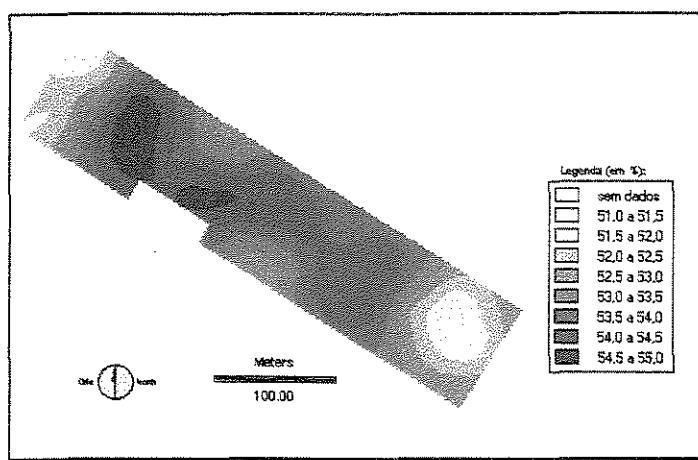
Mapa Geo-referenciado Interpolado do Zinco



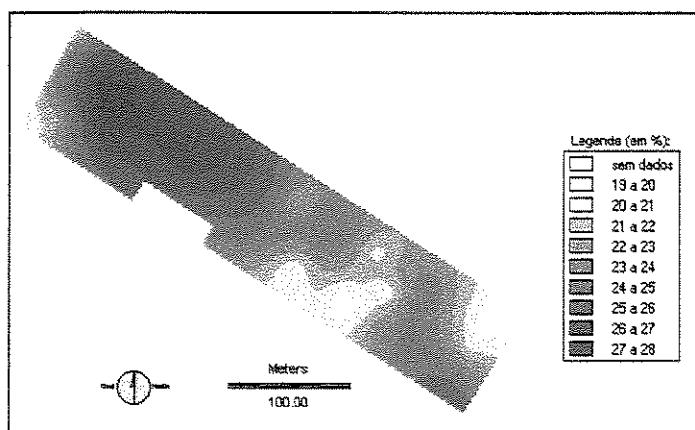
Mapa Geo-referenciado Interpolado do Silte Fino



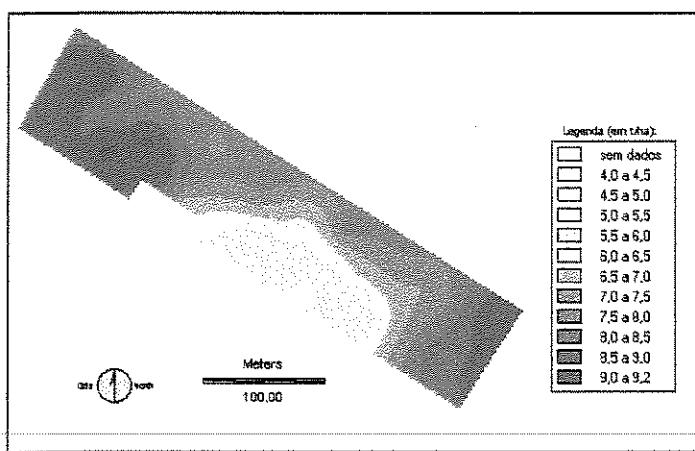
Mapa Geo-referenciado Interpolado do Silte Grosso



Mapa Geo-referenciado Interpolado da Argila



Mapa Geo-referenciado Interpolado da Areia



Mapa Geo-referenciado Interpolado do Rendimento da Cultura

ANEXO 8: Análises de Regressões Lineares Multivariadas

Regressões Múltiplas passo a passo:

Variáveis	Coef.Det.(r2)	Diferenças	
		para segundo	entre passos
MO+Mg	79.23%	2.33%	-
MO+Mg+Argila	79.74%	0.09%	0.51%
MO+Mg+Argila+Ca	80.52%	0.67%	0.78%
MO+Mg+Argila+Ca+P	81.28%	0.59%	0.76%
MO+Mg+Argila+Ca+P+K	81.56%	0.22%	0.28%
MO+Mg+Argila+Ca+P+K+HAI	82.10%	-	0.54%

Regressões Múltiplas passo a passo com todas as variáveis:

Variáveis	Coef.Det.(r2)	Diferenças	
		para segundo	entre passos
Fe+Zn	83.03%	0.37%	-
Fe+Zn+Sbases	85.07%	0.32%	2.04%
Fe+Zn+Sbases+Cu	87.12%	0.37%	2.05%
Fe+Zn+Sbases+Cu+V%	89.94%	1.39%	2.82%
Fe+Zn+Sbases+Cu+V%+CTC	91.53%	0.81%	1.59%
Fe+Zn+Sbases+Cu+V%+CTC+B	91.88%	0.00%	0.35%

Nota: As diferenças para o segundo correspondem a quanto mais o rendimento é explicado pelas variáveis a entrar em relação ao par, trio, etc que ficou em segundo lugar nas regressões lineares e as diferenças entre passos mostram o ganho com a nova variável a entrar no modelo de regressão.

Regressões Simples de todas as variáveis com relação ao Rendimento Ordenadas:

Variável	Coef.Det.(r2)
MO	60.98%
CTC	58.90%
P	48.96%
Areia	45.61%
Mg	35.29%
Zn	28.79%
Fe	28.72%
SGrosso	24.89%
Ca	22.73%
K	21.85%
SFino	15.46%
H+Al	14.25%
Mn	9.65%
V%	8.08%
Cu	3.60%
Argila	2.77%
B	2.44%
pH	1.81%
SBases	0.003%

Regressões Múltiplas das variáveis de interesse em duplas com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
MO+Mg	79.23%
K+Mg	76.90%
MO+K	76.63%
MO+HAI	75.22%
Mg+HAI	75.19%
MO+Argila	69.03%
P+MO	68.73%
MO+Ca	62.33%
P+K	54.84%
P+Mg	53.79%
P+HAI	51.30%
P+Ca	49.32%
P+Argila	49.01%
Mg+Argila	48.41%
Ca+Mg	48.12%
K+Argila	44.94%
K+HAI	43.62%
HAI+Argila	37.74%
K+Ca	33.87%
Ca+HAI	27.83%
Ca+Argila	23.54%

Regressões Múltiplas das variáveis de interesse para 3 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
MO+Mg+Argila	79.74%
MO+Mg+Ca	79.65%
MO+Mg+P	79.32%
MO+Mg+K	79.23%
MO+Mg+HAI	79.22%

Regressões Múltiplas das variáveis de interesse para 4 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
MO+Mg+Argila+Ca	80.52%
MO+Mg+Argila+K	79.85%
MO+Mg+Argila+HAI	79.78%
MO+Mg+Argila+P	79.77%

Regressões Múltiplas das variáveis de interesse para 5 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
MO+Mg+Argila+Ca+P	81.28%
MO+Mg+Argila+Ca+HAI	80.69%
MO+Mg+Argila+Ca+K	80.54%

Regressões Múltiplas das variáveis de interesse para 6 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
MO+Mg+Argila+Ca+P+K	81.56%
MO+Mg+Argila+Ca+P+HAI	81.34%

Regressões Múltiplas das variáveis de interesse para 7 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
MO+Mg+Argila+Ca+P+K+HAI	82.10%

Régressões Múltiplas de todas as variáveis para 2 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)	Variáveis	Coef.Det.(r2)
Fe+Zn	83.03%	CTC+SFino	63.32%
MO+Zn	82.66%	MO+Ca	62.33%
MO+Cu	80.67%	MO+CTC	62.25%
MO+Mg	79.23%	Argila+SGrosso	61.40%
CTC+Zn	77.23%	MO+SGrosso	61.13%
Zn+Areia	77.23%	MO+Areia	60.99%
K+Mg	76.90%	Zn+SGrosso	60.89%
MO+K	76.63%	Mg+SFino	60.22%
Mg+V%	76.61%	CTC+Fe	60.20%
MO+pH	76.57%	P+Zn	59.99%
MO+Sbases	75.31%	CTC+SGrosso	59.05%
MO+HAI	75.22%	CTC+Areia	58.89%
Mg+HAI	75.19%	pH+Zn	58.75%
Mg+CTC	75.10%	V%+Fe	58.75%
pH+Mg	74.49%	Argila+Areia	58.41%
V%+Zn	74.31%	Sbases+Zn	58.40%
Sbases+V%	74.04%	P+Areia	56.99%
MO+V%	73.85%	pH+Areia	56.92%
Sbases+Fe	73.60%	P+SGrosso	56.51%
Mg+Fe	73.38%	V%+Areia	56.41%
MO+Mn	73.25%	Zn+SFino	55.51%
K+Zn	72.90%	P+B	54.95%
Mg+Areia	72.77%	P+K	54.84%
HAI+Zn	72.73%	P+Mg	53.79%
MO+Fe	72.13%	K+Sbases	53.13%
Mg+SGrosso	70.92%	HAI+Sbases	53.02%
MO+Argila	69.03%	pH+HAI	52.98%
pH+CTC	69.03%	HAI+Areia	52.97%
CTC+Argila	68.82%	P+Fe	52.20%
P+MO	68.73%	pH+Fe	51.65%
pH+K	68.34%	P+Cu	51.35%
CTC+Mn	67.78%	P+HAI	51.30%
MO+B	66.35%	Mg+Cu	50.75%
Sbases+CTC	66.33%	P+pH	50.50%
P+CTC	65.76%	B+Areia	50.33%
HAI+CTC	65.64%	Mn+Areia	50.05%
MO+SFino	65.60%	P+Sbases	49.73%
K+CTC	65.15%	P+V%	49.58%
CTC+Cu	65.15%	Ca+Zn	49.53%
Mg+SBases	64.55%	P+Mn	49.41%
CTC+V%	64.38%	P+Ca	49.32%
Sbases+Areia	64.30%	Fe+Argila	49.04%
CTC+B	63.80%	P+Argila	49.01%
P+SFino	63.58%	Mg+Argila	48.41%
Ca+CTC	63.35%	K+Areia	48.40%

Régressões Múltiplas de todas as variáveis para 2 variáveis com relação ao Rendimento (Cont.):

Variáveis	Coef.Det.(r2)	Variáveis	Coef.Det.(r2)
Ca+Mg	48.12%	Ca+Mn	26.18%
Cu+Areia	47.38%	HAI+B	25.22%
Ca+Areia	46.83%	V%+SGrosso	25.16%
Fe+Mn	46.54%	Cu+SGrosso	25.05%
Fe+Areia	46.38%	HAI+SGrosso	24.87%
Areia+SGrosso	45.81%	V%+Mn	24.83%
Areia+SFino	45.72%	Ca+Cu	24.18%
B+SGrosso	45.71%	Ca+Argila	23.54%
K+Argila	44.94%	pH+Ca	23.52%
Cu+Zn	44.06%	Ca+V%	23.17%
Ca+SGrosso	43.94%	Ca+B	23.10%
K+HAI	43.62%	K+SFino	22.21%
HAI+Fe	42.65%	HAI+V%	21.48%
Mg+B	42.32%	pH+SFino	18.40%
Zn+Argila	42.07%	pH+V%	18.06%
B+SFino	41.45%	SBases+SFino	18.03%
K+Mn	40.02%	HAI+SFino	17.78%
Ca+SFino	39.40%	pH+Mn	17.38%
HAI+Argila	37.74%	pH+Argila	17.31%
Mg+Zn	36.30%	V%+B	16.13%
B+Fe	36.24%	V%+SFino	15.85%
Cu+Fe	35.32%	Cu+SFino	15.79%
Mg+Mn	35.29%	HAI+Cu	15.44%
K+V%	35.07%	SBases+Mn	10.93%
pH+SGrosso	34.71%	pH+B	10.84%
Mn+SGrosso	34.31%	Cu+Argila	10.10%
K+Ca	33.87%	B+Mn	9.72%
K+B	33.57%	Mn+Argila	9.65%
SBases+SGrosso	33.27%	B+Cu	8.83%
Ca+Fe	33.18%	V%+Cu	8.06%
Cu+Mn	32.74%	pH+SBases	7.41%
Mn+SFino	32.60%	SBases+Cu	5.31%
Fe+SGrosso	32.33%	SBases+Argila	5.24%
Argila+SFino	31.63%	pH+Cu	3.58%
HAI+Mn	31.30%	B+Argila	2.99%
B+Zn	30.43%	SBases+B	2.87%
K+Fe	29.66%		
Fe+SFino	29.32%		
Mn+Zn	28.78%		
Ca+HAI	27.83%		
K+Cu	27.65%		
V%+Argila	27.51%		
Ca+SBases	27.24%		
SFino+SGrosso	26.87%		
K+SGrosso	26.79%		

Regressões Múltiplas de todas as variáveis para 3 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
Fe+Zn+Sbases	85.07%
Fe+Zn+Cu	84.75%
Fe+Zn+Mg	84.57%
Fe+Zn+Argila	84.52%
Fe+Zn+SGrosso	84.07%
Fe+Zn+SFino	83.99%
Fe+Zn+CTC	83.88%
Fe+Zn+MO	83.83%
Fe+Zn+Areia	83.76%
Fe+Zn+HAI	83.75%
Fe+Zn+B	83.65%
Fe+Zn+pH	83.41%
Fe+Zn+V%	83.40%
Fe+Zn+K	83.34%
Fe+Zn+P	83.21%
Fe+Zn+Mn	83.07%
Fe+Zn+Ca	83.04%

Regressões Múltiplas de todas as variáveis para 4 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
Fe+Zn+Sbases+Cu	87.12%
Fe+Zn+Sbases+V%	86.75%
Fe+Zn+Sbases+Argila	86.64%
Fe+Zn+Sbases+SGrosso	86.49%
Fe+Zn+Sbases+Areia	85.62%
Fe+Zn+Sbases+B	85.55%
Fe+Zn+Sbases+Mn	85.46%
Fe+Zn+Sbases+Ca	85.36%
Fe+Zn+Sbases+SFino	85.33%
Fe+Zn+Sbases+CTC	85.16%
Fe+Zn+Sbases+K	85.14%
Fe+Zn+Sbases+HAI	85.12%
Fe+Zn+Sbases+Mg	85.10%
Fe+Zn+Sbases+P	85.09%
Fe+Zn+Sbases+MO	85.07%
Fe+Zn+Sbases+pH	85.07%

Regressões Múltiplas de todas as variáveis para 5 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
Fe+Zn+Sbases+Cu+V%	89.94%
Fe+Zn+Sbases+Cu+Argila	88.55%
Fe+Zn+Sbases+Cu+MO	88.26%
Fe+Zn+Sbases+Cu+B	88.10%
Fe+Zn+Sbases+Cu+Sfino	88.08%
Fe+Zn+Sbases+Cu+P	87.95%
Fe+Zn+Sbases+Cu+Sgrosso	87.78%
Fe+Zn+Sbases+Cu+Mg	87.77%
Fe+Zn+Sbases+Cu+Mn	87.45%
Fe+Zn+Sbases+Cu+pH	87.43%
Fe+Zn+Sbases+Cu+CTC	87.26%
Fe+Zn+Sbases+Cu+K	87.23%
Fe+Zn+Sbases+Cu+Areia	87.17%
Fe+Zn+Sbases+Cu+HAI	87.13%
Fe+Zn+Sbases+Cu+Ca	87.12%

Regressões Múltiplas de todas as variáveis para 6 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
Fe+Zn+Sbases+Cu+V%+CTC	91.53%
Fe+Zn+Sbases+Cu+V%+K	90.72%
Fe+Zn+Sbases+Cu+V%+HAI	90.54%
Fe+Zn+Sbases+Cu+V%+Areia	90.42%
Fe+Zn+Sbases+Cu+V%+Ca	90.35%
Fe+Zn+Sbases+Cu+V%+Sfino	90.29%
Fe+Zn+Sbases+Cu+V%+pH	90.21%
Fe+Zn+Sbases+Cu+V%+Mn	90.19%
Fe+Zn+Sbases+Cu+V%+Mg	90.11%
Fe+Zn+Sbases+Cu+V%+Argila	90.09%
Fe+Zn+Sbases+Cu+V%+MO	90.03%
Fe+Zn+Sbases+Cu+V%+P	89.96%
Fe+Zn+Sbases+Cu+V%+B	89.95%
Fe+Zn+Sbases+Cu+V%+Sgrosso	89.94%

Regressões Múltiplas de todas as variáveis para 7 variáveis com relação ao Rendimento:

Variáveis	Coef.Det.(r2)
Fe+Zn+Sbases+Cu+V%+CTC+B	91.88%
Fe+Zn+Sbases+Cu+V%+CTC+Sfino	91.88%
Fe+Zn+Sbases+Cu+V%+CTC+Mg	91.87%
Fe+Zn+Sbases+Cu+V%+CTC+P	91.83%
Fe+Zn+Sbases+Cu+V%+CTC+Argila	91.77%
Fe+Zn+Sbases+Cu+V%+CTC+K	91.70%
Fe+Zn+Sbases+Cu+V%+CTC+Mn	91.68%
Fe+Zn+Sbases+Cu+V%+CTC+Ca	91.64%
Fe+Zn+Sbases+Cu+V%+CTC+pH	91.63%
Fe+Zn+Sbases+Cu+V%+CTC+Areia	91.61%
Fe+Zn+Sbases+Cu+V%+CTC+Sgrosso	91.61%
Fe+Zn+Sbases+Cu+V%+CTC+MO	91.60%
Fe+Zn+Sbases+Cu+V%+CTC+HAI	91.59%

REFERÊNCIAS BIBLIOGRÁFICAS:

ABLER, R.F. *The National Sciences Foundation National Center for Geographic Information and Analysis*. International Journal of Geographic Information Systems. v. 1, n. 4, p. 303-326. 1987.

ANDA (Associação Nacional para Difusão de Adubos). Manual de Adubação. 265p. 1971.

AQUINO,L.H. e DUARTE, G.S. Curso de Estatística Experimental. Ministério da Educação. Escola Superior de Agricultura de Lavras. Departamento de Ciências Exatas. 204p.1986.

ARONOFF, S. *Geographic Information Systems: a Management Perspective*. WDL Publications. Otawa. Canada. p.12-21. 1989.

BAKHSH, A.; COLVIN, T.S.; JAYNES, D.B.; KANWAR, R.S.; TIM, U.S. *Spatial Distribution of soil attributes affecting crop yield*. ASAE Meeting Presentation, Paper n. 971032, Minnesota, USA. 10p. 1997.

BECKER, H. e SENFT, D. *Satellites key to new farming aids*. Agricultural Research. February. p.4-8. 1992.

BENATTI JR, R.; FRANÇA, G.V.; MOREIRA, C.A. Manejo Convencional e Reduzido em 4 tipos de Solos na Cultura do Milho em SP. Fundação Cargill. 68p. (s/data).

BHATTI, A.V.; MULLA, D.J.; FRAZIER, B.E. *Estimation of soil properties and wheat yields on complex eroded hills using geostatistics and thematic mapper images.* Remote Sensing Environment, v. 37, p.181-191. 1991.

BLACKMORE, S. *Precision farming: an introduction.* Outlook in Agriculture v. 23, n. 4, p. 275-280. 1994.

BORGELT, S.C.; HARRISON, J.D.; SUDDUTH, K.A.; BIRREL, S.J. Evaluation of GPS for applications in Precision Agriculture. Paper. 1996.

Homepage: <http://www.nal.usda.gov/ttic/tektran/data/000006/90/0000069013.html>

BOUMA, J. *From soil survey to a soil data base for precision agriculture.* IN: STAFFORD, J. (ed.). Precision Agriculture, 97- First European Conference on Precision Agriculture. SCI, p.61-69. 1997.

BOUMA, J.; FINKE, P.A. *Origin and Nature of soil resource variability.* IN: ROBERT, P.C. et al (eds.). Procedures of soil specific crop management: A Workshop on Research and Development Issues. SSSA Spec. Publ. Soil Science Society of America, WI. p.1-7. 1993.

BRAGA, L.P.V. Geoestatística e aplicações. Minicurso do 9º simpósio brasileiro de probabilidade e estatística. IME. Universidade de São Paulo. São Paulo. 36p. 1990.

BURROUGH, P.A. Principles of Geographic Information Systems for land resources assesment. Clarendon. Oxford. England. 195p. 1986.

CAAP (Centro Australiano para Agricultura de Precisão). Towards environmentally and economically sustainable agriculture. Paper. 1997.

Homepage: <http://www.usyd.edu.au/su/agric/acpa/intro.htm>

CALKINS, H.W. *Creating large digital files from mapped data. Proceedings, UNESCO conference on computer mapping of natural resources.* Mexico City. México. p. 209-214. 1975.

CÂMARA, G. Anatomia de um SIG. Revista Fator GIS. Sagres Editora. Ano 1, n. 4, p.11-15. Curitiba. 1994.

CAMARGO, O.A.de. Compactação do Solo e Desenvolvimento de Plantas. Fundação Cargill. 44p. 1983.

CAMBARDELLA, C.A.; MOORMAN, T.B.; NOVAK, J.M.; PARKIN, T.B.; KARLEN, D.L.; TURCO, R.F.; KONOPKA, A.E. *Field-scale variability of soil properties in Central Iowa Soils. Soil Science Society of America Journal,* v.58, p.1501-1511. 1994.

CAMELO, L.G.L.; SIERRA, J.; FUMAGALLI, C.; MIGUEZ, S.R. *Variabilidad espacial de fosforo em suelo y planta em un argiudol tipico bajo cultivo de maiz. Revista Facultad de la Agronomia.* Universidade de Buenos Aires, v. 14, n. 1, p.1-8. 1994.

CATI (Coordenadoria de Assistência Técnica Integral). Manual Técnico das Culturas. V.8. 518p. 1986.

CINTRA, J.P. CAD, GIS, DBMS ou cartografia digital? Departamento de transportes. Escola
politécnica da Universidade de São Paulo. São Paulo. Paper. 10p. (s/data).

CLINE, M.G. *Principles of soil sampling. Soil science*, v. 58, p. 275-288. 1944.

CMT (Corvallis MicroTechnology, Inc.). GPS/GIS Seminars. Level I, end-user training. 1996

CORÁ, J.E. The potential for site-specific management of soil and corn yield variability induced by tillage. East Lansing, MI. Tese de Doutorado apresentada à Michigan State University,
USA. 104p. 1997.

CORÁ, J.E.; MARQUES JR,J. Atributos do solo para Agricultura de Precisão. IN: SILVA,
F.M.da (coord). Simpósio de Mecanização e Agricultura de Precisão. XXVII CONBEA.
Poços de Caldas. p.31-70. 1998.

COSTA NETO, P.L.O. Estatística. Editora Edgard Blücher Itda. 262p. 1977.

COWEN, D.J. *GIS versus CAD versus DBMS: what are the differences? Photogrammetric
engineering and remote sensing*. v. 54, n. 11, november, p.1551-1555. 1988.

CRAIN, I.K. e McDONALD, C.L. *From land inventory to land management: the evolution of an
operational GIS. Proceeding. Auto Carto VI*. v. 1, p. 41-50. 1983.

CRESSIE, N.A.C. Statistics for spatial data. John Wiley ed. New York. 900p. 1993.

CUNHA, J.M.P. e JAKOB, A.A.E. O GIS como ferramenta de análise. IN: Sistemas de Informações Geográficas (GIS): Um novo instrumento para os estudos demográficos. Textos NEPO, n.29. Núcleo de Estudos de População, Universidade Estadual de Campinas. p. 6-15. 1994.

DANA, P. Global Positioning System Overview. The Geographer's Craft Project, Department of Geography, University of Texas at Austin. 1999
Homepage: <http://www.utexas.edu/depts/grg/gcraft/notes/gps/gps.html>

DANGERMOND, J. *A review of digital data commonly available and some of the practical problems of entering them into a GIS. Technical papers*. St. Louis. Paper. p.222-232. 1988.

DOE (Department of Environment). Handling Geographic Informations. London. p.1-4. 1987.

DUNN, R.F. *Do the Math. Page probes*. Paper. 1997.
homepage: <http://www.precisionag.com/math.html>

EASTMAN, J.R. Idrisi Manual. Clark University. Graduate School of Geography, Massachusetts. 1992.

EASTMAN, J.R. Idrisi for Windows, v.2. Manual do Usuário. Centro de Recursos Idrisi, Brasil UFRGS. 1998.

EMERSON, J.D. e STRENIO, J. Análise exploratória de dados: técnicas robustas; um guia.

p. 59-96. Ed. Salamandra. Lisboa. 1983.

FANHA, A.B. Caracterização de reservatórios através de técnicas estatísticas multivariadas e modelagem estocástica no campo de baixa do algodão, Bacia Potiguar. Dissertação de Mestrado apresentada ao Instituto de Geociências - UNICAMP. 178p. 1994.

FERRARI, R. Viagem ao SIG. Sagres Editora. Curitiba. 171p. 1997.

FINCK, C. On tap for technology. *Farm Journal, December*, p. 24. 1996.

FINKE, P.A.; GOENSE, D. Differences in barley yields as a result of soil variability. *Journal of Agriculture Science*, v. 120, p.171-180. 1993.

FOLEGATTI, M.V. Estabilidade temporal e variabilidade espacial da umidade e do armazenamento de água em solo siltoso. Tese de Livre Docência apresentada à Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo. 84p. 1996.

FRAISSE, C.W. Agricultura de Precisão: a tecnologia de GIS/GPS chega às fazendas. *Revista Fator GIS.* Sagres Editora. Ano 5, n.21, p. 28-31. Curitiba. 1997.

FUNDACÃO CARGILL. Micronutrientes. 124p. 1982.

GARCÍA, A.G. Variabilidade espacial de atributos físicos do solo e resposta espectral da cultura de feijão irrigado, em imagens aéreas digitais. Dissertação de Mestrado. Escola Superior de Agricultura “Luiz de Queiroz”. Universidade de São Paulo. Piracicaba. 78p. 1997.

GOODCHILD, M.F. *Geographic Information Systems in undergraduate geography: a contemporary dilemma. The operational geographer.* v. 8, p. 34-38. 1985.

GOODCHILD, M.F. e GOPAL, S. Accuracy of spatial database. Taylor and Francis. London. Paper. p.1-3. 1989.

GUIMARÃES, E.C. Variabilidade espacial da umidade e da densidade do solo em um latossolo roxo. Dissertação de Mestrado apresentada à Faculdade de Engenharia Agrícola, UNICAMP. 138p. 1993.

GUIMARÃES, M.M. Caracterização geológica e geoestatística de reservatório carbonático da Bacia de Campos. Dissertação de Mestrado apresentada ao Instituto de Geociências, UNICAMP. 135p. 1994.

HAMLETT, J.M.; HORTON, R.; CRESSIE, N.A.C. *Resistance and exploratory techniques for use in semivariogram analyses. Soil Sci. Soc. Am. Journal,* v. 50. p.868-875. 1986.

HEATH, O.C.S. A estatística na pesquisa científica. Ed. EDUSP. São Paulo. 95p. 1981.

HOEL, P.G. Estatística Elementar. Editora Atlas S.A. 430p. 1981.

HOSKINSON, R. L. *Using GIS in the national site-specific tecnologies for agriculture. ASAE paper* n. 953239. p.2-3. 1995.

ISAAKS, E.H.; SRIVASTAVA, R.M. *An Introduction to Applied Geostatistics. Oxford University Press, New York.* 561p. 1989.

JOHN DEERE CO. 1999

homepage: <http://www.deere.com>

JOHNSON, R.C. *Target Farming - A pratical guide to Precision Farming concepts and tecnology. Paper.* p.1-15. 1996.

JOURNEL, A.G.; HUIJBREGTS, C.J. *Mining Geostatistics. Academic Press, London.* 600p. 1978.

KECKLER, D. *Surfer for Windows: user's guide, v.6: Contouring and 3D surface mapping.* Colorado: Golden Software. 1995. 1v.

LANGDALE, G.W.; SHRADER, W.D. *Soil erosion effects on soil productivity of cultivated cropland.* IN: SCHMIDT, B.L.(ed.). *Determinants of soil loss tolerance. Madison. ASA Meeting Presentation.* p. 95-111. 1982.

MALAVOLTA, E. *Manual de Química Agrícola. Adubos e Adubação.* Ed. Agronômica Ceres. 487p. 1959.

_____. Elementos de Nutrição Mineral de Plantas. Ed. Agronômica Ceres. 251 p.
1980.

_____. (coord). Seminário sobre Corretivos Agrícolas. Fundação Cargill. 375p. 1985.

MALAVOLTA, E.; HAAG, H.P.; MELLO, F.A.F.; BRASIL SOBRINHO, M.O.C. Nutrição
Mineral e Adubação de Plantas Cultivadas. Livraria Pioneira Ed. 142p. 1974.

MARBLE, D.F. et al. *Geographic Informations Systems and Remote Sensing. The manual of
Remote Sensing. American Society of Photogrammetry*. Falls Church.
Virginia. v.1, p. 923-958. 1983.

MATHERON, G. *Principles of geoestatistics. Economic geology*. El Paso. v. 58. p.1246-1266.
1963.

McGRAW, T. *Soil Test Level Variability in Southern Minnesota (Minnesota). Better crops with
plant food*. Georgia. v. 78, n. 4, p. 24-25. 1994.

MEDINA, J.C. Melhoramento e Produção do Milho no Brasil. 650p. 1997.

MILLER, M.P.; SINGER, M.J.; NIELSEN, D.R. *Spatial variability of wheat yield and soil
properties on complex hills. Soil Science Society of American Journal*, v. 52, p.1133-1141.
1988.

MIRANDA, L.T.; MIRANDA, L.E.C.; SAWAZAKI, E. Genética Ecológica e Melhoramento de Milho. Fundação Cargill. 30p. 1984.

MORETTIN, P.A. e BUSSAB, W.O. Estatística básica. 4^a edição. Ed. Atual. São Paulo. 321p. 1987.

MORRIS, R.M.; BLACKMORE, B.S.; WHEELER, P.N.; JONES, R.J.A.; MORRIS, J. The role of Precision Farming in sustainable agriculture: a European perspective. Paper. 1994.
homepage: http://www.ag.arizona.edu/precisionag/pf_dd_frame.htm

MOURA, A.G.de. Tópicos de Estatística Descritiva. Cadernos Didáticos, v.6. Universidade Católica de Goiás. 146p. 1995.

MULLA, D.J.; BHATTI, A.V.; KUNKEL, R. *Methods for removing spatial variability from field research trials. Advances in Soil Science*, v. 13, p. 201-213. 1990.

MULLA, D.J. *Geoestatistics, remote sensing and precision farming. 1997 Precision Agriculture: Spatial and Temporal Variability of Environmental Quality*. Wiley, Chichester (Ciba Foundation Symposium 210) p.100-119. 1997.

MULLA, D.J.; SCHEPERS, J.S. *Key processes and properties for site-specific soil and crop management*. IN: PIERCE, F.J.; SADLER, E.J. (eds.). The state of site-specific management for agriculture. ASA misc. Publ. ASA, CSSA, SSSA, Madison, WI. p.1-18. 1997.

NIELSEN, D.R.; BIGGAR, W.; ERB, K.T. *Spatial variability of field-measured soil-water properties.* Hilgardia, v. 42, n. 7, p.215-259. 1973.

OLIVEIRA, A.J.de; GARRIDO, W.E.; ARAÚJO, J.D.de; LOURENÇO, S. (coord). Métodos de Pesquisa em Fertilidade do Solo. Empresa Brasileira de Pesquisa Agropecuária. Brasília.392p. 1991.

OLIVEIRA, J.B.de; JACOMINE, P.K.T.; CAMARGO, M.N. Classes gerais de solos do Brasil. Guia auxiliar para seu reconhecimento. UNESP, FUNEP. 201p. 1992.

PARENT, P.J. Geographic Information Systems: evolution, academic involvement and issues arising from the proliferation of information. Master's thesis. University of Santa Barbara. California. p.20-32. 1988.

POWER, J.F.; RIES, R.E.; SALDOVAL,F.M. *Quality parameters of spring wheat and forage crops related to topsoil and subsoil thickness.* Soil Science Society of American Journal, v. 46. p.381-386. 1982.

RAIJ, B.V. Avaliação da Fertilidade do Solo. Instituto da Potassa & Fosfato (EUA), Instituto Internacional da Potassa (Suíça). 142p. 1983.

REICHARDT, K.; VIEIRA, S.R.; LIBARDI, P.L. Variabilidade espacial de solos e experimentação de campo. Revista Brasileira Ciência do Solo, Campinas, v. 10, p.1-6. 1986.

REICHENBERGER, L. e RUSSNOGLE, J. *Farm by the foot*, Farm Journal, March, p. 11-15.

1989.

REMACRE, A.Z. Krigagem da Média. Geociências, v.15, n.1, p. 9-16. 1996.

ROBERT, P. *A guide to Precision System*, Fin Special Issue, p.12-16. (s/data).

ROYLE, A.G. *Estimating small blocks of Ore. How do it with confidence*. World Mining. 1979

RUNYON, J. *Environmental management solutions for agriculture: integrating field inspections, GIS, GPS, and aerial photography*, Geo Info Systems, April, p. 42-44. 1994.

SALVIANO, A.A.C. Variabilidade de atributos de solo e de crotalaria juncea L. em solo degradado do município de Piracicaba-SP. Tese de Doutorado apresentada à Escola Superior de Agricultura “Luiz de Queiroz” da Universidade de São Paulo. 83p. 1996.

SAS. SAS Procedures guide for personal computers. Version 6 edition. p.350-357. 1985.

SCHLOTZHAUER, S.D.; LITTEL, R.C. SAS System for elementary statistical analysis. p. 118-121. 1987.

SESSAY, M.F.; STOCKING, M.A. *Soil productivity and fertility maintenance of a degraded oxisol in Sierra Leone*. IN: *Sustainable land management in African semi-arid and subhumid regions*. Proceedings. Dakar, Senegal. p.189-201. 1995.

SHAPIRO, S.S.; WILK, M.B. An analysis of variance test for normality (complete samples). Biometrika, n.52, p. 591-611. 1965.

SILVA, A.B. Sistema de Informação Georeferenciada: uma introdução. 127p. (no prelo).

SILVA, A.P. Variabilidade espacial de atributos físicos do solo. Tese de Doutorado apresentada à Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo. 105p. 1988.

SOKAL, R.R. e ROHLF, F.J. Biometry. Ed. Freeman. San Francisco. Paper. p.1-5. 1969.

SOUZA, L.S. Variabilidade espacial do solo em sistemas de manejo. Tese de Doutorado apresentada à Universidade Federal do Rio Grande do Sul, Porto Alegre. 162p. 1992.

SPIEGEL, M. Estatística. Coleção Schaum. 4^a edição. McGraw-Hill. 454p. 1985.

STAR, J. e ESTES, J. Geographic Information Systems: an introduction. Practice Hall. New Jersey. p.14-23. 1990.

STEINITZ, C.; PARKER, P.; JORDAN, L. *Hand-drawn overlays: their history and prospective uses*. Landscape architecture. September. p.444-455. 1976.

THOMPSON, S.K. *Spatial Sampling*. IN: 1997 Precision Agriculture: Spatial and Temporal Variability of Environmental Quality. Wiley, Chichester (Ciba Foundation Symposium 210), p. 100-119. 1997.

TOLEDO, G.L.; OVALLE, I.I. Estatística Básica. 2^a edição. Editora Atlas. 460p. 1991.

TRANGMAR, B.B.; YOST, R.S.; UEHARA, U. *Application of Geostatistics to Spatial Studies of Soil Properties*. Advances in Agronomy. v.38, p.45-94. 1985.

TWEETEN, L. *Is Precision Farming Good for Society? Better crops with plant food*. v. 80, n. 3, p.3-5. 1996.

VAUCLIN, M.; VIEIRA, S.R.; BERNARD, R.; HATFIELD, J.L. *Spatial variability of surface temperature along transects of a bare soil*. Water resources research. v. 18. Washington. p.1677-1686. 1982.

VIEIRA, S.R.; TILLOTSON, P.M.; BIGGAR, J.W.; NIELSEN, D.R. *Scaling of semivariograms and the kriging estimation of field-measured properties*. Revista Brasileira Ciência do Solo. Viçosa, v. 21. p.525-533. 1997.

VIEIRA, S.R.; DECHEN, S.C.F.; MARIA, I.C.de. Uso de Geoestatística no mapeamento de atributos de solo e planta. *Paper*. GIS BRASIL, Curitiba. 12p. 1998.

WONNACOTT, R.J.; WONNACOTT, T.H. Fundamentos da Estatística. Livros técnicos e Científicos. Ed. S.A. 350p. 1985.