

unesp  **UNIVERSIDADE ESTADUAL PAULISTA**

Faculdade de Ciências e Tecnologia

Programa de Pós-Graduação em Ciências Cartográficas

JAQUELINE VICENTE



**ESTUDO COMPARATIVO DE MÉTODOS
GEOESTATÍSTICOS APLICADOS EM
AGRICULTURA DE PRECISÃO**

PRESIDENTE PRUDENTE

ABRIL 2004



JAQUELINE VICENTE

**ESTUDO COMPARATIVO DE MÉTODOS
GEOESTATÍSTICOS APLICADOS EM AGRICULTURA
DE PRECISÃO**

**Dissertação apresentada ao
Programa de Pós-Graduação em
Ciências Cartográficas da Faculdade
de Ciências e Tecnologia da UNESP,
para a obtenção do título de Mestre
em Ciências Cartográficas.**

**Orientador:
Prof. Dr. Nilton Nobuhiro Imai**

PRESIDENTE PRUDENTE

ABRIL 2004

DADOS CURRICULARES

JAQUELINE VICENTE

Nascimento 26/01/1980 – Presidente Prudente/SP.
Filiação José Vicente Filho.
Vergínia Davoli Vicente.

1997 – 2001 Curso de Graduação.
Faculdade de Ciências e Tecnologia da Universidade
Estadual Paulista “Júlio de Mesquita Filho” – Campus de
Presidente Prudente.
Engenharia Cartográfica.

2002 – 2004 Programa de Pós-Graduação em Ciências Cartográficas da
Faculdade de Ciências e Tecnologia da Universidade
Estadual Paulista “Júlio de Mesquita Filho” – Campus de
Presidente Prudente.
Mestrado em Ciências Cartográficas.

DEDICATÓRIA

À minha querida mãe, Vergínia, por todas as dificuldades superadas, por me esperar até tarde, mesmo cansada e por agüentar o meu “stress” nas épocas mais turbulentas. Não tenho palavras pra agradecer por tudo que fez para me ver chegar até aqui.

Ao meu pai, José (in memorian), pelos exemplos de vida que deixou e por tudo que me ensinou em vida.

Ao meu marido, pelo amor que sente por mim e por sempre acreditar que chegaremos juntos a algum lugar.

AGRADECIMENTOS

Gostaria de agradecer a CAPES pelo apoio financeiro durante o desenvolvimento da pesquisa, ao meu orientador Prof. Dr. Nilton Nobuhiro Imai pela orientação desde as bolsas de iniciação científica até o mestrado. Gostaria de agradecer a banca, pelas sugestões e críticas construtivas que com toda certeza só me ajudarão a melhorar esse trabalho. A EMBRAPA – Soja de Londrina - PR e a Cooperativa de Palotina - PR, por fornecer os dados de rendimento da soja. Ao Gege (Geraldo Lonien) e ao Adriano, funcionários da EMBRAPA pela grande ajuda na coleta dos dados em campo. Ao professor Elemar Voll pelas dicas. Ao Eduardo (EMBRAPA), Ítalo Tysushia (FCT - UNESP) e aos estagiários Paulo, Daniel e Lauriana pela ajuda nos trabalhos de campo, ao professor Júlio Kiyoshi Hasegawa, aos amigos Aninha (Nilcilene), Airton e Clélia, pela grande ajuda com o Matlab. Ao pessoal da sala 12 pela compreensão nas horas de *stress*. Aos funcionários e professores do departamento de cartografia e da seção de pós-graduação. À todos os amigos do Programa de Pós Graduação em Ciências Cartográficas e aos que sempre me deram força mesmo à distância. Ao meu irmão Luiz Eduardo Vicente, pelo exemplo de vida e de caráter, à sua esposa Andréa e ao meu sobrinho Luiz Felipe pela força e o incentivo em todos os momentos. Ao meu sogro e minha sogra, Sr. Cláudio e D. Neli, por tudo que fizeram por mim desde que nos conhecemos, e por me acolherem com tanto carinho em sua família.

Obrigada a todos.

EPÍGRAFE

*“A vitória mais bela que se pode
alcançar é vencer a si mesmo.”*

Santo Ignácio de Loyola

SUMÁRIO

LISTA DE FIGURAS	10
LISTA DE TABELAS	14
LISTA DE SIGLAS E ABREVIATURAS	15
RESUMO	16
ABSTRACT	17
1. INTRODUÇÃO	18
1.1. Descrição Geral	18
1.2. Hipótese	21
1.3. Objetivo	22
1.4. Justificativa	22
1.5. Estrutura do Trabalho	23
2. VARIÁVEIS REGIONALIZADAS	25
2.1. Características das Variáveis Regionalizadas.....	27
2.2. Análise da Continuidade ou Variabilidade Espacial	28
3. FUNÇÃO VARIOGRAMA	30
3.1. Parâmetros do Semivariograma	32
3.2. Modelando os Semivariogramas Experimentais	34
3.3. Restrições para o Modelo de Semivariograma	35
3.3.1. Modelos de Variogramas Positivos Definidos	36
3.3.2. Modelos em Uma Direção	39
3.4. Anisotropia	41
3.4.1. Modelos de Anisotropia.....	43
3.4.1.1. Anisotropia Geométrica para uma estrutura	47
3.4.1.2. Anisotropia Geométrica para efeito pepita e duas estruturas	48
3.4.1.3. Anisotropia Zonal e Geométrica.....	50
3.5. Modelo Linear de Corregionalização	55
4. INFERÊNCIAS UTILIZANDO OS MÉTODOS DE KRIGAGEM E COKRIGAGEM....	58
4.1. Krigagem.....	58
4.1.1. Variância dos Erros Estimados	61
4.1.2. Krigagem Ordinária	63
4.1.3. Krigagem Indicadora ou por Indicação	66
4.2. Cokrigagem.....	69

4.2.1. Cokrigagem Indicadora ou Não Linear	72
4.2.2. Cokrigagem Ordinária Padronizada	73
4.2.3. Cokrigagem Co-localizada	73
5. COMPORTAMENTO ESPECTRAL DA VEGETAÇÃO E DO SOLO.....	75
5.1. Características da Reflectância Espectral da Vegetação: a Função Distribuição da Reflectância Bidirecional.....	77
5.1.1. Função Distribuição da Reflectância Bidirecional	78
5.2. Índices de Vegetação	80
5.2.1. Razão Simples	81
5.2.2. Índice de Vegetação Diferença Normalizada (NDVI).....	84
6. MATERIAIS E MÉTODOS.....	87
6.1. Coleta dos Dados	87
6.1.1. Sistema de Aquisição de Imagens	88
6.2. Processamento Digital das Imagens	91
6.2.1. Fototriangulação e Retificação das Imagens	91
6.2.2. Estimativa do Fator de Reflectância	92
6.2.3. Normalização Radiométrica das Imagens	93
6.2.4. Georreferenciamento (Registro de Imagens) e Geração do Mosaico	95
6.2.5. Geração das Imagens Razão	97
6.3. Métodos de Interpolação.....	97
6.3.1. Interpolação pelo Método da Krigagem.....	97
6.3.2. Interpolação pelo Método da Cokrigagem	99
6.4. Coeficiente de Concordância Kappa	100
7. EXPERIMENTOS E RESULTADOS	103
7.1. Coleta dos Dados para o Primeiro Experimento - Palotina - PR.....	103
7.2. Realização dos processos de Interpolação para o Experimento 1	104
7.2.1. Análise Exploratória do Subconjunto de Dados Amostrais	106
7.2.2. Krigagem Ordinária Isotrópica (KOI)	108
7.2.3. Krigagem Ordinária Anisotrópica (KOA)	109
7.2.4. Krigagem Indicadora Isotrópica (KII)	113
7.2.5. Análise dos Resultados Obtidos pelos Processos de Interpolação do Experimento 1	115
7.3. Coleta dos Dados de Rendimento e das Imagens para o Segundo Experimento – Londrina - PR	119

7.3.1. Aquisição das Imagens	120
7.3.2. Levantamento Geodésico e Coleta dos Dados de Rendimento	121
7.4. Processamento Digital das Imagens	124
7.4.1. Fototriangulação e Retificação das Imagens	124
7.4.2. Estimativa do Fator de Reflectância	125
7.4.3. Normalização das Imagens	126
7.4.4. Georreferenciamento e Geração do Mosaico	133
7.5. Realização dos processos de Interpolação para o Experimento 2	135
7.5.1. Análise Exploratória do Subconjunto de Amostras	136
7.5.2. Krigagem Ordinária Isotrópica (KOI)	137
7.5.3. Krigagem Ordinária Anisotrópica (KOA)	139
7.5.4. Krigagem Indicadora Isotrópica (KII)	143
7.5.5. Cokrigagem.....	145
7.5.5.1. Verificação da Correlação entre as Variáveis.....	145
7.5.5.2. Geração dos Semivariogramas	148
7.5.6. Análise dos Resultados Obtidos pelos Processos de Interpolação do Experimento 2	149
8. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES	154
8.1. Considerações Finais	154
8.2. Conclusões	155
8.3. Recomendações	159
REFERÊNCIAS BIBLIOGRÁFICAS	160
BIBLIOGRAFIA CONSULTADA	162

LISTA DE FIGURAS

FIGURA 1.1 – RELAÇÃO ENTRE FITOMASSA, RESPOSTA ESPECTRAL E FATORES QUE DETERMINAM O RENDIMENTO.....	22
FIGURA 2.1 (A) E (B) - COMPONENTES PRINCIPAIS DA VARIAÇÃO ESPACIAL.....	26
FIGURA 3.1 – DISPERSÃO DE UMA VARIÁVEL $V(X)$ PARA UMA DETERMINADA DISTÂNCIA	30
FIGURA 3.2 – EXEMPLO DE SEMIVARIOGRAMA EXPERIMENTAL.....	33
FIGURA 3.3 – MODELO TEÓRICO DE TRANSIÇÃO DO TIPO ESFÉRICO	37
FIGURA 3.4 – MODELO TEÓRICO DE TRANSIÇÃO DO TIPO EXPONENCIAL.....	38
FIGURA 3.5 – MODELO TEÓRICO DE TRANSIÇÃO DO TIPO GAUSSIANO.....	38
FIGURA 3.6 – AGRUPAMENTO BIDIMENSIONAL DOS DADOS PARA FORMAR UM VARIOGRAMA DE SUPERFÍCIE	41
FIGURA 3.7 – VARIOGRAMA DE SUPERFÍCIE UTILIZADO NA CONSTRUÇÃO DO MAPA DE CONTORNO.....	42
FIGURA 3.8 – DIAGRAMA DE ROSA PARA SEIS DIREÇÕES.....	42
FIGURA 3.9 – EXEMPLO DE ANISOTROPIA: (A) GEOMÉTRICA, (B) MISTURA DE ANISOTROPIA ZONAL E GEOMÉTRICA.....	43
FIGURA 3.10 – MODELO DIRECIONAL DE VARIOGRAMA COM O MESMO PATAMAR.....	44
FIGURA 3.11 – MODELOS DE VARIOGRAMAS DIRECIONAIS AO LONGO DE TRÊS EIXOS DE ANISOTROPIA	47
FIGURA 3.12 – MODELOS QUE APRESENTAM MAIS DE UMA ESTRUTURA.....	48
FIGURA 3.13 – MODELO VARIOGRAMA DIRECIONAL COM ANISOTROPIA ZONAL E GEOMÉTRICA	51
FIGURA 3.14 – ROTAÇÕES REALIZADAS NOS EIXOS DE ANISOTROPIA.....	55
FIGURA 4.1 – CODIFICAÇÃO POR INDICAÇÃO DOS DADOS AMOSTRAIS PARA O VALOR DE CORTE $Z=Z_k$	67
FIGURA 5.1 - MÉDIAS ESTIMADAS PARA RAZÃO SIMPLES	85
FIGURA 5.2 - MÉDIAS ESTIMADAS PARA NDVI.....	85
FIGURA 6.1 – ESQUEMA DOS LEVANTAMENTOS DE CAMPO REALIZADOS PARA AMBOS OS EXPERIMENTOS.....	88
FIGURA 6.2– SISTEMA DE AQUISIÇÃO DE IMAGENS.....	89
FIGURA 6.3– ÂNGULO DE VISADA DA CÂMARA.....	93
FIGURA 6.4 – DIAGRAMA DO PROCESSO DE KRIGAGEM	98
FIGURA 6.5 – DIAGRAMA DO PROCESSO DE COKRIGAGEM	100

FIGURA 7.1 – POSIÇÕES DOS ELEMENTOS AMOSTRAIS DO PRIMEIRO EXPERIMENTO	103
FIGURA 7.2 – SUBCONJUNTO DE AMOSTRAS ESTRATIFICADAS	104
FIGURA 7.3 – INTERPOLAÇÃO DO CONJUNTO TOTAL DE ELEMENTOS AMOSTRAIS	106
FIGURA 7.4 – HISTOGRAMA DOS DADOS DO SUBCONJUNTO DE ELEMENTOS AMOSTRAIS DE RENDIMENTO	106
FIGURA 7.5 – GRÁFICO DE ADERÊNCIA DOS DADOS	107
FIGURA 7.6 – SEMIVARIOGRAMA DE SUPERFÍCIE.....	107
FIGURA 7.7– CONVENÇÕES GEOMÉTRICAS UTILIZADAS EM GEOESTATÍSTICA	107
FIGURA 7.8 – SEMIVARIOGRAMA PARA A DIREÇÃO DE MAIOR CONTINUIDADE.....	108
FIGURA 7.9 – INTERPOLAÇÃO POR KRIGAGEM ORDINÁRIA ISOTRÓPICA	109
FIGURA 7.10 – MAPA DE VARIÂNCIA DA KRIGAGEM ORDINÁRIA ISOTRÓPICA	109
FIGURA 7.11 – SEMIVARIOGRAMA PARA A DIREÇÃO DE MAIOR CONTINUIDADE.....	110
FIGURA 7.12 – SEMIVARIOGRAMA PARA A DIREÇÃO DE MENOR CONTINUIDADE.....	110
FIGURA 7.13 – MODELAGEM DA ANISOTROPIA	111
FIGURA 7.14 - INTERPOLAÇÃO POR KRIGAGEM ORDINÁRIA ANISOTRÓPICA.....	112
FIGURA 7.15 – MAPA DE VARIÂNCIA DA KRIGAGEM ORDINÁRIA ANISOTRÓPICA.....	112
FIGURA 7.16 - CORTE 1	113
FIGURA 7.17 - CORTE 2	113
FIGURA 7.18 - CORTE 3	113
FIGURA 7.19 - CORTE 4	113
FIGURA 7.20- CORTE	113
FIGURA 7. 21- CORTE 6	113
FIGURA 7.22 - CORTE 7	113
FIGURA 7.23 - CORTE 8	113
FIGURA 7.24 - CORTE 9	114
FIGURA 7.25 - INTERPOLAÇÃO POR KRIGAGEM INDICADORA ISOTRÓPICA	115
FIGURA 7.26 – MAPA DE INCERTEZA DA KRIGAGEM INDICADORA ISOTRÓPICA	115
FIGURA 7.27 – MAPA TEMÁTICO DA KRIGAGEM ORDINÁRIA ISOTRÓPICA	116
FIGURA 7.28 - MAPA TEMÁTICO DA KRIGAGEM ORDINÁRIA ANISOTRÓPICA.....	116
FIGURA 7.29 - MAPA TEMÁTICO DA KRIGAGEM INDICADORA ISOTRÓPICA	116
FIGURA 7.30 – MAPA DO CONJUNTO TOTAL DE ELEMENTOS AMOSTRAIS	116
FIGURA 7.31 – ÁREA IMAGEADA	121
FIGURA 7.32 – LEVANTAMENTO DOS PONTOS COM O RECEPTOR GPS.....	123
FIGURA 7.33 – CROQUI DO LEVANTAMENTO DOS DADOS DE RENDIMENTO	123

FIGURA 7.34 – IMAGEM NÃO RETIFICADA	125
FIGURA 7.35 – IMAGEM RETIFICADA	125
FIGURA 7.36 – DIAGRAMA DA ROTINA PARA TRANSFORMAÇÃO DAS IMAGENS.....	126
FIGURA 7.37 – VARIAÇÃO DO ÂNGULO DE VISADA DA CÂMERA	126
FIGURA 7.38 – HISTOGRAMA PADRÃO DAS IMAGENS SEM VARIAÇÃO DE ÂNGULO	129
FIGURA 7.39 – HISTOGRAMA PADRÃO DAS A COM VARIAÇÃO DE ÂNGULO	129
FIGURA 7.40 – HISTOGRAMA DA IMAGEM CORRIGIDA	130
FIGURA 7.41 – RESULTADO DA RAZÃO DE BANDAS PARA UMA DAS IMAGENS	133
FIGURA 7.42 – MOSAICO COM AS IMAGENS RAZÃO SIMPLES	134
FIGURA 7.44 – CONJUNTO TOTAL DE ELEMENTOS AMOSTRAIS.....	135
FIGURA 7.45 – SUBCONJUNTO DE ELEMENTOS AMOSTRAIS	135
FIGURA 7.46 – INTERPOLAÇÃO DO CONJUNTO TOTAL DE ELEMENTOS AMOSTRAIS.....	136
FIGURA 7.47 – HISTOGRAMA.....	136
FIGURA 7.48 – GRÁFICO DA PROBABILIDADE NORMAL.....	136
FIGURA 7.49 – SEMIVARIOGRAMA DE SUPERFÍCIE.....	137
FIGURA 7.50– CONVENÇÕES GEOMÉTRICAS UTILIZADAS EM GEOESTATÍSTICA.....	137
FIGURA 7.51 – SEMIVARIOGRAMA PARA A DIREÇÃO DE MAIOR ALCANCE.....	138
FIGURA 7.52 – KRIGAGEM ORDINÁRIA ISOTRÓPICA	139
FIGURA 7.53 – MAPA DE VARIÂNCIA DA KRIGAGEM ORDINÁRIA ISOTRÓPICA	139
FIGURA 7.54 – SEMIVARIOGRAMA PARA A DIREÇÃO DE MAIOR ALCANCE.....	140
FIGURA 7.55 – SEMIVARIOGRAMA PARA A DIREÇÃO DE MENOR ALCANCE.....	140
FIGURA 7.56 – MODELAGEM DA ANISOTROPIA.....	141
FIGURA 7.57 - INTERPOLAÇÃO POR KRIGAGEM ORDINÁRIA ANISOTRÓPICA	142
FIGURA 7.58 – MAPA DE VARIÂNCIA DA KRIGAGEM ORDINÁRIA ANISOTRÓPICA	142
FIGURA 7.59 – CORTE 1.....	143
FIGURA 7.60 – CORTE 2.....	143
FIGURA 7.61 – CORTE 3.....	143
FIGURA 7.62 - INTERPOLAÇÃO POR KRIGAGEM INDICADORA ISOTRÓPICA	144
FIGURA 7.63 – MAPA DE VARIÂNCIA DA KRIGAGEM INDICADORA ISOTRÓPICA	144
FIGURA 7.64 – GRÁFICO DA CORRELAÇÃO	147
FIGURA 7.65 – SEMIVARIOGRAMA INDIVIDUAL PARA A VARIÁVEL PRIMÁRIA (RENDIMENTO)	148
FIGURA 7.66 – SEMIVARIOGRAMA INDIVIDUAL PARA A VARIÁVEL SECUNDÁRIA (VALOR DA RAZÃO).....	148

FIGURA 7.67 – SEMIVARIOGRAMA CRUZADO PARA A VARIÁVEL PRIMÁRIA E SECUNDÁRIA	148
FIGURA 7.68 – MAPA TEMÁTICO DA KRIGAGEM ORDINÁRIA ISOTRÓPICA	150
FIGURA 7.69 – MAPA TEMÁTICO DA KRIGAGEM ORDINÁRIA ANISOTRÓPICA	150
FIGURA 7.70 – MAPA TEMÁTICO DA KRIGAGEM INDICADORA ISOTRÓPICA	150
FIGURA 7.71 – MAPA TEMÁTICO DO CONJUNTO TOTAL DE ELEMENTOS AMOSTRAIS	150

LISTA DE TABELAS

TABELA 5.1 – VARIÁVEIS QUE INTERFEREM NA FUNÇÃO DISTRIBUIÇÃO BIDIRECIONAL DA REFLECTÂNCIA DE UMA COBERTURA VEGETAL.....	77
TABELA 7.1 – PARÂMETROS DOS SEMIVARIOGRAMAS DE MAIOR E MENOR ALCANCE.....	110
TABELA 7.2– PARÂMETROS DO SEMIVARIOGRAMA ANINHADO	112
TABELA 7.3 – PARÂMETROS DE AJUSTE DOS SEMIVARIOGRAMAS	114
TABELA 7.4 – MATRIZ DE CONFUSÃO PARA KRIGAGEM ORDINÁRIA ISOTRÓPICA	117
TABELA 7.5 - MATRIZ DE CONFUSÃO PARA KRIGAGEM ORDINÁRIA ANISOTRÓPICA	118
TABELA 7.6 - MATRIZ DE CONFUSÃO PARA KRIGAGEM INDICADORA ISOTRÓPICA	118
TABELA 7.7 – ÍNDICE DE CONCORDÂNCIA KAPPA	119
TABELA 7.8 – MÉDIA E DESVIO PADRÃO DOS FATORES DE REFLECTÂNCIA NA BANDA DO VERMELHO ANTES DA NORMALIZAÇÃO.....	127
TABELA 7.9 – MÉDIA E DESVIO PADRÃO DOS FATORES DE REFLECTÂNCIA NA BANDA DO INFRAVERMELHO ANTES DA NORMALIZAÇÃO.....	128
TABELA 7.10 – MÉDIA E DESVIO PADRÃO DOS FATORES DE REFLECTÂNCIA PARA A BANDA DO VERMELHO DEPOIS DA NORMALIZAÇÃO.....	131
TABELA 7.11 – MÉDIA E DESVIO PADRÃO DOS FATORES DE REFLECTÂNCIA PARA A BANDA DO INFRAVERMELHO DEPOIS DA NORMALIZAÇÃO.....	132
TABELA 7.12 – PARÂMETROS DO SEMIVARIOGRAMA.....	138
TABELA 7.13 – PARÂMETROS DOS SEMIVARIOGRAMAS DE MAIOR E MENOR ALCANCES	140
TABELA 7.14 – PARÂMETROS DO SEMIVARIOGRAMA ANINHADO.....	141
TABELA 7.15 – PARÂMETROS DE AJUSTE DOS SEMIVARIOGRAMAS.....	144
TABELA 7.16 – VALORES DO RENDIMENTO E DA RAZÃO	146
TABELA 7.17 – MATRIZ DE CONFUSÃO PARA KRIGAGEM ORDINÁRIA ISOTRÓPICA	151
TABELA 7.18 – MATRIZ DE CONFUSÃO PARA KRIGAGEM ORDINÁRIA ANISOTRÓPICA	151
TABELA 7.19 – MATRIZ DE CONFUSÃO PARA KRIGAGEM INDICADORA ISOTRÓPICA	152
TABELA 7.20 – ÍNDICE DE CONCORDÂNCIA KAPPA	152

LISTA DE SIGLAS E ABREVIATURAS

CoKI	– Cokrigagem Co-localizada Isotrópica
EMBRAPA	– Empresa Brasileira de Pesquisa Agropecuária
GPS	– Global Positioning System
KOI	– Krigagem Ordinária Isotrópica
KOA	– Krigagem Ordinária Anisotrópica
KII	– Krigagem Indicadora Isotrópica
LAI	– Índice de Área Foliar
NDVI	– Índice de Vegetação Diferença Normalizada
NIR	– Infra Vermelho Próximo (Near Infra-Red)
R	– Vermelho (Red)
RS	– Razão Simples
UNESP	– Universidade Estadual Paulista

Vicente, J. *Estudo Comparativo de Métodos Geoestatísticos Aplicados em Agricultura de Precisão*. 2004. 163 p. Dissertação (Mestrado em Ciências Cartográficas) - Programa de Pós-Graduação em Ciências Cartográficas, Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente.

RESUMO

O rendimento das culturas pode variar no espaço em decorrência da heterogeneidade das formas do relevo, dos tipos de solo e do manejo ao qual estes solos têm sido submetidos. Como uma de suas estratégias principais, a agricultura de precisão fundamenta-se na coleta sistemática e o processamento de dados georreferenciados para produzir informações que permitam manter os processos produtivos sob controle, orientando-os ao aprimoramento contínuo. Na agricultura de precisão tem sido adotados dois métodos para obter superfícies que apresentam a distribuição espacial do rendimento. O primeiro utiliza amostragem aleatória do rendimento. O segundo faz uso de uma amostragem sistemática com colhedeira equipada com receptor GPS e um dispositivo de estimativa de peso dos grãos colhidos. Este oferece medidas de rendimentos mais precisas, porém a um custo mais elevado. Sabendo-se que imagens multiespectrais de sensoriamento remoto podem apresentar correlação com a vegetação, as mesmas podem ser utilizadas como dados adicionais no processo de reconstrução de superfícies. Nesta pesquisa, realizou-se o estudo comparativo dos métodos de krigagem ordinária isotrópica e anisotrópica, indicadora isotrópica e a cokrigagem, utilizando dois conjuntos de dados de rendimento de soja, além de imagens multiespectrais obtidas com uma câmara digital. Os resultados obtidos no primeiro experimento, mostraram que o processo de krigagem anisotrópica foi o mais adequado na modelagem do rendimento da soja. Para o segundo experimento, os resultados confirmaram que o processo de krigagem ordinária anisotrópica foi o mais adequado. Porém, os índices de concordância kappa para o segundo experimento não mostraram resultados muito satisfatórios na comparação entre o mapa de referência e os mapas obtidos pelos processos de krigagem. Nesse último experimento, tentou-se ainda realizar o processo de cokrigagem utilizando imagens multiespectrais obtidas com a câmara digital DuncaTech MS-3100, com visada inclinada. Porém, não foi possível a realização do processo de cokrigagem, pois o rendimento da soja (variável primária) e o valor da razão espectral (variável secundária) não apresentaram correlação nesse estudo de caso.

Vicente, J. *Estudo Comparativo de Métodos Geoestatísticos Aplicados em Agricultura de Precisão*. 2004. 163 p. Dissertação (Mestrado em Ciências Cartográficas) - Programa de Pós-Graduação em Ciências Cartográficas, Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente.

ABSTRACT

The crop yield can vary in the space due to the heterogeneity of the relief, of the soil types and to the handling to which these soils have been submitted. As one of their main strategies, the precision farming is based on a systematic acquisition and the georeferenced data processing that produce information to allow to maintaining the productive processes under control, guiding them to the continuous improvement. In the project of precision farming it has been adopted two methods to obtain crop yield distribution surfaces. The first adopt random sampling of the income. The second is based on a systematic sampling with harvester equipped with receiver GPS and a device that estimates the weight of the picked grains. This method offers more accurate measures of crop yields, however at a higher cost. Considering that multispectral images of remote sensing can be correlated correlation with the vegetation, the same ones can be applied as additional data in the process of surfaces reconstruction. In this research, it has been accomplished a comparative study of the methods of isotropic and anisotropic ordinary kriging, isotropic indicator kriging and the cokriging, using two soybean crop yield data sets, besides multispectral images obtained with a digital camera. The results of the first experiment, for a crop area reasonably big, showed that the process of anisotropic kriging was the most appropriate in the modelling of the crop yield of the soy. For the second experiment, the results confirmed that the process of anisotropic ordinary kriging was the most appropriate. However, the kappa indexes was not very satisfactory. In that last experiment, it was still tried to accomplish the cokriging process using off nadir multispectral images acquired by the DuncaTech MS-3100 digital camera. However, it was not possible the accomplishment of the cokriging process, because the crop yield of the soybean (primary variable) and the value of the spectral ratio (secondary variable) they didn't correlate in that study case.

1. INTRODUÇÃO

1.1. Descrição Geral

De acordo com STAFFORD (1996), a agricultura de precisão, também chamada de prescrição localizada, pode ser definida como a aplicação localizada e econômica dos recursos para a produção agrícola, com base na variabilidade espacial das necessidades das culturas.

Considera-se a agricultura de precisão como uma estratégia voltada ao refinamento do processo produtivo agrícola, através do uso intenso da informação, visando a otimização da rentabilidade e da sustentabilidade das culturas, com prioridade à proteção do meio ambiente. O desenvolvimento desta técnica teve lugar no início da década de 1980 por alguns setores da agricultura, em países desenvolvidos, liderados pelos Estados Unidos, Inglaterra, Canadá e Austrália.

A agricultura de precisão fundamenta-se na coleta sistemática e no processamento de dados georreferenciados para produzir informações que permitam manter os processos produtivos sob controle, orientando-os ao aprimoramento contínuo. Ela pressupõe que a maximização da qualidade do produto e da rentabilidade de todo o sistema produtivo é promovida pelo gerenciamento localizado e pela otimização de cada etapa desse processo. Nestas condições, agrega-se ao produto uma vantagem competitiva que nem sempre lhe é conferida pela agricultura convencional, quando apenas reduzem-se custos, ou busca-se a elevação da produtividade como forma de maximizar a renda líquida das explorações.

Basicamente, a integração da produção agrícola através da agricultura de precisão está fundamentada no uso de quatro tecnologias: 1) Sistema de Posicionamento Global; 2) Sensoriamento Remoto; 3) Sistema de Informações Geográficas e 4) Manejo Localizado da Cultura. Além da multidisciplinaridade, uma das grandes virtudes da

agricultura de precisão é não dispensar o acompanhamento “in situ” da lavoura, requerendo o registro do que ocorre durante o desenvolvimento das culturas. Depois do armazenamento adequado, o processamento assistido dos dados deve permitir a análise e representação (mapas e imagens) de um ou vários dos fatores de produção, para determinar causas e efeitos das variações observadas no rendimento das culturas e, desta forma, permitir a adoção de medidas corretivas com base em diagnósticos acurados.

O rendimento é um excelente indicador do desenvolvimento de uma cultura, pois o mesmo é influenciado por diversos fatores, como por exemplo: teor de potássio presente no solo, grau de acidez do solo, tipo de relevo, compactidade do solo, presença de plantas daninhas, fungos, pragas, etc.

Para obter superfícies que representam a distribuição espacial do rendimento das culturas a agricultura de precisão vem utilizando dois métodos. O primeiro utiliza amostragem aleatória do rendimento. O segundo faz uma amostragem sistemática com colhedeira equipada com receptor GPS e um dispositivo de estimativa de peso dos grãos colhidos. Esta última oferece medidas de rendimento mais precisas, porém a um custo mais elevado.

Para produzir uma representação da distribuição do rendimento de uma cultura com base em uma amostra com dados georreferenciados é necessário aplicar uma técnica de inferência. A Geoestatística é uma destas ferramentas, pois permite estimar dados em locais não amostrados levando em conta o comportamento espacial do fenômeno e minimizando o erro dessa estimativa. Dentre as técnicas geoestatísticas estão a krigagem ordinária isotrópica e anisotrópica, krigagem indicadora isotrópica e cokrigagem.

Baseado nos conceitos das técnicas geoestatísticas é possível adotar uma outra forma de utilizar dados amostrais coletados em campo, porém em um número menor do que os dados coletados pela colhedeira, podendo com isso reduzir os custos. Essa redução do

tamanho da amostra pode ser obtida com o auxílio de uma informação adicional que seja correlacionada com o rendimento, aplicando a técnica da cokrigagem. Tentando com isso obter bons resultados com uma quantidade menor de dados amostrais, conseguindo assim reduzir os custos.

Diversos trabalhos realizados afirmam que os índices de vegetação, obtidos através de análises das imagens multiespectrais de plantações, são altamente correlacionadas com a fitomassa da planta, particularmente nas bandas do verde, vermelho e infravermelho próximo. Assim, correlacionando dados de rendimento e índices de vegetação obtidos de dados das imagens multiespectrais da cultura de soja, obtidas utilizando a câmera DUNCAN TECH MS-3100 com visada inclinada, pode ser possível obter um mapa diagnóstico do rendimento da cultura.

As técnicas de inferência geoestatística são tradicionalmente utilizadas em geologia, entretanto, seus métodos podem ser aplicados em meteorologia, geofísica, engenharia florestal, ecologia, medicina, agricultura, etc.

Na realização desse trabalho foram utilizadas imagens obtidas utilizando a câmera multiespectral Duncan Tech MS-3100 com visada inclinada, com o objetivo de reduzir ainda mais os custos do levantamento.

Para obtenção dos mapas, foram realizados e comparados os resultados das interpolações utilizando os métodos geoestatísticos de krigagem ordinária isotrópica (KOI) e anisotrópica (KOA), krigagem indicadora isotrópica (KII) e cokrigagem co-localizada isotrópica (coKI).

Esta pesquisa utiliza os recursos do projeto Fapesp intitulado “Recursos não – convencionais de levantamento de dados da superfície para aquisição de informações cartográficas”, processo n. ° 1997/10956-0. Os dados foram adquiridos de um campo experimental da EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária), com recursos de

um projeto interinstitucional – UNESP e EMBRAPA e de uma plantação experimental da cooperativa de Palotina - PR. Assim, a pesquisa deve complementar o conjunto de estratégias e técnicas desenvolvidas, nesse projeto de pesquisa no ramo da agricultura de precisão.

1.2. Hipótese

Sabe-se que o rendimento da cultura é um excelente indicador desenvolvimento da mesma. Os métodos utilizados atualmente para gerar superfícies de rendimento visando diagnosticar os fatores que o influenciam são extremamente dispendiosos. Tentando minimizar os custos gerados por esses métodos é que se pretende aplicar as técnicas geoestatísticas de inferência, tais como, krigagem ordinária isotrópica e anisotrópica, krigagem indicadora isotrópica para estimar as superfícies de rendimento e verificar a eficácia de cada uma delas, tentando com isso reduzir o tamanho da amostra e reduzir os custos. Além disso, verificou-se através de trabalhos realizados anteriormente que a biomassa da cultura é altamente correlacionada com a resposta espectral das imagens de sensoriamento remoto. Assim, tal correlação permite que esses dados sejam utilizados como informações adicionais na realização do processo de cokrigagem, visando reduzir ainda mais os custos do processo produtivo sem perder a qualidade dos resultados. O esquema da figura 1.1 mostra a relação entre a fitomassa, a resposta espectral, os fatores que determinam o rendimento.

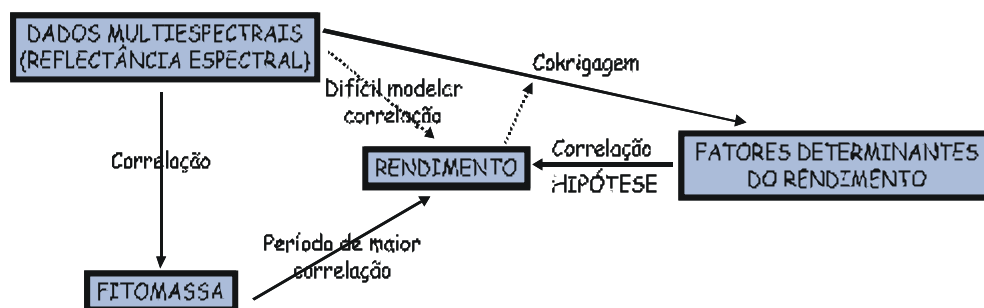


FIGURA 1.1 – RELAÇÃO ENTRE FITOMASSA, RESPOSTA ESPECTRAL E FATORES QUE DETERMINAM O RENDIMENTO
 FONTE: SARTORI, 2003

1.3. Objetivo

A presente pesquisa propõe:

- Realizar e avaliar os métodos geoestatísticos de Krigagem Ordinária Isotrópica, Krigagem Ordinária Anisotrópica e Krigagem Indicadora Isotrópica, para dois conjuntos de dados amostrais de rendimento da soja, com padrões e tamanhos diferentes;
- Avaliar a utilização de imagens multiespectrais obtidas com a câmera Duncan Tech MS-3100 com visada inclinada, na realização do processo de cokrigagem;
- Comparar os resultados obtidos pelos diversos métodos geoestatísticos utilizando o coeficiente de acurácia kappa, o qual se constitui de uma medida da exatidão global.

1.4. Justificativa

Tendo em vista a importância da agricultura no país, é necessário cada vez mais agregar vantagens aos produtos. A agricultura de precisão tem a função de monitorar o desenvolvimento da cultura utilizando as informações vindas de suas próprias variações. Com

isso é preciso buscar métodos e técnicas para reduzir custos e aumentar a rentabilidade do processo produtivo, fazendo com que a agricultura torne-se cada vez mais interessante tanto para os produtores quanto para os consumidores. Este trabalho tem como principal objetivo analisar e comparar métodos para estimar superfícies de rendimento com um número reduzido de elementos amostrais, com vistas a reduzir os custos de produção da informação. Além disso, visa também utilizar a possível correlação existente entre a biomassa da cultura e as bandas do vermelho, verde e do infravermelho próximo, para testar o método da cokrigagem utilizando dados de imagens multiespectrais, também com o objetivo de reduzir os custos do processo de obtenção de informações.

1.5. Estrutura do Trabalho

O presente trabalho foi subdividido em 8 capítulos, os quais serão brevemente resumidos nesse item.

1º Capítulo: Introdução – Traz uma apresentação do trabalho, esclarecendo a técnica de agricultura de precisão. Além disso, o primeiro capítulo traz também os objetivos do trabalho, a hipótese que orienta o mesmo e uma justificativa sobre a importância da sua realização.

2º Capítulo: Variáveis Regionalizadas – Nesse capítulo é realizada uma fundamentação teórica contemplando os principais conceitos das variáveis regionalizadas, tais como suas características e análise da variabilidade espacial.

3º Capítulo: Função Variograma – Nele estão descritos os conceitos e demonstradas as equações utilizadas para gerar os semivariogramas, assim como os modelos teóricos utilizados para ajustá-los e os parâmetros dos semivariogramas. Este capítulo também mostra o conceito de anisotropia e como modelá-la e, também, descreve o modelo linear de correção regionalização, utilizado para modelar duas ou mais variáveis (no caso da cokrigagem).

4º Capítulo: Inferências Utilizando os Métodos de Krigagem e Cokrigagem

– Os métodos de inferência por krigagem, como Krigagem Ordinária Isotrópica e anisotrópica, Krigagem Indicadora Isotrópica e Cokrigagem, como cokrigagem indicadora, ordinária padronizada e co-localizada, são descritos nesse capítulo, bem como os modelos matemáticos envolvidos em tais processos.

5º Capítulo: Comportamento Espectral da Vegetação e do Solo – O

comportamento espectral da vegetação e do solo são apresentados neste capítulo e também a função distribuição da reflectância bidirecional e os índices de vegetação.

6º Capítulo: Materiais e Métodos – Nele estão apresentados os

procedimentos e os materiais utilizados na realização dos trabalhos de campo, assim como os procedimentos realizados no processamento digital das imagens e no preparo dos dados de rendimento da soja.

7º Capítulo: Experimentos e Resultados – Os experimentos realizados com

os diversos métodos de krigagem para ambos os experimentos são descritos neste capítulo, assim como os resultados obtidos e análise dos mesmos.

8º Capítulo: Considerações Finais, Conclusões e Recomendações – Neste

capítulo serão feitas algumas considerações, descritas as conclusões sobre os experimentos realizados e por fim são feitas algumas recomendações para trabalhos futuros.

2. VARIÁVEIS REGIONALIZADAS

Uma variável regionalizada (V.R.) é uma variável distribuída no espaço e no tempo, utilizada para representar um fenômeno natural.

MATHERON (1971) apud CAMARGO (1998), desenvolveu a teoria das variáveis regionalizadas com base nos estudos realizados por Daniel G. Krige em 1951. Segundo CAMARGO (1997), essa teoria diz que uma medida pode ser vista como uma realização de uma função aleatória, ou processo aleatório, ou campo aleatório ou ainda processo estocástico. Tal teoria é a base da geoestatística e a partir dela surgiram os conceitos que levam em consideração a posição, a localização geográfica e a dependência espacial.

De acordo com STURARO (1993), uma variável pode ser considerada regionalizada, se a mesma apresentar uma distribuição no espaço, juntamente com um determinado grau de correlação espacial.

Segundo LANDIM (1998), as variáveis regionalizadas têm um comportamento espacial mostrando características intermediárias entre as variáveis verdadeiramente casuais e as totalmente determinísticas.

A continuidade espacial apresentada pelas variáveis regionalizadas é representada por funções numéricas ordinárias que assumem valores diferentes a cada ponto no espaço, descrevendo um fenômeno natural. A continuidade espacial se dá pelo fato dessas variáveis apresentarem valores similares em dois pontos próximos (vizinhos) e valores menos similares à medida que a distância entre eles aumenta. Além disso, as variáveis regionalizadas apresentam alguns atributos como: localização, anisotropia e transição dos quais o segundo é mais bem discutido nos próximos itens deste trabalho.

De acordo com BURROUGH (1987), a variação espacial de uma variável regionalizada pode ser expressa pela soma de três componentes: uma componente estrutural,

que está associada a um valor médio constante ou a uma tendência constante; uma componente aleatória, espacialmente correlacionada e um ruído aleatório ou um erro residual.

Sendo x , uma posição em uma, duas ou três dimensões, o valor da variável Z na posição x , é dada pela equação (2.1) e suas componentes são mostradas graficamente pela figura (2.1):

$$Z(x) = m(x) + \varepsilon'(x) + \varepsilon'' \quad (2.1)$$

tendo:

- $m(x)$ como a função determinística (função que modela a superfície) que descreve a componente estrutural de Z em x ;
- $\varepsilon'(x)$ como o termo estocástico, o qual varia localmente e depende espacialmente de $m(x)$;
- ε'' como o ruído aleatório não correlacionado, tendo distribuição normal com média zero e variância σ^2 .

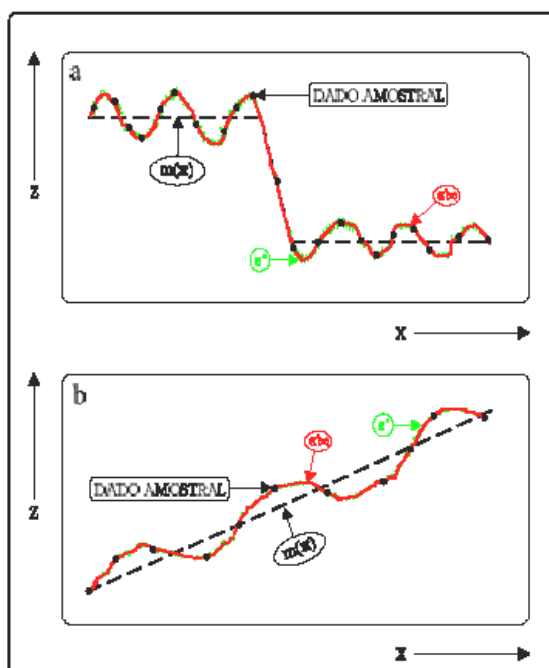


FIGURA 2.1 (A) E (B) - COMPONENTES PRINCIPAIS DA VARIAÇÃO ESPACIAL

Fonte: Burrough (1985) apud Camargo (1998)

A figura 2.1 (a) apresenta uma componente determinística que possui um comportamento regular (diferença entre os níveis médios). A figura 2.1 (b) apresenta a componente determinística com uma tendência constante.

2.1. Características das Variáveis Regionalizadas

De acordo com CAMARGO (1997), as variáveis regionalizadas possuem as seguintes características:

- *Localização*: uma Variável Aleatória (V.A.), é definida por um valor, o qual está associado ao tamanho, orientação e forma da amostra, tal característica é denominada *suporte geométrico*, o qual pode não só se referir a volumes como também à áreas e linhas. Em suma, a teoria das variáveis regionalizadas leva em consideração a geometria da distribuição espacial dos elementos amostrais, ao contrário da estatística clássica, na qual a forma, o tamanho e a orientação não são considerados.
- *Anisotropia*: algumas das variáveis regionalizadas apresentam um comportamento anisotrópico, ou seja, apresentam variações graduais em uma determinada direção e rápida ou irregulares em outra. A anisotropia depende das características do fenômeno estudado, por exemplo, o desenvolvimento de plantas daninhas em uma plantação pode apresentar uma continuidade maior na direção das linhas do que na direção perpendicular; ou também a distribuição de poluentes no ar pode ser mais contínua na direção favorável ao vento do que na direção perpendicular a essa mesma direção.
- *Continuidade*: dependendo do fenômeno que está sendo estudado, a variação espacial de uma V.R. pode ser grande ou pequena. A continuidade espacial é exemplificada em Camargo (1997) com maiores detalhes ,porém aqui também será tratada com maior atenção.

2.2. Análise da Continuidade ou Variabilidade Espacial

Um das principais características das V. R., constitui-se na sua continuidade ou variabilidade espacial, a qual constitui a base da geoestatística.

A continuidade espacial existe na maioria dos conjuntos de dados de ciências da terra. De acordo com ISAACS & SRIVASTAVA (1989), dois dados provavelmente possuem valores mais similares se estão próximos do que dados que estão em locais mais distantes.

Segundo STURARO (1993), a forma de avaliação da continuidade espacial está fundamentada nos princípios de regressão linear, empregados na estatística clássica, para analisar a dependência entre duas variáveis.

ISAACS & SRIVASTAVA (1989), dizem que as mesmas ferramentas utilizadas para descrever a relação entre duas variáveis podem ser utilizadas para descrever a relação entre uma variável e a mesma variável em locais próximos. Em geoestatística a análise é feita para avaliar a dependência entre uma variável com ela mesma separadas com um vetor h .

Existem diversas maneiras de se obter informações quantitativas sobre a dependência espacial entre variáveis como, por exemplo, o coeficiente de correlação, o coeficiente de covariância e o coeficiente de variograma. O primeiro tem uma relação inversamente proporcional ao vetor h da distância, pois quanto maior a distância menor será o coeficiente de correlação. O mesmo ocorre com o segundo, o coeficiente de covariância que, quanto maior a distância menor, é o seu valor. No entanto, para o terceiro, coeficiente de variograma, a relação é diretamente proporcional, quanto maior a distância maior o valor do coeficiente. Isto ocorre, porque esse coeficiente descreve o quanto as variáveis são diferentes entre si. A função variograma será melhor descrita no próximo capítulo, quanto aos outros

índices, uma explicação detalhada pode ser encontrada em ISAACS & SRIVASTAVA (1989).

3. FUNÇÃO VARIOGRAMA

A função variograma é derivada do momento de inércia, que é dado pela equação (3.1):

$$\text{Momento de inércia} = \frac{1}{2n} \sum_{i=1}^n (x_i - y_i)^2 \quad (3.1)$$

Ou seja, a metade da média multiplicada pelo quadrado da diferença de cada ponto na distância h . O fator $\frac{1}{2}$ é consequência do fato de que o interesse está voltado para a distância perpendicular dos pontos da linha de 45° e isso leva alguns estatísticos a denominarem de semivariograma. O gráfico mostrado na figura 3.1, demonstra a interpretação do variograma a partir do momento de inércia.

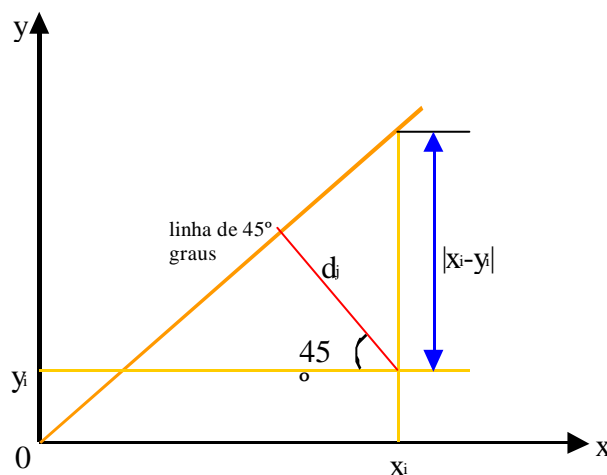


FIGURA 3.1 – DISPERSÃO DE UMA VARIÁVEL $V(X)$ PARA UMA DETERMINADA DISTÂNCIA
Fonte: Adaptada de Camargo (1998)

Derivando a função variograma da equação (3.1) de acordo com o gráfico da figura 3.1 tem-se que a função variograma, $\gamma(h)$, é a metade da média multiplicada pela diferença entre os pares de valores (ISAAKS & SRIVASTAVA, 1989), ou seja:

$$\gamma(\mathbf{h}) = \text{variograma} = \frac{1}{2N(\mathbf{h})} \sum_{(i,j) | h_{ij} = h} (v_i - v_j)^2 \quad (3.2)$$

onde:

- $N(\mathbf{h})$: números de pares de pontos que estão à uma determinada distância h ;
- v_i e v_j : são as amostras nas localizações i e j .

Segundo ISAACS & SRIVASTAVA (1989), o valor de $\gamma(\mathbf{h})$ não é afetado quando os índices i e j são invertidos. Invertendo-se os índices da equação (3.2) tem-se a equação (3.3):

$$\gamma(\mathbf{h}) = \frac{1}{2N(\mathbf{h})} \sum_{(j,i) | h_{ij} = h} (v_j - v_i)^2 \quad (3.3)$$

Em vez de somar todos os valores dos pares (j, i) que são separados pelo vetor \mathbf{h} , pode-se somar todos os pares (i, j) que são separados pelo vetor $-\mathbf{h}$.

Assim, conclui-se que $\gamma(\mathbf{h}) = \gamma(-\mathbf{h})$. Isto implica que o variograma calculado para um vetor \mathbf{h} em um sentido particular é idêntico ao calculado no sentido oposto.

Os conceitos de variograma descritos até o momento explicam a continuidade espacial de uma variável, sendo que estes mesmos conceitos podem ser estendidos para duas ou mais variáveis, ou seja, em vez de trabalhar com pares da mesma variável em locais diferentes, trabalha-se com duas ou mais variáveis em localizações diferentes, definindo os denominados variogramas cruzados. Estendendo a equação (3.3) para mais variáveis, obtém-se a equação (3.4).

$$\gamma_{vu}(h) = \frac{1}{2N(h)} \sum_{(j,i)} (V_{(i)} - V_{(j)})(U_{(i)} - U_{(j)}) \quad (3.4)$$

onde:

- $N(h)$: números de pares de pontos que estão à uma determinada distância h ;
- V_i e V_j : são as amostras da variável V nas localizações i e j ;
- U_i e U_j : são as amostras da variável U nas localizações i e j .

3.1. Parâmetros do Semivariograma

Como já foi colocado anteriormente, o variograma ou semivariograma descreve a continuidade espacial dos dados, que definem as variáveis regionalizadas. Na figura 3.2 é mostrado um variograma ideal usado para representar o que se espera de dados de campo, ou seja, que as diferenças entre as variáveis separadas por um vetor h , que é à distância entre suas localizações, diminua à medida que h também diminua. Na geoestatística, as observações mais próximas são mais semelhantes que observações mais distantes. Assim, o valor da função variograma $\gamma(h)$ aumente quando a distância h aumentar, implicando que quanto maior o valor da função variograma maiores diferenças serão encontradas entre as observações.

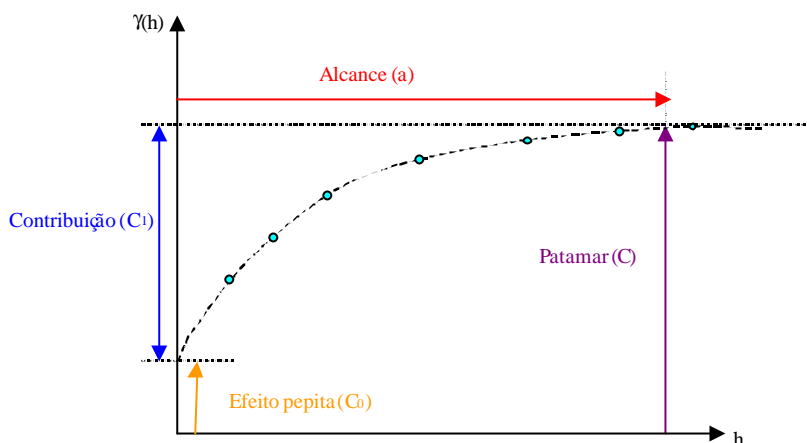


FIGURA 3.2 – EXEMPLO DE SEMIVARIOGRAMA EXPERIMENTAL

Fonte: Adaptada de Camargo (1998)

Na figura 3.2 pode-se identificar os seguintes parâmetros do semivariograma:

- *Alcance (a) ou Amplitude Variográfica* - a medida em que a distância h é incrementada, a variabilidade aumenta até atingir um certo nível, se estabilizando a partir daí. A distância na qual o variograma atinge este nível é denominada *range* ou amplitude variográfica ou ainda alcance (a).
- *Patamar (C)* - é o nível onde o variograma se estabiliza. A partir deste ponto, considera-se que não haja mais dependência entre as observações. Teoricamente esse patamar, também denominado *sill*, deve ser igual a variância estimada *a priori*, isto é, a variância populacional.
- *Efeito Pepita (C_0)* - parâmetro que revela a descontinuidade do semivariograma. Teoricamente $\gamma_0(0)=0$, ou seja, o valor do semivariograma para a distância $h = 0$ deve a ser 0 (zero), porém, na prática, isso não ocorre. Quando a distância h se aproxima de 0 (zero), $\gamma(h)$ se aproxima de um valor positivo, que é o C_0 , o qual revela a descontinuidade do semivariograma para distâncias muito próximas de 0, ou seja, para distâncias menores que a menor distância entre as observações.

- *Contribuição (C_1):* é a diferença entre o patamar (C) e o efeito pepita (C_0), ou seja, quanto de informação os pares de pontos, dentro de uma determinada distância h , estão fornecendo.

3.2. Modelando os Semivariogramas Experimentais

O gráfico do semivariograma experimental, $\gamma(h)$, é construído através de um conjunto de valores obtidos pela equação (3.3), a partir dos quais deve ser ajustada uma função. O modelo ajustado a esse gráfico deve representar a tendência da função semivariograma $\gamma(h)$ em relação a uma certa distância h , para que as estimativas obtidas pelo processo de krigagem e/ou cokrigagem sejam mais exatas.

O processo de ajuste do semivariograma é interativo, ou seja, o intérprete define valores para os parâmetros descritos no item anterior, visando representar melhor a continuidade espacial.

As semivariâncias devem ser calculadas para alguns valores de h , ou seja, para distâncias e direções diferentes, encontrando assim os eixos de anisotropia, assunto que também é tratado, no item 3.4 deste capítulo.

Os modelos teóricos utilizados para representar a continuidade espacial devem obedecer a algumas restrições, pois os valores obtidos por essas funções serão utilizados pela matriz de krigagem e/ou cokrigagem. Primeiramente são apresentadas algumas restrições que devem ser respeitadas pelos modelos, depois então são apresentados os modelos teóricos “básicos” que respeitam essas restrições. Estes modelos básicos são considerados isotrópicos (ISAAKS & SRIVASTAVA, 1989).

3.3. Restrições para o Modelo de Semivariograma

A necessidade de se modelar vem do fato dos valores dos variogramas experimentais serem necessários para algumas distâncias e direções para as quais não são conhecidos os valores dos variogramas.

Pode-se considerar uma interpolação entre os valores dos semivariogramas direcionais experimentais conhecidos. Com a interpolação são fornecidos números, e também um problema: a solução do sistema de krigagem ordinária utilizando esses números pode não existir ou se existir, pode não ser única. Isto acontece por que os valores utilizados para construir a matriz de krigagem não são apropriados para que esta seja positiva definida.

Para garantir que as equações de krigagem ordinária tenham uma, e somente uma, solução consistente, deve-se assegurar que a matriz de krigagem, dada na equação (3.5) satisfaça a condição de positiva definida. Isto é, assegurar que seu determinante seja maior que 0 (zero) e que todos os elementos da sua diagonal principal sejam positivos.

$$K = \begin{bmatrix} \tilde{C}_{00} & \tilde{C}_{01} & \dots & \tilde{C}_{0n} \\ \tilde{C}_{10} & \tilde{C}_{11} & \dots & \tilde{C}_{1n} \\ \dots & \dots & \dots & \dots \\ \tilde{C}_{n0} & \tilde{C}_{n1} & \dots & \tilde{C}_{nn} \end{bmatrix} \quad (3.5)$$

Sendo os \tilde{C}_{ij} as covariâncias entre os pares de pontos.

A condição necessária para que a matriz K , dada na equação (3.5), seja positiva definida é dada pela equação (3.6):

$$w^t K w = \sum_{i=0}^n \sum_{j=0}^n w_i w_j \tilde{C}_{ij} > 0 \quad (3.6)$$

onde: w_i e w_j são os pesos atribuídos às amostras.

3.3.1. Modelos de Variogramas Positivos Definidos

Uma forma de garantir a condição de positiva definida é utilizar funções que são conhecidas como positivas definidas. Pode parecer uma idéia restrita num primeiro momento, porém, essas funções podem ser combinadas e ainda assim serão positivas definidas. A seguir são apresentados alguns modelos “básicos” que satisfazem a condição de positivo definido os quais, provavelmente, fornecerão um ajuste satisfatório a todos os variogramas experimentais encontrados na prática. No caso de variogramas experimentais mais complexos podem ser utilizadas combinações dos variogramas básicos, pois muitas vezes o esforço de se criar um novo modelo que obedeça a condição imposta não se justifica.

Segundo ISAACS & SRIVASTAVA (1989), estes modelos são simples, isotrópicos, ou seja, independem da direção. Os modelos podem ser divididos em dois tipos: aqueles que atingem um patamar ou *sill* e aqueles que não atingem um patamar. No primeiro caso, os modelos são denominados de modelos de transição. No segundo tipo, os modelos não atingem um patamar, mas continuam aumentando à medida que em que a distância aumenta.

São apresentados a seguir os modelos de semivariogramas básicos:

Modelo de Efeito Pepita: na literatura esse efeito, freqüentemente, aparece como uma constante C_0 . Alguns semivariogramas experimentais possuem uma descontinuidade na origem, denominado efeito epita, como já foi descrito anteriormente. Essa descontinuidade pode ser modelada utilizando um modelo de transição positivo definido, dado pela equação (3.7):

$$g_0(h) = \begin{cases} 0 & \text{se } h = 0 \\ 1 & \text{para outros} \end{cases} \quad (3.7)$$

A notação para o efeito pepita é $\omega_0\gamma_0(h)$, onde ω_0 é a altura da descontinuidade na origem e $\gamma_0(h)$ é o modelo básico padronizado dado pela equação (3.7).

Modelo Esférico: é o modelo mais comumente utilizado, sendo que seu modelo padronizado é dado pela equação (3.8) e mostrado na figura (3.3):

$$\mathbf{g}_{\text{esférico}}(h) = \begin{cases} 1.5\frac{h}{a} - 0.5\left(\frac{h}{a}\right)^3 & \text{se } h \leq a \\ 1 & \text{outros} \end{cases} \quad (3.8)$$




FIGURA 3.3 – MODELO TEÓRICO DE TRANSIÇÃO DO TIPO ESFÉRICO

Modelo Exponencial: é o modelo comumente usado, o qual possui a equação padronizada dada em (3.9) e é mostrado na figura (3.4):

$$\mathbf{g}_{\text{exponencial}}(h) = 1 - \exp\left(-\frac{3h}{a}\right) \quad (3.9)$$




FIGURA 3.4 – MODELO TEÓRICO DE TRANSIÇÃO DO TIPO EXPONENCIAL

Modelo Gaussiano: modelo de transição frequentemente usado para representar fenômenos extremamente contínuos (Figura 3.5). Sua equação é dada em (3.10):




FIGURA 3.5 – MODELO TEÓRICO DE TRANSIÇÃO DO TIPO GAUSSIANO

$$\mathbf{g}_{\text{gaussiano}}(h) = 1 - \exp\left(-\frac{3h^2}{a^2}\right) \quad (3.10)$$

Modelo Linear: modelo não atinge um patamar, mas aumenta na medida em que a distância h aumenta. Sua equação é dada por (3.11):

$$\mathbf{g}_{\text{linear}}(h) = |h| \quad (3.11)$$

3.3.2. Modelos em Uma Direção

No item anterior foram descritos os modelos básicos que ajustam os variogramas direcionais experimentais. De acordo com ISAACS & SRIVASTAVA (1989), para casos isotrópicos, os variogramas direcionais experimentais dependem somente da distância h e não da direção, e são os mesmos para qualquer direção. Nesse caso, pode ser modelado o variograma direcional experimental omnidirecional, o qual é preferível em casos de fenômenos comportados mais fáceis de modelar.

Embora algumas vezes seja possível modelar um semivariograma experimental satisfatoriamente usando apenas um dos modelos básicos, freqüentemente, é necessário utilizar uma combinação desses modelos para obter um ajuste melhor. Quando isso ocorre, é necessário recordar da condição de positivo definido dos modelos básicos. Uma combinação linear dos modelos de variogramas positivos definidos, com coeficientes positivos definidos, é também um modelo positivo definido.

A combinação linear de dois modelos é apresentada na equação (3.12):

$$\mathbf{g}(h) = \sum_{i=1}^n w_i \mathbf{g}_i(h) \quad (3.12)$$

onde:

w_i – peso atribuído a amostra no ponto i ;

$\mathbf{g}_i(h)$ – valor do semivariograma para o ponto i a uma determinada distância h .

A combinação linear dos modelos básicos é denominada de “estrutura aninhada”, na qual cada um dos termos da combinação linear da equação (3.12) representa um

modelo básico da estrutura aninhada. O termo $|w_i|$ assegura a condição de positivo definido do modelo, como já foi mostrado anteriormente.

Para ajustar uma combinação linear, ou seja, uma estrutura aninhada de modelos de variogramas básicos para um variograma direcional experimental, é necessário definir uma descrição de forma geral. Se o variograma experimental atinge um patamar, o melhor é utilizar um dos modelos de transição, se não o modelo linear pode ser o melhor.

Não existe limite de modelos para a combinação linear mostrada na equação (3.12) e nem uma regra para a combinação desses modelos. Pode haver casos em que sejam necessários vários modelos de comportamentos bem diferentes para ajustar corretamente um variograma experimental adequadamente. Por exemplo, se o variograma experimental não atinge um patamar e apresenta um comportamento parabólico próximo à origem, uma combinação linear do modelo Gaussiano e do modelo linear pode fornecer um ajuste satisfatório. Um truque para saber, com maior segurança, qual o modelo ideal para ser utilizado é observar o comportamento do variograma experimental próximo à origem: se o variograma tem um comportamento parabólico próximo à origem, o melhor modelo é o Gaussiano; no caso de apresentar um comportamento linear próximo à origem, então os modelos esféricos ou exponenciais se ajustam melhor. Isso ocorre pois as observações que possuem mais informações sobre o comportamento espacial do fenômeno estão próximas à origem, isto é, tem um valor de γ baixo. Então, um bom ajuste do modelo para esses pontos é garantia que o fenômeno será bem explicado.

3.4. Anisotropia

Segundo ISAACS & SRIVASTAVA (1989), em alguns conjuntos de dados os valores dos dados são mais contínuos ao longo de certas direções do que em outras, sendo essa variação da continuidade espacial denominada de anisotropia. Existem diversas formas de se identificar os eixos de maior e menor continuidade espacial, ou seja, os eixos de anisotropia.

Um das formas de revelar rapidamente a anisotropia direcional é construir um mapa de contorno dos variogramas experimentais de superfície. Os programas que geram os mapas de superfície geralmente requerem os dados em um sistema de coordenadas retangulares, sendo esse tipo de mapa simples de se construir, se as tolerâncias h estiverem no sistema de coordenadas retangulares, como mostra a figura (3.6).




FIGURA 3.6 – AGRUPAMENTO BIDIMENSIONAL DOS DADOS PARA FORMAR UM VARIOGRAMA DE SUPERFÍCIE
Adaptado de Isaacs & Srivastava (1989)

Calculando os valores dos variogramas para os pares dos pontos separados por um vetor $h = (h_x, h_y)$, são agrupados todos os pares cuja separação na direção x seja $h_x \pm \Delta_x$ e a separação na direção y seja $h_y \pm \Delta_y$. A figura (3.7) mostra um variograma de superfície construído como descrito anteriormente. Através desse mapa são traçadas as isolinhas, ou seja, as curvas de igual valor, obtendo assim o mapa de contorno.

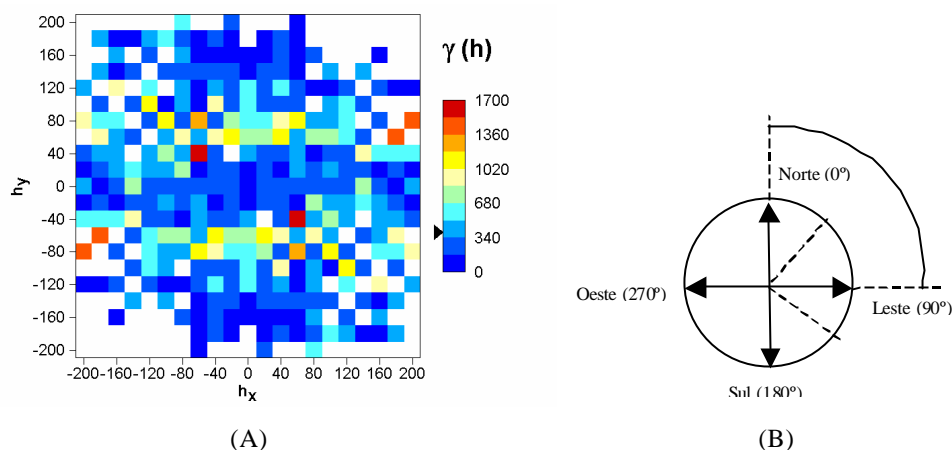


FIGURA 3.7 – VARIOGRAMA DE SUPERFÍCIE UTILIZADO NA CONSTRUÇÃO DO MAPA DE CONTOURNO

Mesmo sem desenhar as isolinhas, é possível perceber uma anisotropia na direção 0° leste-oeste ou vice-versa. Apesar da simplicidade os mapas de contorno não são muito utilizados na prática.

Outra forma de se encontrar os eixos de anisotropia é calculando os variogramas experimentais para diversas direções, as quais ofereçam uma interpretação razoável. Para cada uma das direções, encontram-se as distâncias onde os variogramas atingem um certo valor de patamar (alcance), por exemplo, 80 m. Com os valores das distâncias encontrados, constrói-se uma “rosa de diagramas”, como a mostrada na figura (3.8).




FIGURA 3.8 – DIAGRAMA DE ROSA PARA SEIS DIREÇÕES
Adaptada de Isaaks & Srivastava (1989)

3.4.1. Modelos de Anisotropia

Muitas vezes, os variogramas direcionais experimentais revelam maiores mudanças no alcance e no patamar com a mudança de direção. Segundo ISAAKS & SRIVASTAVA (1989), existem dois tipos de anisotropia: a *anisotropia geométrica* e a *anisotropia zonal*. Na primeira, o variograma direcional experimental apresenta uma variação no alcance, enquanto o patamar permanece constante. Já no caso da anisotropia zonal ocorre o inverso, o patamar varia enquanto o alcance permanece constante. Na figura (3.9 a) é mostrado um exemplo de anisotropia geométrica e na figura (3.9 b), um exemplo de anisotropia geométrica e zonal ao mesmo tempo.




FIGURA 3.9 – EXEMPLO DE ANISOTROPIA: (A) GEOMÉTRICA, (B) MISTURA DE ANISOTROPIA ZONAL E GEOMÉTRICA
Fonte: Isaaks & Srivastava (1989)

Um conjunto de variogramas direcionais mostram a mudança de alcance e patamar com as mudanças de direção, um deles identifica o eixo de anisotropia. Isto é feito para identificar o alcance máximo e mínimo, no caso da anisotropia geométrica e o patamar máximo e mínimo, no caso da anisotropia zonal.

Após a definição dos eixos da anisotropia, a próxima etapa é o estabelecimento de um único modelo que descreva como o variograma muda de acordo com a distância e a direção, especificando um modelo único para todas as direções da anisotropia, o qual é denominado de *modelo aninhado*. Num primeiro momento trabalhar-se-á apenas com o

sistema definido pelos eixos de anisotropia. Uma vez visto como construir um modelo completo neste sistema de coordenadas será, então, definido como trabalhar no sistema de coordenadas dos dados.

Um método simples de combinar os vários modelos em um único consistente para todas as direções, é definir uma transformação que reduza todos os variogramas para um modelo comum com alcance padronizado igual a 1. O truque é transformar a distância de separação, de modo que o modelo padronizado forneça um valor de variograma que seja idêntico para qualquer modelo direcional, para a mesma distância de separação.

Por exemplo, dois modelos transicionais de variografia com o mesmo patamar são mostrados na figura 3.10. Um possui o alcance igual a 1, enquanto o outro tem um alcance a .




FIGURA 3.10 – MODELO DIRECIONAL DE VARIOGRAMA COM O MESMO PATAMAR
Adaptada de Isaaks & Srivastava (1989)

De acordo com ISAAKS & SRIVASTAVA (1989), se o modelo for calculado com o alcance 1 em uma distância de h/a o patamar terá o mesmo valor que aquele calculado com alcance a em uma distância h . Com isso, obtém-se o modelo reduzido com alcance 1 a uma separação de h/a . Tal equivalência pode ser expressa pela equação (3.13).

$$\mathbf{g}_1\left(\frac{h}{a}\right) = \mathbf{g}_a(h) \quad (3.13)$$

ou, sendo $h_1 = h/a$, tem-se que:

$$\mathbf{g}_1(h_1) = \mathbf{g}_a(h) \quad (3.14)$$

Assim, qualquer modelo direcional com alcance a pode ser reduzido para um modelo padronizado com alcance de 1, substituindo, simplesmente a distância h pela distância reduzida h/a .

Este conceito de modelo equivalente pode ser expandido para duas ou três dimensões.

Para o caso de duas dimensões, considerando que a_x é o alcance na direção x e a_y é o alcance na direção y , o modelo variograma anisotrópico será expresso pela equação (3.15).

$$\mathbf{g}(h) = \mathbf{g}(h_x, h_y) = \mathbf{g}_1(h_1) \quad (3.15)$$

e a distância reduzida h_1 é dada por (3.16):

$$h_1 = \sqrt{\left(\frac{h_x}{a_x}\right)^2 + \left(\frac{h_y}{a_y}\right)^2} \quad (3.16)$$

onde h_x é a componente h ao longo do eixo x e h_y é a componente h ao longo de y .

O modelo de variograma anisotrópico para três dimensões é obtido da mesma forma, com os alcances a_x , a_y , a_z e é dado pela equação (3.17):

$$\mathbf{g}(h) = \mathbf{g}(h_x, h_y, h_z) = \mathbf{g}_1(h_1) \quad (3.17)$$

e a distância reduzida h_1 é expressa por:

$$h_1 = \sqrt{\left(\frac{h_x}{a_x}\right)^2 + \left(\frac{h_y}{a_y}\right)^2 + \left(\frac{h_z}{a_z}\right)^2} \quad (3.18)$$

Este método também pode ser aplicado a modelos de variograma que não atingem um patamar.

3.4.1.1. Anisotropia Geométrica para uma estrutura

Como já foi citada anteriormente, a anisotropia geométrica se caracteriza por variogramas direcionais experimentais que possuem o mesmo patamar, porém com diferentes alcances.

Observando a figura 3.11, nota-se três modelos de variograma direcional ao longo de três eixos perpendiculares de anisotropia e também nota-se que o efeito pepita não existe. Cada um deles é formado por apenas uma estrutura, e todos possuem o mesmo patamar, no entanto com alcances diferentes.




FIGURA 3.11 – MODELOS DE VARIOGRAMAS DIRECIONAIS AO LONGO DE TRÊS EIXOS DE ANISOTROPIA
Adaptada de Isaaks & Srivastava (1989)

O modelo tridimensional equivalente é dado pela equação (3.19):

$$\mathbf{g}(h) = |\mathbf{w}_1| \mathbf{g}_1(h_1) \quad (3.19)$$

onde a distância reduzida é:

$$h_1 = \sqrt{\left(\frac{h_x}{a_x}\right)^2 + \left(\frac{h_y}{a_y}\right)^2 + \left(\frac{h_z}{a_z}\right)^2} \quad (3.20)$$

Na equação (3.17), $\gamma_1(h_1)$ é o modelo equivalente com o alcance padronizado de 1 e w_1 é o peso dado para que o semivariograma seja positivo definido, como foi descrito na seção 3.3.1. Para cada estrutura aninhada, os modelos direcionais devem ser todos do mesmo tipo. Isto é, o modelo direcional deve ser esférico, exponencial ou algum outro que seja adequado para todas as estruturas aninhadas, todavia eles podem diferir de uma estrutura aninhada para outra (ISAAKS & SRIVASTAVA, 1989).

3.4.1.2. Anisotropia Geométrica para efeito pepita e duas estruturas

Um problema que geralmente é encontrado na prática é o fato de um modelo possuir mais que uma estrutura, como o exemplo dado em ISAAKS & SRIVASTAVA (1989), mostrado na figura 3.12.




FIGURA 3.12 – MODELOS QUE APRESENTAM MAIS DE UMA ESTRUTURA
Adaptada de Isaaks & Srivastava (1989)

Cada um dos modelos mostrados na figura 3.12 é formado de três estruturas, a primeira é o efeito pepita, e as outras duas estruturas de transição adicionais. O efeito pepita é considerado isotrópico, enquanto que as outras duas

estruturas são isotrópicas no plano x e y, mas apresentam uma anisotropia entre o plano x e y e a direção z.

Como o efeito pepita é isotrópico, ele pode ser modelado diretamente pela equação (3.21).

$$\mathbf{g}(h) = w_0 \mathbf{g}_0(h), \quad (3.21)$$

onde $\gamma_0(h)$ é definido pela equação (3.22):

$$\mathbf{g}_0(h) = \begin{cases} 0 & \text{se } h = 0 \\ 1 & \text{para outras} \end{cases} \quad (3.22)$$

A segunda estrutura é identificada na figura 3.12 pelos alcances $a_{x,1}$, $a_{y,1}$, $a_{z,1}$ e o coeficiente w_1 . Como já dito, ela é isotrópica no plano x, y e apresenta uma anisotropia entre este plano e a direção z. O modelo isotrópico equivalente é dado pela equação (3.23).

$$\mathbf{g}(h) = |w_1| \mathbf{g}_1(h_1) \quad (3.23)$$

e a distância reduzida é dada por (3.24):

$$h_1 = \sqrt{\left(\frac{h_x}{a_{x,1}}\right)^2 + \left(\frac{h_y}{a_{y,1}}\right)^2 + \left(\frac{h_z}{a_{z,1}}\right)^2} \quad (3.24)$$

Finalmente, a última estrutura é caracterizada pelos alcances $a_{x,2}$, $a_{y,2}$, $a_{z,2}$ e pelo coeficiente w_2 , na equação (3.25):

$$\mathbf{g}_2(h) = |w_2| \mathbf{g}_2(h_2) \quad (3.25)$$

analogamente a equação (3.24), a distância reduzida é dada por (3.26):

$$h_1 = \sqrt{\left(\frac{h_x}{a_{x,2}}\right)^2 + \left(\frac{h_y}{a_{y,2}}\right)^2 + \left(\frac{h_z}{a_{z,2}}\right)^2} \quad (3.26)$$

O modelo tridimensional completo anisotrópico é dado pela equação (3.27), resulta da combinação de todos os modelos isotrópicos equivalentes citados anteriormente:

$$\mathbf{g}(h) = \sum_{i=1}^n |w_i| \mathbf{g}_i(h) \Rightarrow \mathbf{g}(h) = w_0 \mathbf{g}_0(h) + w_1 \mathbf{g}_1(h_1) + w_2 \mathbf{g}_2(h_2) \quad (3.27)$$

3.4.1.3. Anisotropia Zonal e Geométrica

A anisotropia zonal se caracteriza por apresentar diferentes patamares em diferentes direções, enquanto o alcance permanece o mesmo. Na prática, esse caso puro raramente acontece, o mais freqüente é encontrar uma mistura de anisotropia geométrica e zonal.

Na figura 3.9 do item 3.4.1 é mostrada uma vista perspectiva da anisotropia zonal e geométrica, na qual ambos, patamar e alcance mudam com a direção.

A figura 3.13 mostra os variogramas direcionais e suas estruturas para os dois tipos de anisotropia, zonal e geométrica.




FIGURA 3.13 – MODELO VARIOGRAMA DIRECIONAL COM ANISOTROPIA ZONAL E GEOMÉTRICA

Adaptada de Isaaks & Srivastava (1989)

No exemplo dado por ISAAKS & SRIVASTAVA (1989), na figura 3.13, observa-se que os modelos ao longo dos eixos x e y possuem o mesmo patamar, com coeficiente w_1 , mas com diferentes alcances, assim eles podem ser modelados como anisotropia geométrica, formando a primeira estrutura. Porém, o modelo direcional ao longo do eixo z mostra alcance e patamar diferentes, podendo ser modelado como anisotropia zonal, o que indica a mistura da anisotropia geométrica e zonal. Cada modelo direcional consiste de uma estrutura.

Para calcular o modelo equivalente, a primeira estrutura será um modelo isotrópico com um patamar w_1 e alcance de 1, usando a equação (3.20) e a distância reduzida h_1 pela equação (3.21).

Já a segunda estrutura tem o patamar igual a w_2 e existe somente em uma direção. A componente zonal é modelada usando um variograma direcional na direção z :

$$\mathbf{g}(h) = w_2 \mathbf{g}_1(h_2) \quad (3.28)$$

e a distância reduzida h_2 é:

$$h_2 = \frac{h_z}{a_z} \quad (3.29)$$

O modelo completo é dado pela combinação das duas estruturas:

$$\mathbf{g}(h) = w_1 \mathbf{g}_1(h) + w_2 \mathbf{g}_1(h_2) \quad (3.30)$$

O método para reduzir modelos de variogramas direcionais para um isotrópico com alcance padronizado de 1, pode ser escrito matricialmente. A notação de matriz é dada a seguir:

$$h_n = Th \quad (3.31)$$

onde h_n é o vetor das distâncias reduzidas para as n estruturas aninhadas e T é a matriz inversa dos alcances dos eixos de anisotropia dada por:

$$T = \begin{bmatrix} \frac{1}{a_x} & 0 & 0 \\ 0 & \frac{1}{a_y} & 0 \\ 0 & 0 & \frac{1}{a_z} \end{bmatrix} \quad (3.32)$$

Então o vetor h_1 é dado por:

$$h_1 = \begin{bmatrix} \frac{1}{a_x} & 0 & 0 \\ 0 & \frac{1}{a_y} & 0 \\ 0 & 0 & \frac{1}{a_z} \end{bmatrix} \begin{bmatrix} h_x \\ h_y \\ h_z \end{bmatrix} \quad (3.33)$$

O modelo deve ser calculado para várias distâncias para garantir o variograma correto em cada caso.

Agora será considerado os casos onde os eixos de anisotropia não coincidem com os eixos das coordenadas dos dados.

De acordo com ISAAKS & SRIVASTAVA (1989), a orientação do eixo da anisotropia é controlada por algum fato físico inerente no fenômeno representado pelos dados, enquanto a orientação do sistema de coordenadas dos dados freqüentemente é arbitrária.

Os métodos descritos até o momento fornecem modelos de variogramas que podem ser calculados para qualquer distância e direção, dadas no sistema de coordenadas coincidentes com os eixos da anisotropia. Dadas as componentes (h_x, h_y, h_z) coincidentes com o eixo de anisotropia, pode-se calcular os modelos isotrópicos para alcances padronizados. Porém, quando os eixos de anisotropia não coincidem com o sistema de coordenadas dos dados é necessário realizar uma transformação para que eles se tornem coincidentes e o método da distância reduzida possa ser utilizado.

Existem vários métodos para realizar essa transformação, porém, neste trabalho apenas um será apresentado. Apesar de não ser o único, é o mais direto e mais fácil de ser aplicado.

Nesse método, é utilizada uma matriz R para realizar a transformação, como segue:


$$h' = Rh \quad (3.34)$$

onde h é o vetor de coordenadas no sistema de coordenadas dos dados, h' é o mesmo vetor transformado para o sistema de coordenadas anisotrópico e R a matriz de rotações.

A matriz R é obtida a partir da definição de dois ângulos de rotação, utilizando algumas convenções da trigonometria, como mostrado a seguir:

$$R = \begin{bmatrix} \cos(\mathbf{a})\cos(\mathbf{f}) & \sin(\mathbf{a})\cos(\mathbf{f}) & \sin(\mathbf{f}) \\ -\sin(\mathbf{a}) & \cos(\mathbf{a}) & 0 \\ -\cos(\mathbf{a})\sin(\mathbf{f}) & -\sin(\mathbf{a})\sin(\mathbf{f}) & \cos(\mathbf{f}) \end{bmatrix} \quad (3.35)$$

Para entender melhor o que acontece quando a transformação é aplicada são mostrados nas figura 3.14 dois gráficos ilustrando as rotações realizadas.






FIGURA 3.14 – ROTAÇÕES REALIZADAS NOS EIXOS DE ANISOTROPIA.
Adaptada de Isaaks & Srivastava.

3.5. Modelo Linear de Corregionalização

O modelo linear de corregionalização permite modelar auto-variogramas e variogramas cruzados para duas ou mais variáveis, (ISAAKS & SRIVASTAVA, 1989). Os auto-variogramas caracterizam cada variável separadamente e os variogramas - cruzados caracterizam pares de variáveis. Considerando duas variáveis U e V , seus modelos de auto-variogramas e variogramas cruzados devem ser construídos usando os mesmos modelos básicos descritos anteriormente, como segue:

$$\begin{aligned}
 \mathbf{g}_U(h) &= u_0 \mathbf{g}_0(h) + u_1 \mathbf{g}_1(h) + \dots + u_n \mathbf{g}_n(h) \\
 \mathbf{g}_V(h) &= v_0 \mathbf{g}_0(h) + v_1 \mathbf{g}_1(h) + \dots + v_n \mathbf{g}_n(h) \\
 \mathbf{g}_{UV}(h) &= w_0 \mathbf{g}_0(h) + w_1 \mathbf{g}_1(h) + \dots + w_n \mathbf{g}_n(h)
 \end{aligned}
 \tag{3.36}$$

onde $\mathbf{g}_U(h)$ e $\mathbf{g}_V(h)$ são auto-variogramas e $\mathbf{g}_{UV}(h)$ é o variograma-cruzado das variáveis U e V . Os modelos de variogramas básicos são dados por $\mathbf{g}_0(h)$, $\mathbf{g}_1(h)$, ..., $\mathbf{g}_n(h)$, onde u , v e w são os coeficientes.

Os auto-variogramas e os variogramas-cruzados podem ser dados pelas equações (3.37) e (3.38) respectivamente, dadas abaixo:

$$\mathbf{g}_u(h) = \frac{1}{2N(h)} \sum_{(i,j)|h_{ij}=h} (u_i - u_j)^2 \quad (3.37)$$

$$\mathbf{g}_u(h) = \frac{1}{2N(h)} \sum_{(i,j)|h_{ij}=h} (u_i - u_j)^* (v_i - v_j) \quad (3.38)$$

A equação (3.36) pode ser convenientemente escrita na forma matricial, como segue:

- Combinações do primeiro modelo básico:

$$\begin{bmatrix} \mathbf{g}_{U,0}(h) & \mathbf{g}_{UV,0}(h) \\ \mathbf{g}_{VU,0}(h) & \mathbf{g}_{V,0}(h) \end{bmatrix} = \begin{bmatrix} u_0 & \mathbf{w}_0 \\ \mathbf{w}_0 & v_0 \end{bmatrix} * \begin{bmatrix} \mathbf{g}_0(h) & 0 \\ 0 & \mathbf{g}_0(h) \end{bmatrix} \quad (3.39)$$

- Combinações do segundo modelo básico:

$$\begin{bmatrix} \mathbf{g}_{U,1}(h) & \mathbf{g}_{UV,1}(h) \\ \mathbf{g}_{VU,1}(h) & \mathbf{g}_{V,1}(h) \end{bmatrix} = \begin{bmatrix} u_1 & \mathbf{w}_1 \\ \mathbf{w}_1 & v_1 \end{bmatrix} * \begin{bmatrix} \mathbf{g}_1(h) & 0 \\ 0 & \mathbf{g}_1(h) \end{bmatrix} \quad (3.40)$$

- Combinações dos n -*ésimos* modelos básicos:

$$\begin{bmatrix} \mathbf{g}_{U,n}(h) & \mathbf{g}_{UV,n}(h) \\ \mathbf{g}_{VU,n}(h) & \mathbf{g}_{V,n}(h) \end{bmatrix} = \begin{bmatrix} u_n & \mathbf{w}_n \\ \mathbf{w}_n & v_n \end{bmatrix} * \begin{bmatrix} \mathbf{g}_n(h) & 0 \\ 0 & \mathbf{g}_n(h) \end{bmatrix} \quad (3.41)$$

Para garantir a condição de positivo definido do modelo, deve-se assegurar que os coeficientes u , v e ω sejam maiores que 0 (zero):

$u_i > 0$ e $v_j > 0$, para todos $j=0, \dots, n$

$u_j \cdot v_j > w_i w_j$, para todos $j=0, \dots, n$

4. INFERÊNCIAS UTILIZANDO OS MÉTODOS DE KRIGAGEM E COKRIGAGEM

De acordo com DELFINER E DELHOMME (1975) *apud* CAMARGO (1998), o termo krigagem é derivado do nome Daniel G. Krige, que foi o primeiro a introduzir o uso das médias móveis para evitar a superestimação sistemática em reservas de mineração. O método de krigagem pode ser utilizado para solucionar problemas em diversas áreas como mapeamentos geológicos, de solos, hidrológicos, atmosféricos, etc (CAMARGO, 1998).

O método de krigagem é semelhante ao de interpolação por média móvel ponderada, porém na krigagem os pesos dados a cada observação são determinados a partir de uma pré-análise espacial utilizando semivariogramas experimentais. Considerando que o estimador de krigagem fornece, em média, *estimativas não tendenciosas e com variância mínima*, ou seja, a diferença entre os valores estimados e os verdadeiros, para o mesmo ponto, deve ser igual a zero e os estimadores possuem a menor variância entre os estimadores.

A krigagem inclui diversos tipos de métodos de estimação, tais como: krigagem simples, ordinária, universal, indicadora, disjunta e cokrigagem. Porém este estudo tratará de algumas variações da krigagem ordinária como: krigagem ordinária isotrópica e anisotrópica, além da indicadora isotrópica e da cokrigagem.

4.1. Krigagem

Para satisfazer as condições de não viés e menor variância citadas no item anterior, visto que não são conhecidos os valores verdadeiros dos pontos estimados, a krigagem baseia-se em um modelo probabilístico, ou seja, num processo que trata os dados como resultados de um processo aleatório que não corresponde

exatamente à realidade. Nos modelos probabilísticos, o erro residual médio e a variância dos erros podem ser estimados, e com isso podem ser atribuídos pesos às amostras, de modo que o erro médio seja zero e a variância seja mínima.

Estimando um ponto não amostrado, através de uma combinação linear dos pesos de amostras de sua vizinhança, levando em conta a teoria de que pontos mais próximos são mais correlacionados que os pontos mais distantes, tem-se que:

$$\hat{v} = \sum_{j=1}^n w_j \cdot v_j \quad (4.1)$$

sendo: \hat{v} o valor estimado;

w_j os pesos atribuídos as amostras;

v o valor verdadeiro.

O erro (r_i) no ponto estimado é a diferença entre o valor estimado e o real:

$$r_i = \hat{v} - v \quad (4.2)$$

Após um número de estimativas k , o erro médio (m_r) é dado por:

$$m_r = \frac{1}{k} \sum_{i=1}^k r_i = \frac{1}{k} \sum_{i=1}^k \hat{v}_i - v \quad (4.3)$$

Como já dito, os valores verdadeiros não são conhecidos, por isso utiliza-se um modelo probabilístico, no qual os valores estimados são obtidos por meio de um

processo aleatório estacionário. Assume-se então que o valor médio esperado é constante para as diversas localizações, ou seja, cada par de variáveis possui uma distribuição conjunta que depende somente da distância e não de suas localizações. Nesse processo, tanto os valores verdadeiros quanto os estimados são considerados variáveis aleatórias, pois os valores estimados são resultado de uma combinação linear de variáveis aleatórias que são as amostras, como na equação (4.4):

$$\hat{V}(x_0) = \sum_{i=1}^n w_i V(x_i) \quad (4.4)$$

O erro, também nesse caso, é obtido através da diferença entre o valor estimado e o valor verdadeiro e, também, é considerado como uma variável aleatória:

$$R(x_0) = \hat{V}(x_0) - V(x_0) \quad (4.5)$$

Substituindo a equação (4.4), que expressa o valor estimado em termos de combinação linear das variáveis aleatórias, em (4.5), tem-se o erro dado pela equação (4.6):

$$R(x_0) = \sum_{i=1}^n w_i \cdot V(x_i) - V(x_0) \quad (4.6)$$

Para garantir a condição de não viés, a qual estabelece que erro residual médio é zero, aplica-se a fórmula da esperança de um valor na equação (4.6), como é demonstrada pela equação (4.7):

$$\begin{aligned}
E\{R(x_0)\} &= E\left\{\sum_{i=1}^n w_i V(x_i) - V(x_0)\right\} \\
E\{R(x_0)\} &= \sum_{i=1}^n w_i E\{V(x_i) - E\{V(x_0)\}\}
\end{aligned} \tag{4.7}$$

Aplicando-se a condição de estacionariedade, a qual diz que o valor médio é constante para as diversas localizações, tem-se que:

$$\begin{aligned}
E\{R(x_0)\} &= \sum_{i=1}^n w_i E\{V\} - E\{V\} \\
E\{R(x_0)\} &= 0 = E\{V\} \left(\sum_{i=1}^n w_i - 1\right) \\
E\{V\} &= \sum_{i=1}^n w_i E\{V\} \\
\sum_{i=1}^n w_i &= 1
\end{aligned} \tag{4.8}$$

4.1.1. Variância dos Erros Estimados

No processo de krigagem o principal objetivo é avaliar a variância do erro da estimativa e minimizá-la. Como já foi definido na equação (4.6), o erro é dado por:

$$R(x_0) = \sum_{i=1}^n w_i V(x_i) - V(x_0),$$

onde $\sum_{i=1}^n w_i V(x_i) = \hat{V}_0$.

A variância de uma combinação linear ponderada pode ser escrita em termos de covariância, segundo a equação (4.9):

$$Var\left\{\sum_{i=1}^n w_i V_i\right\} = \sum_{i=1}^n \sum_{j=1}^n w_i w_j \{V_i V_j\} \tag{4.9}$$

Pelas regras estatísticas a equação (4.9) da variância dos erros pode ser estendida, como mostra a equação (4.10):

$$Var\{\hat{V}(x_0) - V(x_0)\} = Var\{\hat{V}(x_0) + Var(Vx_0) - 2Cov(\hat{V}(x_0), V(x_0))\} \quad (4.10)$$

Sabendo que:

$$Cov\{\hat{V}(x_0), \hat{V}(x_0)\} = Var\{\hat{V}(x_0)\} \quad (4.11)$$

$$Cov\{V(x_0), V(x_0)\} = Var\{V(x_0),\}$$

Substituindo a equação (4.11) na equação (4.10) e obtendo-se (4.12), como segue:

$$Var\{\hat{V}(x_0) - V(x_0)\} = Cov\{\hat{V}(x_0), \hat{V}(x_0)\} - Cov\{\hat{V}(x_0), V(x_0)\} - Cov\{\hat{V}(x_0), V(x_0)\} + Cov\{V(x_0), V(x_0)\} \quad (4.12)$$

$$Var\{\hat{V}(x_0) - V(x_0)\} = Cov\{\hat{V}(x_0), \hat{V}(x_0)\} - 2Cov\{\hat{V}(x_0), V(x_0)\} + Cov\{V(x_0), V(x_0)\}$$

Analisando, então, cada termo da equação (4.12) separadamente, pode-se ver que, no primeiro termo da equação, tem-se a covariância de $\hat{V}(x_0)$ com ela mesma, como foi mostrado nas equações (4.11), ou seja, é o mesmo que a variância de uma combinação linear de variáveis aleatórias, como segue em (4.13):

$$Var\{\hat{V}(x_0)\hat{V}(x_0)\} = Var\left\{\sum_{i=1}^n w_i \cdot V_i\right\} = \sum_{i=1}^n \sum_{j=1}^n w_i w_j C_{ij} \quad (4.13)$$

Segundo ISAACS & SRIVASTAVA (1989), a covariância entre duas variáveis aleatórias é definida como segue na equação (4.14):

$$Cov\{V_i V_0\} = \tilde{C}_{i0} = E\{(V_i - E\{V_i\})(V_0 - E\{V_0\})\} = E\{V_i V_0\} - E\{V_i\}E\{V_0\} \quad (4.14)$$

Assim, o segundo termo pode ser reescrito como segue em (4.15):

$$\begin{aligned} 2Cov\{\hat{V}(x_0)V(x_0)\} &= 2Cov\left\{\left(\sum_{i=1}^n w_i V_i\right)V_0\right\} \\ &= 2E\left\{\sum_{i=1}^n w_i V_i \cdot V_0\right\} - 2E\left\{\sum_{i=1}^n w_i V_i\right\} \cdot E\{V_0\} \\ &= 2\sum_{i=1}^n w_i \cdot E\{V_i, V_0\} - 2\sum_{i=1}^n w_i \cdot E\{V_i\} \cdot E\{V_0\} \\ &= 2\sum_{i=1}^n w_i \cdot Cov\{V_i V_0\} \\ &= 2\sum_{i=1}^n w_i \tilde{C}_{i0} \end{aligned} \quad (4.15)$$

Combinando os três termos novamente, tem-se a seguinte equação para a variância do erro:

$$\tilde{s}_R^2 = \tilde{s}^2 + \sum_{i=1}^n \sum_{j=1}^n w_i w_j \tilde{C}_{ij} - 2\sum_{i=1}^n w_i \tilde{C}_{i0} \quad (4.16)$$

4.1.2. Krigagem Ordinária

De acordo com FELGUEIRAS (1999), a krigagem ordinária possibilita a inferência do atributo, numa posição u , sem a necessidade de se conhecer a média estacionária μ . Com a condição de que a somatória dos ponderadores da krigagem $w_i(u)$ seja igual a 1, isto é:

$$\sum_{i=1}^n w_i = 1 \quad (4.17)$$

Para isso é necessário calcular as $n + 1$ derivadas parciais da equação (4.16) e igualar a zero. A primeira derivada, em relação a w_1 , é detalhada a seguir:

$$\begin{aligned} \frac{\partial(\sum_{i=1}^n \sum_{j=1}^n w_i w_j \tilde{C}_{1j})}{\partial w_1} &= \frac{\partial(w_1^2 \tilde{C}_{11} + 2w_1 \sum_{j=2}^n w_j \tilde{C}_{1j})}{\partial w_1} \\ &= 2w_1 \tilde{C}_{11} + 2 \sum_{j=2}^n w_j \tilde{C}_{1j} \\ &= 2 \sum_{j=1}^n w_j \tilde{C}_{1j} \\ \frac{\partial(\sum_{i=1}^n w_i \tilde{C}_{i0})}{\partial w_i} &= \frac{\partial(w_1 \tilde{C}_{10})}{\partial w_1} = \tilde{C}_{10} \end{aligned} \quad (4.18)$$

$$\frac{\partial(\mathbf{m}(\sum_{i=1}^n w_i - 1))}{\partial w_1} = \frac{\partial(\mathbf{m}w_1)}{\partial w_1} = \mathbf{m} \quad (4.19)$$

Derivando σ_R^2 em relação à w_1 , tem-se que:

$$\frac{\partial(\tilde{\mathbf{s}}_R^2)}{\partial w_1} = 2 \sum_{j=1}^n w_j \tilde{C}_{1j} - 2 \tilde{C}_{10} + 2\mathbf{m} \quad (4.20)$$

Igualando a zero, tem-se:

$$\begin{aligned} 2 \sum_{j=1}^n w_j \tilde{C}_{1j} - 2 \tilde{C}_{10} + 2\mathbf{m} &= 0 \\ \sum_{j=1}^n w_j \tilde{C}_{1j} + \mathbf{m} &= \tilde{C}_{10} \end{aligned} \quad (4.21)$$

Destas derivadas têm-se as seguintes condições:

$$\sum_{j=1}^n w_j \tilde{C}_{ij} + \mathbf{m} = \tilde{C}_{i0} \quad \forall i = 1, \dots, n \quad (4.22)$$

$$\sum_{i=1}^n w_i = 1 \quad (4.23)$$

O sistema de equações para a krigagem ordinária pode ser escrito matricialmente como:

$$\begin{bmatrix} \tilde{C}_{11} & \dots & \tilde{C}_{1n} & 1 \\ \dots & \dots & \dots & \dots \\ \tilde{C}_{n1} & \dots & \tilde{C}_{nn} & 1 \\ 1 & \dots & 1 & 0 \end{bmatrix} \begin{bmatrix} w_1 \\ \dots \\ w_n \\ \mathbf{m} \end{bmatrix} = \begin{bmatrix} \tilde{C}_{10} \\ \dots \\ \tilde{C}_{n0} \\ 1 \end{bmatrix} \quad (4.24)$$

$C \quad \cdot \quad W = D$

Cuja solução é:

$$\begin{aligned} C \cdot w &= D \\ C^{-1} \cdot C \cdot w &= C^{-1} \cdot D \\ I \cdot w &= C^{-1} \cdot D \\ w &= C^{-1} \cdot D \end{aligned} \quad (4.25)$$

E a variância dos erros minimizada pela krigagem ordinária é dada por:

$$\mathbf{s}_R = \mathbf{s} - w \cdot D \quad (4.26)$$

4.1.3. Krigagem Indicadora ou por Indicação

A krigagem indicadora é um estimador de krigagem não linear, ou seja, um estimador de krigagem linear aplicado a um conjunto de dados que foram modificados segundo uma transformação gaussiana, lognormal ou outra (DEUTSCH E JOURNAL, 1998). Na krigagem indicadora é necessário a realização de uma transformação não linear sobre o conjunto de dados amostrais $Z(u_k)$, a qual é denominada *codificação por indicação*. A principal vantagem da krigagem indicadora é a de ser uma técnica não paramétrica, ou seja, nenhum tipo de distribuição para a variável aleatória é considerado a priori, o que possibilita uma estimativa da função de distribuição para a VA, permitindo a determinação de incertezas e a inferência de valores do atributo em locais não amostrados. Essa técnica também possibilita a modelagem de dados com grande variabilidade espacial.

A função distribuição acumulada, **fdac**, $F(u; z|(n))$, modela a incerteza sobre os valores de $Z(u)$, em posições u não amostradas. A krigagem indicadora permite uma aproximação da fdac.

Como já foi colocado anteriormente, a krigagem indicadora requer que os valores dos atributos sejam modificados segundo uma transformação não linear, a *codificação por indicação*. Um conjunto amostral por indicação $I(u=u_k)$ para um valor de corte z_k é gerado através da codificação por indicação aplicada a um conjunto de dados $Z(u=u_k)$, segundo a equação (4.27):

$$I(u; z_k) = \begin{cases} 1, & \text{se } Z(u) \leq z_k \\ 0, & \text{se } Z(u) > z_k \end{cases} \quad (4.27)$$

O processo de codificação por indicação aplicado sobre todo conjunto amostral para o valor de corte z_k , onde $k = 1, 2, \dots, k$, é mostrado na figura 6.1:




FIGURA 4.1 – CODIFICAÇÃO POR INDICAÇÃO DOS DADOS AMOSTRAIS PARA O VALOR DE CORTE $Z=Z_k$

Fonte: Felgueiras, 1999

O modelo de variografia é obtido através do conjunto amostral codificado com valores 0 e 1, o qual depende da existência mínima de 0's e 1's no conjunto de amostra. Segundo ISAACS & SRIVASTAVA (1989), o melhor modelo de variografia é obtido para o valor de corte igual ao valor da mediana, do conjunto amostral.

O conjunto amostral codificado é utilizado para inferir valores para variáveis aleatórias por indicação $I(u; z_k)$, com $u \neq u_\alpha$.

Segundo Felgueiras (1999), a esperança condicional da VA numérica por indicação $I(u; z_k)$ é calculada por:

$$\begin{aligned} E\{I(u; z_k) / (n)\} &= 1 \cdot \text{prob}\{I(u; z_k) = 1 / (n)\} + 0 \cdot \text{prob}\{I(u; z_k) = 0 / (n)\} \\ &= 1 \cdot \text{prob}\{I(u; z_k) = 1 / (n)\} = F^*(u; z_k) / (n) \end{aligned} \quad (4.28)$$

A formulação acima mostra que a esperança condicional de $I(u; z_k)$ fornece, para cada valor de corte z_k , uma estimativa da função de distribuição acumulada condicionada, $F^*(u; z_k|n)$, para atributos numéricos.

A krigagem indicadora simples é dada pela equação (4.29) abaixo:

$$F^*_{s}(u; z_k |n) = \sum_{a=1}^{n(u)} I_{sa}(u; z_k) i(u_a; z_k) + [1 - \sum_{a=1}^{n(u)} I_{sa}(u; z_k) F^*(z_k)] \quad (4.29)$$

onde:

$F^*(z_k)$ é a média da função aleatória da região estacionária; e

$\lambda_{s\alpha}(u; z_k)$ são os pesos determinados com o objetivo de minimizar a variância do erro da estimação.

No entanto, considerando que a somatória dos pesos seja igual a 1 têm-se a krigagem indicadora ordinária, a qual possui a seguinte equação de estimação:

$$F^*_{o}(u; z_k |n) = \sum_{a=1}^{n(u)} I_{oa}(u; z_k) i(u_a; z_k) \quad (4.30)$$

Os pesos $I_{oa}(u; z_k)$ são calculados resolvendo o sistema de equações abaixo:

$$\begin{cases} \sum_{b=1}^{n(u)} I_{ob}(u; z_k) C_1(h_{ab}; z_k) + \phi(u; z_k) = C_1(h_a; z_k) \\ \sum_{b=1}^{n(u)} I_{ob}(u; z_k) = 1 \end{cases} \quad (4.31)$$

Onde:

$\phi(u; z_k)$ – é o multiplicador de *Lagrange*;

$h_{\alpha\beta}$ - vetor separação definido pelas posições u_{α} e u_{β} ;

h_{α} - vetor definido entre as posições u_{α} e u ;

$C_I(h_{\alpha\beta}; z_k)$ – autocovariância dada por $h_{\alpha\beta}$;

$C_I(h_{\alpha}; z_k)$ – autocovariância dada por h_{α} ;

Ressalta-se que as autocovariâncias são dadas pelos modelos variográficos teóricos definidos pelo conjunto I para o valor de corte z_k .

A krigagem indicadora, tanto simples quanto ordinária, fornecem estimativas para cada valor de corte z_k , que é também a melhor estimativa mínima quadrática da esperança condicional da VA $I(u, z_k)$, segundo FELGUEIRAS (1999). Calculando as estimativas para diversos valores de corte da fdac de $Z(u)$, tem-se uma aproximação discretizada da fdac real de $Z(u)$. Por isso, quanto maior for o número de cortes melhor será a aproximação.

4.2. Cokrigagem

O termo cokrigagem é reservado para a regressão linear que usa dados em diferentes atributos, (DEUTSCH E JOURNAL, 1998). O processo de cokrigagem é um procedimento geoestatístico pelo qual diversas variáveis regionalizadas podem ser estimadas em conjunto, com base na correlação espacial entre elas. Pode ser considerada uma extensão multivariada do método de krigagem quando, para cada local amostrado, obtém-se um vetor de valores em lugar de um valor único.

O processo de cokrigagem é utilizado para duas ou mais variáveis que são amostradas nos mesmos locais, em um mesmo domínio espacial e apresentam um certo grau de correlação. Tal método deve ser usado, principalmente, quando uma das variáveis apresenta-se sub-amostrada em relação às outras. O objetivo principal deste

método é, portanto, melhorar a estimativa da variável sub-amostrada utilizando aquelas densamente amostradas, (LANDIM et al. 2002).

Para simplificar a notação, optou-se por desenvolver o sistema de cokrigagem em termos de duas variáveis, o que facilitará o entendimento do que é desenvolvido para um número maior de variáveis.

A estimativa por cokrigagem é uma combinação linear de valores de dados primários e secundários e é dada por (4.32):

$$U_{cok}^*(u) = \sum_{i=1}^{n_1} a_i u_i + \sum_{j=1}^{n_2} b_j v_j \quad (4.32)$$

onde:

$U_{cok}^*(u)$ - é a estimativa de u ;

u_i 's - são os dados primários em posições próximas de n ;

v_j 's - são os dados secundários em posições próximas de n ;

a_i 's e b_j 's - são os pesos determinados para as amostras.

O desenvolvimento do sistema de cokrigagem é idêntico ao desenvolvimento do sistema de krigagem ordinária. Neste caso, também inicia-se definindo a estimativa dos erros como:

$$\begin{aligned} R &= U_{cok}^* - U_{cok} \\ R &= \sum_i^{n_1} a_i U_i + \sum_j^{n_2} b_j V_j - U_{cok} \end{aligned} \quad (4.33)$$

onde U_i 's são as variáveis aleatórias representando o fenômeno U nas n localizações próximas onde U foi amostrado, idem para os V_j 's e o fenômeno V .

A equação (4.33) pode ser escrita como matriz:

$$R = w^t U \quad (4.34)$$

Sendo,

$$w^t = (a_1, \dots, a_n; b_1, \dots, b_n, -1) \text{ e}$$

$$U^t = (U_1, \dots, U_i; V_1, \dots, V_n, U_0).$$

Para expressar a variância de R tem-se a equação (4.35) abaixo:

$$\begin{aligned} \text{Var}\{R\} &= w^t C_U w \\ \text{Var}\{R\} &= \sum_i^{n_1} \sum_j^{n_1} a_i a_j \text{Cov}\{U_i U_j\} + \sum_i^{n_2} \sum_j^{n_2} b_i b_j \text{Cov}\{V_i V_j\} + \\ &+ 2 \sum_i^{n_1} \sum_j^{n_2} a_i b_j \text{Cov}\{U_i V_j\} - 2 \sum_i^{n_1} a_i \text{Cov}\{U_i U_0\} - 2 \sum_j^{n_2} b_j \text{Cov}\{V_j V_0\} + \text{Cov}\{U_0 U_0\} \end{aligned} \quad (4.35)$$

onde C_U é a matriz covariância de U.

O conjunto de pesos do sistema de cokrigagem deve obedecer duas condições. Primeiro, a estimativa dos pesos deve ser não viesada. Segundo, os pesos devem ser tal que a variância do erro seja a menor possível, conforme ISAACS & SRIVASTAVA (1989).

Para assegurar a primeira condição tem-se que:

$$\sum_{i=1}^n a_i = 1 \quad \text{e} \quad \sum_{j=1}^n b_j = 0$$

A variância do erro correspondente pode ser calculada usando a equação (4.13), ou para a condição especial de não viés, essa equação pode ser

simplificada fazendo algumas substituições e utilizando os multiplicadores de Lagrange.

A versão simplificada é dada por (4.36):

$$Var(R) = Cov\{U_0U_0\} + \mathbf{m} - \sum_{i=1}^{n1} a_i Cov\{U_iU_0\} - \sum_{j=1}^{n2} b_j Cov\{V_jU_0\} \quad (4.36)$$

4.2.1. Cokrigagem Indicadora ou Não Linear

A krigagem indicadora não usa completamente todos os dados contidos no conjunto original z . No caso de uma variável contínua, ela considera somente os valores que excedem o valor de corte k .

A solução é considerar todos os k dados indicadores $i(u_{\mathbf{a}}, z_k)$, $k = 1, \dots, k$, para estimar cada valor da função distribuição acumulativa condicional. A estimativa correspondente seria a krigagem co-indicadora (coKI) definida como:

$$[i(u; z_{k0})^*]_{coKI} = \sum_{k=1}^K \sum_{a=1}^n I_{a,k}(u; z_{k0}) \cdot i(u; z_k) \quad (4.37)$$

O sistema de cokrigagem correspondente seria denominado por uma matriz de K^2 covariâncias diretas e covariâncias indicadoras cruzadas do tipo:

$$C_1(h; z_k, z_{k'}) = Cov\{I(u; z_k), I(u+h; z_{k'})\} \quad (4.38)$$

O processo de cokrigagem indicadora se torna inviável para um valor de K muito grande, por esse motivo o detalhamento de tal processo não será feito. Isto pode ser encontrado em DEUTSCH E JOURNAL (1998).

4.2.2. Cokrigagem Ordinária Padronizada

O processo de cokrigagem ordinária padronizada consiste em criar novas variáveis secundárias, que possuam a média igual às variáveis primárias utilizadas no processo. Para isso, é necessário que a soma dos pesos das variáveis primárias e secundárias seja igual a 1.

Assim tem-se a equação abaixo:

$$U_{cok}^*(x_0) = \sum_{i=1}^{n_1} a_i u_i + \sum_{j=1}^{n_2} b_j v_j [Y(v_j') + m_U - m_Y] \quad (4.39)$$

Com a condição: $\sum_{i=1}^{n_1} a_i + \sum_{j=1}^{n_2} b_j = 1$, onde $m_U = E\{U(x_0)\}$ e $m_Y = E\{Y(x_0)\}$

são as médias estacionárias de U e Y.

4.2.3. Cokrigagem Co-localizada

De acordo com DEUTSH & JOURNAL (1998), a cokrigagem co-localizada consiste de uma forma reduzida da cokrigagem, retendo somente a variável secundária co-localizada $b(v_j)$, contanto que esteja disponível em todas as localizações v sendo estimadas. O estimador da cokrigagem co-localizada é dado pela equação (4.40).

$$U_{cok}^*(u) = \sum_{i=1}^{n_1} a_i u_i + b v \quad (4.40)$$

O sistema de cokrigagem requer somente o conhecimento da covariância C_U e da covariância cruzada $C_{UY}(h)$. Os outros podem ser aproximados pelo modelo dado pela equação (4.41).

$$C_{UY}(h) = B * C_U(h) \quad \forall h \quad (4.41)$$

Onde, $B = \sqrt{C_Y(0)/C_U(0)} * r_{UY}(0)$, $C_U(0)$, $C_Y(0)$ são as variâncias de U e Y, e $\rho_{UY}(0)$ é o coeficiente de correlação co-localizado dos dados u – y.

5. COMPORTAMENTO ESPECTRAL DA VEGETAÇÃO E DO SOLO

No sensoriamento remoto é de extrema importância saber como a radiação eletromagnética interage com a superfície da Terra, (CURRAN, 1983). Portanto, este capítulo trata da interação da radiação eletromagnética com os dois principais componentes considerados neste trabalho: o solo e a vegetação.

Solo

Diversos fatores influenciam na radiação refletida pela superfície, tais como: óxidos de ferro, umidade, matéria orgânica, granulometria, mineralogia e o material de origem (CURRAN, 1983). Portanto a quantidade de energia refletida por um tipo de solo é dada em função desses fatores.

O teor de óxido de ferro presente no solo é importante na reflectância tanto na banda do visível quanto do infravermelho próximo (MOREIRA, 2001).

A matéria orgânica existente no solo é um fator de forte influência na reflectância dos solos. Tal fator se mostra inversamente proporcional a reflectância do solo, ou seja, conforme o teor de matéria orgânica aumenta, a reflectância do solo diminui no intervalo de comprimento de onda de 400 a 2500 nm (MOREIRA, 2001).

Outro fator bastante influente na reflectância dos solos é a rugosidade e a formação de crosta superficial. De acordo com CURRAN (1983), as superfícies devem ser ásperas o bastante para permitir que haja interação entre a radiação e a superfície dos objetos. A rugosidade do solo, causada muitas vezes pela formação de torrões durante a aração do terreno, pode influenciar na reflectância do solo. E, além disso, a aração da terra provoca a quebra da estrutura superficial do solo, o que aumenta de 15 a 20 % a reflectância dos solos em relação àqueles com estrutura bem definida (MOREIRA, 2001).

Quando o solo apresenta-se molhado, mostra uma coloração mais escura, pois a absorção da radiação eletromagnética aumenta com a presença de água, isso faz com que a reflectância do solo diminua na região do visível e do infravermelho próximo se comparado com um solo seco.

Vegetação

Segundo JENSEN (2000), uma folha verde tipicamente saudável, tem uma alta reflectância na região do infravermelho entre 700 – 1200 nm.

MOREIRA (2001) e CURRAN (1983), dizem que os principais mecanismos que influenciam a quantidade de energia refletida pelas folhas são: pigmentos, água, espaços de ar e estrutura celular. Além disso, a energia refletida é influenciada também, pela maturação ou idade da folha, posição nodal, condição de iluminação, pubescência e senescência.

Os pigmentos das folhas, compostos pelas clorofilas *a* e *b* e xantofila absorvem a radiação eletromagnética do visível na faixa de 400 a 700 nm. Em função das características dos diferentes pigmentos, a absorção da radiação é mais acentuada nos comprimentos de onda de 480 nm (clorofila “b”) e 680 nm (clorofila “a”).

Na região do infravermelho próximo, o comportamento da radiação eletromagnética, quanto à reflexão, transmissão e absorção, é dominado pelas propriedades ópticas da folha, que dependem da sua estrutura celular interna (MOREIRA, 2001).

As considerações feitas referênciam a uma única folha são fundamentais para o entendimento do comportamento espectral das diferentes coberturas vegetais (CURRAN, 1983). Porém, a reflectância da cobertura vegetal é consideravelmente menor que a de uma única folha, por causa da atenuação da radiação

decorrente da variação do ângulo de incidência da radiação e de visada; devido a outros elementos do dossel e à resposta espectral da base do dossel, denominada reflectância de fundo (MOREIRA, 2001).

5.1. Características da Reflectância Espectral da Vegetação: a Função Distribuição da Reflectância Bidirecional

Se a cobertura vegetal, como a de uma plantação de soja, refletisse a mesma quantidade de radiância que chega ao sensor, sem influência do ângulo de incidência solar e dos ângulos, ou a geometria de visada do sensor, seria uma reflexão difusa perfeita. Isto resultaria em uma superfície perfeitamente lambertiana, ou seja, a energia incidente refletida seria igual em todas as direções. Porém, isto não ocorre de fato. Na verdade o fluxo de radiância espectral que parte da cobertura vegetal em direção ao sistema sensor é influenciado por diversos fatores (JENSEN, 2000), os quais são resumidos na tabela 5.1.

TABELA 5.1 – VARIÁVEIS QUE INTERFEREM NA FUNÇÃO DISTRIBUIÇÃO BIDIRECIONAL DA REFLECTÂNCIA DE UMA COBERTURA VEGETAL
Fonte: Jensen (2000)

Iluminação	Geometria <ul style="list-style-type: none"> - ângulo de incidência do Sol (ou sinal emitido do Radar); - azimute Características Espectrais (λ)
Sensor	Geometria <ul style="list-style-type: none"> - ângulo de visada; - direção do azimute (0 – 360°); - Sensitividade Espectral (λ); - IFOV (miliradianos).
Vegetação	Cobertura <ul style="list-style-type: none"> - tipo (planta); - fechamento (%); - orientação sistemática (fileiras); não sistemática (aleatória). Copa <ul style="list-style-type: none"> - forma (circular, cônica); - diâmetro (m). Folha <ul style="list-style-type: none"> - índice de área foliar (LAI); - distribuição do ângulo da folha (LAD).
Solo	Textura; Cor; Conteúdo de Humidade.

A quantidade e a distribuição do fluxo de radiância que deixa a cobertura vegetal é influenciado pelo tipo de vegetação presente. Algumas coberturas vegetais têm 100% de recobrimento, assim o solo debaixo não é visível através dela. Porém, ao contrário, também existem coberturas que tem $< 100\%$ de recobrimento, permitindo assim que porções de solo também sejam refletidas no campo de visada instantâneo (IFOV) do sensor, criando um pixel híbrido ou misto.

De acordo com JENSEN (2000), alguns tipos de vegetação são orientadas aleatoriamente, enquanto outras são orientadas sistematicamente, ou seja, arranjadas em fileiras na direção cardinal ($0 - 360^\circ$).

O Índice de Área Foliar (LAI) – é um importante parâmetro biológico porque: define a área que interage com a radiação e fornece muitos sinais ao sensoriamento remoto, e esta é a superfície responsável pela absorção do carbono e a troca com a atmosfera (JENSEN 2000).

A orientação das folhas (LAD), também é um fator que pode influenciar na resposta espectral da vegetação, pois pode mudar ao longo dos dias. Algumas folhas estão predominantemente orientadas no plano horizontal, enquanto outras estão orientadas verticalmente.

Todos os fatores descritos anteriormente, podem ter impactos significantes na reflexão da luz incidente para um sistema sensor.

5.1.1. Função Distribuição da Reflectância Bidirecional

De acordo com JENSEN (2000), medidas de reflectância bidirecional obtidas da vegetação e do solo têm demonstrado que a maioria da superfície terrestre possui comportamento não - lambertiano (anisotrópico).

O impacto da função distribuição da reflectância bidirecional não é ainda bem entendido, apesar de se saber que ela afeta vários dados de sensoriamento remoto usados para observações da Terra, especialmente para sensores com grandes campos de visada.

A maior parte dos objetos da superfície da Terra (solo, vegetação e até mesmo a água) revela uma relação entre a quantidade de radiância refletida, tanto com características geométricas da irradiância do Sol quanto com a geometria de visada do sensor.

O efeito bidirecional nos dados de sensoriamento remoto é mais óbvio quando o ângulo de iluminação e o ângulo de visada do sensor são quase idênticos e no mesmo plano (Jensen, 2000). O plano solar principal é formado quando a origem, o objetivo e o sensor estão no mesmo plano (no ângulo de azimute solar).

Cientistas têm tentado prever exatamente quanta energia radiante, em um determinado comprimento de onda, deixa uma folha ou cobertura vegetal, baseado em alguns fatores, incluindo os descritos na tabela 5.1. Alguns modelos têm sido amplamente utilizados, como os modelos SAIL e Li-Strahler, encontrados em JENSEN (2000). Estes modelos representam importantes tentativas para explicitar e modelar as interações matéria – energia localizadas acima e abaixo da cobertura vegetal. Eles se esforçam para inverter os modelos e usar as características da reflectância gravadas pelo sistema de sensor remoto para prever as características de tipos específicos de estruturas dentro da cobertura, altura das árvores, densidade, índice de área foliar, etc. Infelizmente, é difícil calibrar tais modelos porque muitas informações devem ser conhecidas sobre a folha e, também, as características da cobertura vegetal, condições atmosféricas, ângulo solar e geometria de visada, além do declive e aspectos do terreno.

5.2. Índices de Vegetação

A transformação espectral realizada entre dados multiespectrais, a qual retorna uma determinada quantidade, é denominado de *índice de vegetação*. Tal transformação pode ser a razão ou a diferença entre duas bandas.

Segundo MOREIRA, (2001), a assinatura espectral da vegetação verde e sadia possui um contraste evidente na região do visível, especialmente na região do vermelho e do infravermelho próximo.

Os índices de vegetação são utilizados para realçar o comportamento espectral da vegetação em relação ao solo, pois o contraste do solo na região do vermelho e do infravermelho próximo não é tão evidente quanto o da vegetação.

A composição das bandas do visível e do infravermelho próximo pode realçar diferenças espectrais entre solos e vegetação. Por isso, a razão entre essas bandas tem sido muito utilizada na estimativa de biomassa e cobertura de vegetação.

Os índices de vegetação derivados de dados obtidos de imagens multiespectrais de sensoriamento remoto, tem se tornado uma das principais fontes de informação para o monitoramento das condições da vegetação e mapeamento das mudanças de cobertura da superfície terrestre. O índice de vegetação mais amplamente utilizado nesse contexto é o NDVI (Índice de Vegetação Diferença Normalizada), o qual é dado pela composição matemática entre as bandas vermelho e infravermelho. No entanto, além do NDVI, a literatura traz diversos índices de vegetação, como o da Razão Simples.

De acordo com MOREIRA (2001), do ponto de vista matemático, a Razão Simples e a Diferença Normalizada (NDVI) apresentam equivalência funcional, por conterem o mesmo tipo de informações sobre os parâmetros biofísicos da cultura. No entanto, o NDVI, é mais sensível à vegetação esparsa do que a razão simples.

Como foi colocado anteriormente, os índices de vegetação têm sido utilizados para monitoramento e mapeamento de culturas, assim como para diversos outros fins relacionados à vegetação. TEILLET et al. (1997), utilizaram o índice de vegetação NDVI para demonstrar o impacto das mudanças no comprimento de onda e escala espacial, usando imagens do Espectroradiômetro Aerotransportado nas bandas do visível e infravermelho próximo para a região de floresta do sudeste de British Columbia. Enquanto GAMON et al. (2002), utilizou os índices de vegetação para estimar o conteúdo de água presente nas plantas, comparando o NDVI com outros índices.

Segundo MOREIRA (2001), na literatura se encontram mais de cinquenta índices de vegetação.

5.2.1. Razão Simples

O índice de vegetação mais simples e útil é denominado razão simples (RS), o qual é dado pela razão entre as bandas do vermelho e do infravermelho próximo. A equação para se determinar a RS é:

$$RS = \frac{NIR}{R} \quad (5.1)$$

onde NIR e R são as reflectâncias (ρ_{NIR} e ρ_R) ou as radiâncias (L_{NIR} e L_R) nas bandas do infravermelho próximo e vermelho, respectivamente.

Segundo IMAI et al. (2003), um forte motivo para usar razões com índice de vegetação, é que as medições feitas em campo, correspondentes às radiâncias (L), podem ser usadas diretamente, sem que haja necessidade de sua conversão para

dados de reflectância (ρ), quando se considera os valores de radiância obtidos através de uma placa de reflectância padrão.

A razão entre as radiâncias (L) de duas bandas, designadas por NIR e R difere da razão das reflectâncias (ρ) para essas mesmas duas bandas, pela razão de irradiâncias (E) entre essas bandas resulta na equação (5.2).

$$\frac{L_{NIR}}{L_R} = \left(\frac{E_{NIR}}{E_R} \right) * \left(\frac{r_{NIR}}{r_R} \right) \quad (5.2)$$

onde:

L_{NIR} – radiância na banda do infravermelho próximo;

L_R - radiância na banda do vermelho;

E_{NIR} – irradiância na banda do infravermelho próximo;

E_{IR} – irradiância na banda do vermelho;

ρ_{NIR} – reflectâncias na banda do infravermelho próximo;

ρ_R – reflectâncias na banda do vermelho;

Pois,

$$L_1 = \frac{(M_1)}{p} \quad (5.3)$$

$$L_1 = \frac{(r_1 * E_1)}{p} \quad (5.4)$$

O processo de conversão da radiância (L) para reflectância (ρ) deve considerar medidas realizadas sobre uma placa de referência padrão. A irradiância (E) pode ser obtida a partir das medidas feitas sobre essa placa, cuja reflectância (ρ) é aproximadamente 1.

$$E_{IVR} = \left(\frac{\mathbf{p} * L_{NIR_p}}{\mathbf{r}_{NIR_p}} \right) \quad (5.5)$$

$$E_R = \left(\frac{\mathbf{p} * L_{Rp}}{\mathbf{r}_{Rp}} \right) \quad (5.6)$$

onde:

L_{NIR_p} – radiância na banda do infravermelho próximo da placa;

L_{Rp} - radiância na banda do vermelho da placa;

ρ_{NIR_p} – reflectâncias na banda do infravermelho próximo da placa;

ρ_{Rp} – reflectâncias na banda do vermelho da placa;

Com isso, obtém-se a seguinte equação:

$$\frac{L_{NIR}}{L_R} = \left(\frac{L_{NIR_p} / \mathbf{r}_{NIR_p}}{L_{Rp} / \mathbf{r}_{Rp}} \right) * \left(\frac{\mathbf{r}_{NIR_p}}{\mathbf{r}_{Rp}} \right) \quad (5.7)$$

Rearranjando a equação anterior e isolando a razão das reflectâncias no primeiro termo, obtém-se o índice de vegetação razão simples tendo como entrada a reflectância:

$$RS = \begin{pmatrix} \mathbf{r}_{NIR} \\ \mathbf{r}_R \end{pmatrix} = \begin{pmatrix} L_{NIR} \\ L_R \end{pmatrix} * \begin{pmatrix} L_{Rp} \\ L_{NIRp} \end{pmatrix} \quad (5.8)$$

Com isso a razão das radiâncias entre as duas bandas será igual a razão de suas reflectâncias apenas quando as medidas de radiância sobre a placa padrão forem iguais nas duas bandas.

5.2.2. Índice de Vegetação Diferença Normalizada (NDVI)

Um dos índices de vegetação mais utilizados em sensoriamento remoto é o NDVI, Índice de Vegetação Diferença Normalizada, o qual é dado pela equação (5.9):

$$NDVI = \frac{(NIR - R)}{(NIR + R)} \quad (5.9)$$

onde:

- *NIR* é a energia refletida na região do infravermelho próximo, e
- *R* é a energia refletida na região do vermelho do espectro.

Com base em experimentos realizados, IMAI et al. (2003), verificaram que o índice de vegetação da diferença normalizada (NDVI) não se constitui em uma medida apropriada para avaliação de culturas que cobrem totalmente o terreno, ou seja, que não são esparsas, pois ele é extremamente sensível a vegetação esparsa, enquanto que o índice de vegetação razão simples é muito mais sensível à culturas “fechadas”. Pode-se notar pelos gráficos das figuras 5.1 e 5.2, que mostram as médias estimadas para os índices de razão simples e NDVI, respectivamente, que a razão simples contínua

sensível mesmo depois que a cultura recobre toda a área (após 45 dias aproximadamente), enquanto o NDVI se estabiliza a partir desse período.




FIGURA 5.1 - MÉDIAS ESTIMADAS PARA RAZÃO SIMPLES
Fonte: Imai et al., 2003

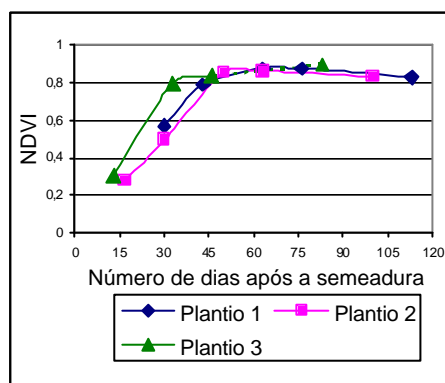


FIGURA 5.2 - MÉDIAS ESTIMADAS PARA NDVI
Fonte: Imai et al., 2003

Sabe-se que a fitomassa de uma cultura é avaliada pela taxa de aumento de matéria seca nas partes vegetativas da planta de soja (folhas, pecíolos e ramos). Porém, essa taxa é pequena no início, aumentando com o desenvolvimento dos estádios vegetativos da cultura. É o acúmulo de matéria seca nas plantas que determina o rendimento da cultura, de modo que a fitomassa, em determinados estágios de desenvolvimento, pode se constituir em um bom indicador do rendimento da cultura.

Dá a importância de verificar qual o índice que melhor representa a variação da massa verde da cultura e qual o melhor estágio para fazer a tomada das imagens.

6. MATERIAIS E MÉTODOS

6.1. Coleta dos Dados

A coleta dos dados foi realizada em duas áreas distintas, para que fossem realizados dois experimentos.

1^a Experimento – Coleta dos Dados no Município de Palotina - PR

Os dados foram obtidos no dia 20 de março de 2002, utilizando uma colhedeira instrumentada com um monitor de rendimento (PF3000-AgLeader) e um receptor GPS, o qual realiza posicionamento com a tecnologia DGPS recebendo dados de correção por satélite. Nesse experimento, os elementos amostrais foram coletadas pela colhedeira enquanto um receptor GPS acoplado à mesma recebeu informações posicionais. Assim, foram obtidos dados de rendimento e a posição de onde cada elemento amostral foi coletado.

2^a Experimento – Coleta dos Dados na Embrapa Soja – Londrina - PR

Foi realizada na plantação experimental da EMBRAPA – Soja em Londrina também no Paraná. Nesse caso, os dados de rendimento foram coletados manualmente, assim como suas respectivas informações posicionais, as quais foram coletadas com um receptor *GPS 4600LS da Trimble*, com o coletor TDC. Somente para este experimento foram tomadas imagens da área de forma a recobrirem toda área de interesse, juntamente com as informações posicionais necessárias para geração de um produto georreferenciado, este levantamento se deu no dia 07 de fevereiro de 2003.

Para que as posições sejam coletadas a área foi sinalizada com estacas de bambu numeradas, para facilitar a identificação.

O esquema mostrado na figura 6.1 mostra as etapas para a realização de ambos os experimentos.

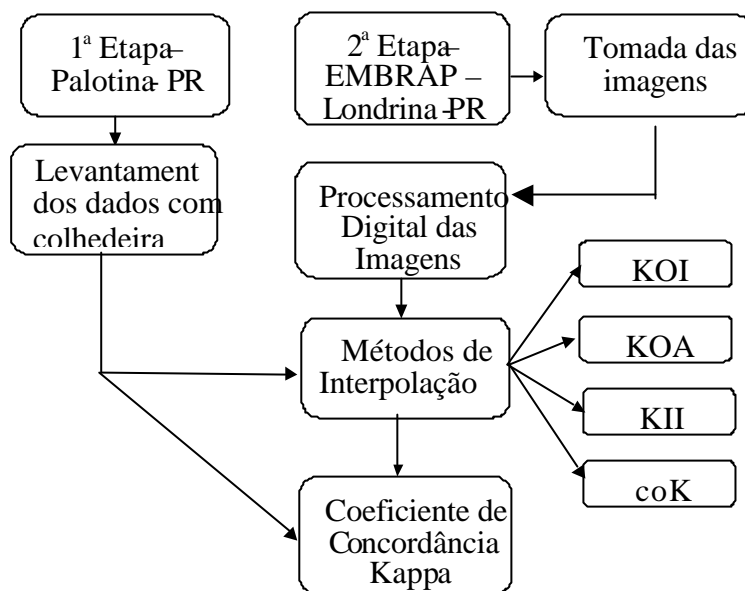


FIGURA 6.1 – ESQUEMA DOS LEVANTAMENTOS DE CAMPO REALIZADOS PARA AMBOS OS EXPERIMENTOS

6.1.1. Sistema de Aquisição de Imagens

O sistema de aquisição de imagens utilizado para o segundo experimento, foi projetado e construído na FCT / UNESP de Presidente Prudente, juntamente com a EMBRAPA – Soja de Londrina no Paraná. Ele é constituído basicamente pela câmara digital acoplada a uma carreta, um microcomputador, um monitor de vídeo e um receptor GPS. O sistema de aquisição de imagens é mostrado na figura 6.2.



FIGURA 6.2– SISTEMA DE AQUISIÇÃO DE IMAGENS

1. Câmara Digital Multiespectral DuncanTech MS 3100 – CIR

Uma câmara digital foi utilizada para coletar imagens multiespectrais. A câmara digital Duncan Tech MS 3100, utiliza um prisma para separar a radiação que entra através das lentes da câmara. A imagem adquirida para cada exposição é formada por comprimentos de onda de luz que passam através de cada caminho óptico do prisma.

Para adquirir dados de imagens com esse tipo de câmara, o sistema dispõe de um *frame grabber* (dispositivo capaz de ler o dados digitais de *pixels* produzidos pela câmara e transferir essa informação para a memória do computador como uma imagem), capaz de realizar aquisição paralela de um número apropriado de canais de imagens digitais à profundidade correta de bits.

As especificações da câmara são as seguintes:

- Chip CCD de 6,4 x 4,8 mm com 1392 x 1040 detectores cujo tamanho é de 0,0046 mm;
- Para compatibilizar com as outras câmaras digitais, assumiu-se que o tamanho do CCD utilizado é de 34,8 x 26 mm;

- Objetivas intercambiáveis;
- Distância focal da objetiva utilizada de 93 mm com o pixel de 0,025 mm

2. *Condições Atmosféricas*

As imagens foram adquiridas em condições atmosféricas consideradas ideais, no horário aproximado de 15hs 00m. Não havia nuvens recobrando a área imageada, o dia estava bastante claro, assim as configurações da câmara não precisaram ser alteradas com frequência.

3. *Ajustes da Câmara para Aquisição das Imagens*

Os ajustes da câmara devem ser feitos para que as imagens adquiridas tenham as condições ideais para serem utilizadas no trabalho, antes da câmara ser colocada no suporte da carreta. Porém muitas vezes, de acordo com a variação da iluminação e das condições do tempo, é necessário que eles sejam refeitos.

A abertura do sistema óptico e distância focal são configuradas na própria objetiva da câmara, sendo que a abertura maior é de 3,5 mm e a menor de 22 mm, com opções intermediárias de 5,6; 8,11 e 16 mm.

4. *Configurações do Software Câmera Link*

O *software Câmera Link* é um programa instalado no microcomputador para configurar a câmara para cada tipo de condição encontrada. Este *software* é ligado à câmara via comunicação RS-232.

Os controles encontrados neste *software* para a configuração da câmara são: tempo de exposição; modo de aquisição da imagem. As imagens podem ser

adquiridas em quatro canais: infravermelho (CIR), monocromático – IR, mono vermelho –R, mono verde – G; ganho.

6.2. Processamento Digital das Imagens

Nessa etapa foi realizado o processamento, necessário para produzir imagens cuja geometria e radiometria fossem adequadas ao trabalho. Nesse processamento foram produzidos os dados utilizados na tarefa de interpolação.

6.2.1. Fototriangulação e Retificação das Imagens

O processo de fototriangulação é necessário para obtenção dos parâmetros de orientação exterior da câmara: kappa (κ), fi (φ) e omega (ω), que definem a atitude da câmara no instante da tomada da imagem e são chamados de ângulos de Euler, além das coordenadas (X_0 , Y_0 e Z_0) aproximadas do ponto onde foi tomada a imagem (cp – centro perspectivo da câmara) (ANDRADE, 1998). Ainda de acordo com ANDRADE (1998), a orientação exterior permite a recuperação da posição e atitude de cada imagem segundo um referencial terrestre – geralmente no qual se pretende realizar o trabalho fotogramétrico.

Os parâmetros citados anteriormente devem ser utilizados no processo de retificação das imagens. Segundo WOLF (1983), retificação é o processo de geração de uma fotografia vertical equivalente a uma foto negativa inclinada. O produto resultante deste processo é chamado de foto retificada, que neste caso, seria uma imagem retificada, as quais teoricamente são imagens verdadeiramente verticais, e assim estão livres dos deslocamentos devido a inclinação, porém estas imagens não estão livres das distorções causadas pelos deslocamentos devido ao relevo.

O processo de retificação é necessário pois as imagens foram obtidas com a câmara em um ângulo oblíquo, após a retificação elas tornam-se verticais. A

fototriangulação e a retificação foram realizadas utilizando dois programas desenvolvidos pelo Prof. Júlio K. Hasegawa do Departamento de Cartografia da FCT – UNESP.

De acordo com ARRUDA (2002), a imagem retificada é obtida transferindo valores de brilho de uma imagem digital para uma malha fina e regular, que representa um sistema de coordenadas 3D com a coordenada Z constante.

6.2.2. Estimativa do Fator de Reflectância

A reflectância, representada por ‘ ρ ’, é um número adimensional, resultante da razão entre o diferencial do fluxo refletido e o incidente, sobre um diferencial de área ds de interesse. Essa medida, conforme MOREIRA (2001), deve levar em consideração o posicionamento do alvo, do sensor e da fonte de iluminação. Já o fator de reflectância (FR) é a razão entre o fluxo refletido por uma superfície amostral qualquer e o fluxo refletido, na mesma geometria, por uma superfície de referência padrão, conforme a equação (6.1):

$$FR(\%) = \frac{\text{medida tomada sobre o alvo}}{\text{medida da placa de referência}} \quad (6.1)$$

Durante o processo de aquisição das imagens deve ser utilizada uma placa recoberta com sulfato de bário, a qual possui uma superfície cuja reflexão seja perfeitamente difusa (lambertiana), ou seja, que reflita os feixes de raios que nela incidem em todas as direções. A reflectância dessa placa, possui o valor 1, que será considerado padrão para que a reflectância do restante da imagem possa ser analisada.

Durante o processamento das imagens o valor de reflectância dessa placa é utilizado estimar valores de fator de reflectância com base nos valores registrados nas imagens.

6.2.3. Normalização Radiométrica das Imagens

As imagens devem ainda ser analisadas, para verificar se ocorre mudança na resposta espectral, com a variação na distância e no ângulo de visada da câmara, como mostra o esquema da figura 6.3.




FIGURA 6.3- ÂNGULO DE VISADA DA CÂMARA

onde: FOV é o campo de visada da câmara.

Segundo NOVO (1992), a lei do co-seno de Lambert estabelece que o fluxo radiante por unidade de ângulo sólido que deixa uma superfície lambertiana em qualquer direção da superfície varia de acordo com o co-seno do ângulo entre aquela direção e a normal à superfície:

$$I_q = I_0 * \cos q \quad (6.2)$$

onde:

I_θ : é a intensidade na direção de θ ,

I_0 : é a intensidade na normal à superfície.

Se $I_\theta = I_0 * \cos \theta$ então as radiâncias $L_\theta = L_0$.

Caso a condição acima não seja alcançada é necessária a realização de uma normalização radiométrica das imagens.

Para esclarecer a idéia de normalização radiométrica são apresentadas algumas considerações: uma imagem é espacialmente formada por elementos discretos de resolução, denominados *pixels*, os quais são obtidos pela amostragem e quantização de cenas do mundo real. Sabe-se que a quantidade de radiação eletromagnética que forma uma imagem é influenciada por fatores externos da superfície imageada. Entre os fatores que influenciam na tomada da imagem está a atmosfera e o ângulo de visada. Assim, de acordo com SCHOTT et al (1988), a dificuldade de comparação de diferentes cenas decorre, não somente devido às condições atmosféricas, mas também devido às variações de ângulos de inclinação e visada e também dos parâmetros do sensor.

Existem técnicas de correção radiométrica que tentam remover as variações externas à cena.

SCHOTT et al. (1988) desenvolveram uma técnica de normalização radiométrica que corrige os efeitos da atmosfera, iluminação e diferenças de resposta do sensor. Tal técnica é constituída pela aplicação de um conjunto de transformações em cada banda espectral, porém os parâmetros utilizados para tal transformação são retirados de elementos da cena considerados invariantes temporalmente. A normalização radiométrica tem como resultado a alteração do valor de brilho registrado em cada banda para parecer que foi imageada com a mesma função de resposta e nas

mesmas condições atmosféricas e de iluminação de uma imagem considerada em condições ideais.

Uma transformação é dada pela equação 6.3.

$$I_{(i,j)N} = \left(\frac{S_R}{S_{AN}} \right) * [I_{(i,j)AN} - \overline{I_{(i,j)AN}}] + \overline{I_{(i,j)R}} \quad (6.3)$$

Sendo:

- $I_{(i,j)N}$ o valor de brilho do pixel (i,j) na imagem resultante da normalização;
- S_R e S_{AN} os desvios padrões da imagem de referência e da imagem a ser normalizada respectivamente;
- $\overline{I_{(i,j)AN}}$ e $\overline{I_{(i,j)R}}$ são as médias da imagem de referência e da imagem a ser normalizada respectivamente.

Essa transformação é baseada na suposição de que as distribuições são gaussianas e, portanto, representadas pela curva normal com parâmetros média e variância. Assim, adota-se a média e a variância de uma imagem como referência para transformação.

6.2.4. Georreferenciamento (Registro de Imagens) e Geração do Mosaico

O uso de transformações polinomiais de 1º e 2º graus é bastante comum no registro de imagens. As transformações polinomiais fazem o vínculo entre coordenadas de imagem e as coordenadas no sistema de referência através de pontos de controle. Pontos de controle são feições passíveis de identificação na imagem e no terreno (SPRING 3.6.03, 2003).

A determinação dos parâmetros da transformação polinomial selecionada é feita através de um ajustamento por MMQ (Método dos Mínimos Quadrados). Para que esse sistema de equações possa ser montado, as coordenadas dos pontos de controle devem ser conhecidas tanto no referencial da imagem quanto no sistema de referência do terreno.

O número mínimo de pontos de controle representa a situação de um sistema de equações determinado, no qual o número de equações coincide com o número de incógnitas a calcular. Entretanto, como as coordenadas medidas dos pontos de controle estão sujeitas a erros, convém usar um número de pontos maior que o mínimo e realizar um ajustamento.

Segundo WOLF e DEWIT (2000), se uma única foto não contém cobertura suficientemente extensa para servir como um fotomapa de uma área, um mosaico pode ser preparado.

De acordo com autores anteriormente citados, existem três tipos de mosaico: controlados, semicontrolados e não-controlados. Aqui só será comentado o primeiro tipo, o qual de acordo com ARRUDA (2002), é o mais acurado dos três tipos. Esse tipo de mosaico é preparado a partir de fotografias, ou neste caso imagens, que devem ser retificadas. Os mosaicos digitais controlados são preparados por um processo analítico similar ao georreferenciamento. Ao longo das extremidades entre as fotos adjacentes, as feições são alinhadas por toda extensão, embora raramente coincidam de uma imagem para outra.

6.2.5. Geração das Imagens Razão

Após a realização de todos os processamentos descritos anteriormente foram geradas as imagens da razão. Para a geração de tais imagens utilizou-se o índice de vegetação razão simples pelos motivos descritos no item 5.2.2 do capítulo anterior. As bandas utilizadas para obtenção das imagens razão foram as do infravermelho próximo e do vermelho, descartando a verde por não se integrar a composição matemática da razão simples.

6.3. Métodos de Interpolação

Os métodos de interpolação aplicados aos dados amostrais dos dois experimentos foram realizados de acordo com a descrição que segue.

6.3.1. Interpolação pelo Método da Krigagem

O processo de krigagem é composto de seis etapas. Tais etapas são mostradas no diagrama da figura 6.4, e descritas na seqüência.

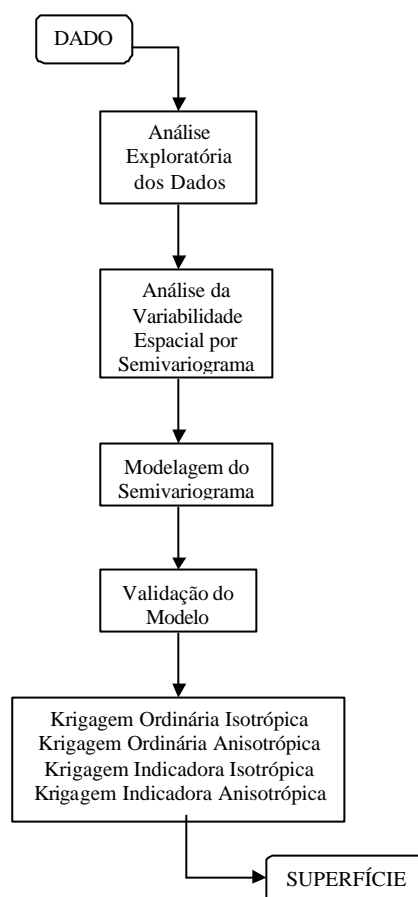


FIGURA 6.4 – DIAGRAMA DO PROCESSO DE KRIGAGEM

A análise exploratória dos dados é realizada através de estatísticas univariadas e bivariadas. As estatísticas univariadas fornecem um meio de organizar e sintetizar um conjunto de valores, e se realiza principalmente através do histograma. As principais características do histograma são: medidas de localização (média, mínimo, máximo, quartil inferior, mediana, quartil superior e máximo); medidas de dispersão (variância e desvio padrão); medidas de forma (coeficiente de assimetria, coeficiente de curtose e coeficiente de variação). Já a estatística bivariada fornece meios para descrever o relacionamento entre duas variáveis, ou seja, entre dois conjuntos de dados ou duas distribuições, e que pode ser visualizada por meio de um diagrama de dispersão e do coeficiente de correlação.

Na análise da variabilidade são gerados semivariogramas, os quais podem ser de superfície ou direcionais, conforme descrito no capítulo 3. A modelagem do semivariograma é realizada para encontrar os parâmetros que são utilizados nos processos de interpolação, como efeito pepita, patamar, alcance e contribuição.

Segundo CAMARGO (2000), o processo de validação do modelo de ajuste é uma etapa que precede as técnicas de interpolação geoestatística. Seu principal objetivo é avaliar a adequação do modelo proposto ao processo que envolve a re-estimação dos valores amostrais conhecidos. Na etapa de validação são gerados diagramas espaciais do erro, histogramas do erro, estatísticas do erro e diagramas de valores observados e estimados.

Finalmente, nos vários processos de krigagem são geradas as superfícies, assim como seus respectivos mapas de variância da krigagem, para o caso da ordinária isotrópica e anisotrópica e mapas de incerteza, para o caso da indicadora isotrópica e anisotrópica.

6.3.2. Interpolação pelo Método da Cokrigagem

O processo de interpolação pelo método de cokrigagem tem características similares descritas para o método de krigagem, as quais são mostradas no diagrama da figura 6.5.

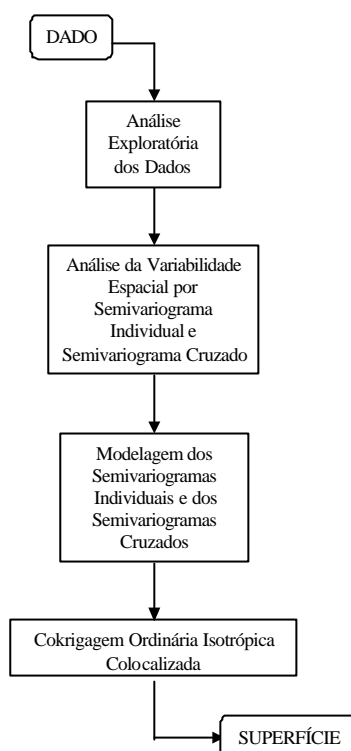


FIGURA 6.5 – DIAGRAMA DO PROCESSO DE COKRIGAGEM

Apesar da similaridade com o processo descrito no item 6.3.1, neste processo são utilizadas duas ou mais variáveis correlacionadas, uma variável primária e variáveis secundárias. Assim, na etapa de geração dos semivariogramas é necessário gerar semivariogramas direcionais individuais, um para cada variável envolvida, e um variograma cruzado com todas as variáveis envolvidas.

O raciocínio para a modelagem dos semivariogramas no processo de cokrigagem é o mesmo da krigagem, assim como os parâmetros encontrados, sendo que maiores detalhes podem ser encontrados no capítulo 4.

6.4. Coeficiente de Concordância *Kappa*

De acordo com ANTUNES & LINGNAU (1997), a avaliação da acurácia pode ser obtida por meio de coeficientes de concordância, sendo que estes podem ser expressos como concordância total ou para classes individuais. O coeficiente

de concordância usado para avaliar a acurácia total do mapa temático neste trabalho é o índice *Kappa*

Em qualquer mapa temático obtido através da classificação digital pode ser efetuada a análise da acurácia referente as seguintes componentes (MONTGOMERY e SCHUCH, 1993):

- Posicional, que se refere a precisão espacial do mapa, e que é variável de acordo com a escala do mapa;
- Temático, refere-se à precisão da classificação das diferentes categorias que compõem o mapa. Estas devem estar de acordo com a escala e o grau de generalização da informação e refletir no mapa a mesma classe no terreno;
- A Área Total obtida por categoria também é uma componente importante, no entanto não muito significativa.

Neste trabalho, será analisada somente a acurácia da componente temática.

Para realizar a verificação da acurácia da componente temática, assim como de qualquer uma das componentes, é necessário utilizar uma imagem de referência, a qual será considerada como verdade terrestre.

Durante o processo de verificação da acurácia é gerada uma matriz de erros ou matriz de confusão, a qual traz de forma resumida os resultados da classificação digital em relação à imagem referência, onde se tem uma distribuição binomial. Cada frequência observada na matriz corresponderá também a uma frequência esperada, a qual é calculada sob uma determinada hipótese, de acordo com as regras da probabilidade (SPIEGEL, 1993). A frequência observada na diagonal (x_{ii}) apresenta a concordância entre o esperado e observado em cada categoria, ou seja, aqueles corretamente classificados. A coluna marginal é o número total de elementos de

imagem para cada classe (x_{i+}). A linha marginal o número de pontos atribuídos a cada classe (x_{+i}), (ANTUNES & LINGNAU, 1997).

COHEN (1960) apud (ANTUNES & LINGNAU, 1997), define *Kappa* como um coeficiente de concordância para escalas nominais que mede a proporção de concordância depois que a concordância atribuída à casualidade é retirada de consideração. O coeficiente *Kappa* considera todos os elementos da matriz de erros ao invés de apenas aqueles que se situam na diagonal principal da mesma, ou seja, estima a soma da coluna e linha marginais. Segundo COHEN (1960) apud (ANTUNES & LINGNAU, 1997), o coeficiente *Kappa* mede o grau de concordância em escalas nominais assumindo que :

- As unidades são independentes;
- As classes ou categorias da escala nominal são independentes e mutuamente exclusivas;
- O classificador e os pontos de referência operam de forma independente.

O índice de concordância *Kappa* é calculado pela equação 6.4:

$$\hat{K} = \frac{x \sum_{i=1}^k x_{ii} - \sum_{i=1}^k (x_{i+} * x_{+i})}{x^2 - \sum_{i=1}^k (x_{i+} * x_{+i})} \quad (6.4)$$

onde,

x_{ii} - número de observações na linha i e coluna i ;

x_{i+} e x_{+i} - totais marginais da linha i e coluna i , respectivamente;

x - número total de observações.

7. EXPERIMENTOS E RESULTADOS

7.1. Coleta dos Dados para o Primeiro Experimento - Palotina - PR

A coleta dos dados deste experimento foi realizada em uma plantação experimental de soja no município de Palotina no Paraná, utilizando uma colhedeira equipada, como descrito no capítulo 6 no item 6.1. Foram coletados 6609 elementos amostrais de rendimento e suas respectivas posições. Os elementos amostrais foram coletados com uma distância de aproximadamente 3 m na mesma linha e de 7 m entre uma linha e outra, totalizando uma área de aproximadamente 135000 m² ou 13,5 hectares. Apesar de dispendioso e de se coletar um número elevado de elementos amostrais, este processo pode ser considerado mais simples que o realizado no segundo experimento, pois os elementos amostrais do rendimento e suas posições são coletadas ao mesmo tempo pelos sensores da colhedeira. As posições dos elementos amostrais coletados em campo são mostradas na figura 7.1.

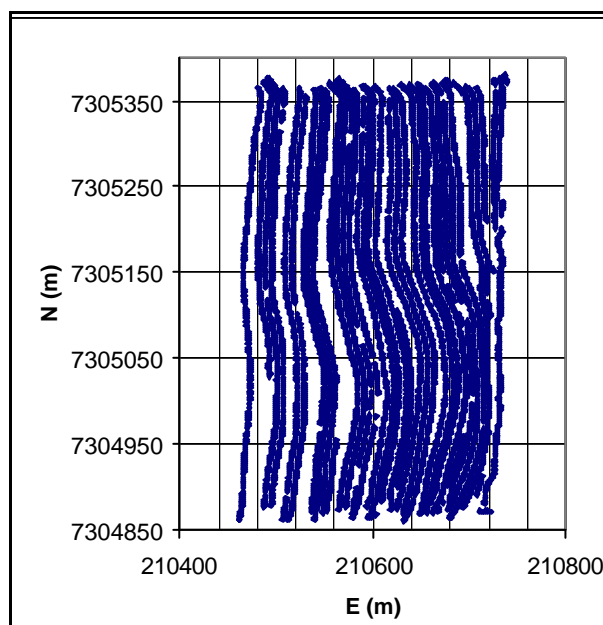


FIGURA 7.1 – POSIÇÕES DOS ELEMENTOS AMOISTRAIS DO PRIMEIRO EXPERIMENTO

7.2. Realização dos processos de Interpolação para o Experimento 1

Este experimento teve como objetivo principal analisar as possíveis vantagens entre os processos de interpolação por Krigagem Ordinária Isotrópica e Anisotrópica e Indicadora Isotrópica dos dados de interesse para a agricultura de precisão. Os dados coletados da colheita de um campo experimental de 500 x 270 m constituem um conjunto de 6609 elementos, como já dito anteriormente. Desse conjunto de dados foi extraído um outro conjunto com 119 elementos amostrais, com o objetivo de verificar a eficácia dos métodos em um conjunto limitado de amostras. Adotou-se o procedimento de amostragem sistemática não-alinhada ou regular estratificada por adequar-se melhor ao conjunto de dados disponível.

O conjunto amostral completo, com 6609 elementos amostrais, mostrado na figura 7.1 foi reduzido para um conjunto menor, com apenas 119 elementos, mostrados na figura 7.2. O primeiro foi usado como referência para comparação dos resultados obtidos nos processos de Krigagem Ordinária Isotrópica e Anisotrópica e Krigagem Indicadora.




FIGURA 7.2 – SUBCONJUNTO DE AMOSTRAS ESTRATIFICADAS

O rendimento da cultura constitui um indicador da interação das variáveis que podem limitá-lo. Assim, na agricultura de precisão as regiões que devem ser analisadas com maior grau de detalhamento devem ser aquelas cujo rendimento possa ser considerado baixo. Essa simplificação é realizada em função da elevada complexidade relacionada com tal diagnóstico. Com base nessas considerações, foi proposto um mapeamento do rendimento da soja em três classes procurando evitar um elevado grau de detalhamento temático incompatível com a complexidade da análise do mapa.

A fim de gerar um produto que possa servir como referência, é necessário que os dados da amostra completa sejam representados numa matriz de dimensões iguais aquelas produzidas nos processos de krigagem avaliados. Tal matriz possui resolução espacial de 5 por 5 m. Essa dimensão é compatível com a acurácia média esperada dos dados de posição fornecidos pela tecnologia WADGPS (*Wide Area Differential Global Positioning System*), geralmente adotado na agricultura de precisão.

Foi realizada uma interpolação pelo método inverso do quadrado da distância, utilizando o conjunto amostral completo, o qual é mostrado na figura 7.3, gerando a verdade terrestre. O motivo pelo qual utilizou-se outro método de interpelação e não o da krigagem, é devido ao fato dos métodos de krigagem não possibilitarem interpolações com um excessivo número de amostras. Ressaltando que a unidade de medida dos dados de rendimento é quilograma/hectare.




FIGURA 7.3 – INTERPOLAÇÃO DO CONJUNTO TOTAL DE ELEMENTOS AMOSTRAIS

7.2.1. Análise Exploratória do Subconjunto de Dados Amostrais

Após a extratificação do conjunto total, gerando um subconjunto com menor número de elementos amostrais (119), foi realizada uma análise exploratória dos dados utilizando o software SPIRNG 3.6.03 e o software VarioWin, somente para a obtenção do semivariograma de superfície.

A primeira etapa da análise exploratória é a geração de um histograma dos dados, para verificar a distribuição das amostras, como é mostrado na figura 7.4.




FIGURA 7.4 – HISTOGRAMA DOS DADOS DO SUBCONJUNTO DE ELEMENTOS AMOSTRAIS DE RENDIMENTO

Pode-se observar que os dados não possuem uma distribuição “muito” normal. Essa afirmação pode ser melhor observada no gráfico de aderência dos dados à curva normal, mostrada na figura 7.5.




FIGURA 7.5 – GRÁFICO DE ADERÊNCIA DOS DADOS

Para visualizar melhor a variabilidade dos dados e seu comportamento anisotrópico foi gerado um semivariograma de superfície, no VarioWin, mostrado na figura 7.6, enquanto que na figura 7.7 são indicadas as convenções utilizadas em geoestatística.




FIGURA 7.6 – SEMIVARIOGRAMA DE SUPERFÍCIE




FIGURA 7.7– CONVENÇÕES GEOMÉTRICAS UTILIZADAS EM GEOESTATÍSTICA

Por meio do semivariograma de superfície e da figura 7.7 pode-se notar que a maior continuidade está presente na direção de 0° a 180° (norte-sul) e a de menor na direção de 90° a 270° (leste-oeste).

7.2.2. Krigagem Ordinária Isotrópica (KOI)

Os semivariogramas teóricos utilizados no processo de KOI, assim como os parâmetros de efeito pepita, alcance, patamar e contribuição encontrados na modelagem desses semivariogramas, foram obtidos utilizando o software VarioWin 2.2. Porém, o processo de KOI foi realizado utilizando o software Spring 3.6.03.

Na krigagem isotrópica o grau de correlação só varia com a distância sendo, portanto, similar para qualquer direção. Por isso é gerado somente um semivariograma, mostrado na figura 7.8, para a direção de 1,5°, que foi a direção de maior continuidade.




FIGURA 7.8 – SEMIVARIOGRAMA PARA A DIREÇÃO DE MAIOR CONTINUIDADE

Para realizar a interpolação limitou-se o raio na direção de maior continuidade, 1,5°, em 150 m e na direção ortogonal a 50 m. O número máximo de elementos utilizados em cada interpolação foi limitado em 5, enquanto admitiu-se um único elemento como sendo mínimo necessário para realizar a interpolação. Decidiu-se evitar um número máximo maior a fim de diminuir o efeito de suavização e por realizar

a interpolação com um único elemento para diminuir o risco de células não interpoladas. As limitações impostas pelos raios máximos e mínimos, introduzem um fator de anisotropia na realização do processo final de interpolação.

O resultado da interpolação e o mapa de variância da krigagem obtidos pelo método de KOI podem ser observados nas figuras 7.9 e 7.10, respectivamente, assim como seus valores de rendimento máximo e mínimo, em kg / há. Na figura 7.10 pode-se observar que a variância é menor onde estão localizadas as amostras.




FIGURA 7.9 – INTERPOLAÇÃO POR KRIGAGEM ORDINÁRIA ISOTRÓPICA





FIGURA 7.10 – MAPA DE VARIÂNCIA DA KRIGAGEM ORDINÁRIA ISOTRÓPICA

7.2.3. Krigagem Ordinária Anisotrópica (KOA)

No processo de interpolação por KOA considera-se as variações do grau de correlação conforme a distância e a direção. Por isso, são identificadas as direções de maior e menor alcance, ou seja, as direções que possuem maior e menor dependência espacial. Uma análise dos semivariogramas de superfície mostrou que os raios máximo e mínimo são, respectivamente, 110 e 62 m. Posteriormente, são

modelados e ajustados os semivariogramas para ambas as direções. Nesse estudo de caso, ressalta-se que o alcance na direção ortogonal àquela de maior continuidade é muito menor que o alcance na direção de maior continuidade, devido à alta variação que ocorre entre as linhas. Isso pode ser verificado observando-se as figuras 7.6 e 7.7 apresentados anteriormente.

Os semivariogramas para as direções de maior e menor alcances podem ser observados nas figuras 7.11 e 7.12.



Os parâmetros obtidos por meio da modelagem dos semivariogramas mostrados nas figuras anteriores são dados na Tabela 7.1.

TABELA 7.1 – PARÂMETROS DOS SEMIVARIOGRAMAS DE MAIOR E MENOR ALCANCE

	Direção de Maior Alcance (1,5°)	Direção de Menor Alcance (92,5°)
Modelo	Gaussiano	Gaussiano
Efeito Pepita (C_0)	62	93
Alcance	105,4	76
Patamar	372	2294
Contribuição (C_1)	310	2201

Em seguida é feita a modelagem da anisotropia, que consiste em unir os dois modelos definidos, num único modelo consistente, o qual descreve a variabilidade espacial do fenômeno em qualquer direção.

A anisotropia é modelada de forma iterativa, dividindo em faixas convenientes o gráfico de semivariogramas de modo que, em cada faixa, reste somente a anisotropia geométrica. A figura 7.13 mostra a modelagem da anisotropia e a tabela 7.2 mostra os parâmetros obtidos para o modelo aninhado.

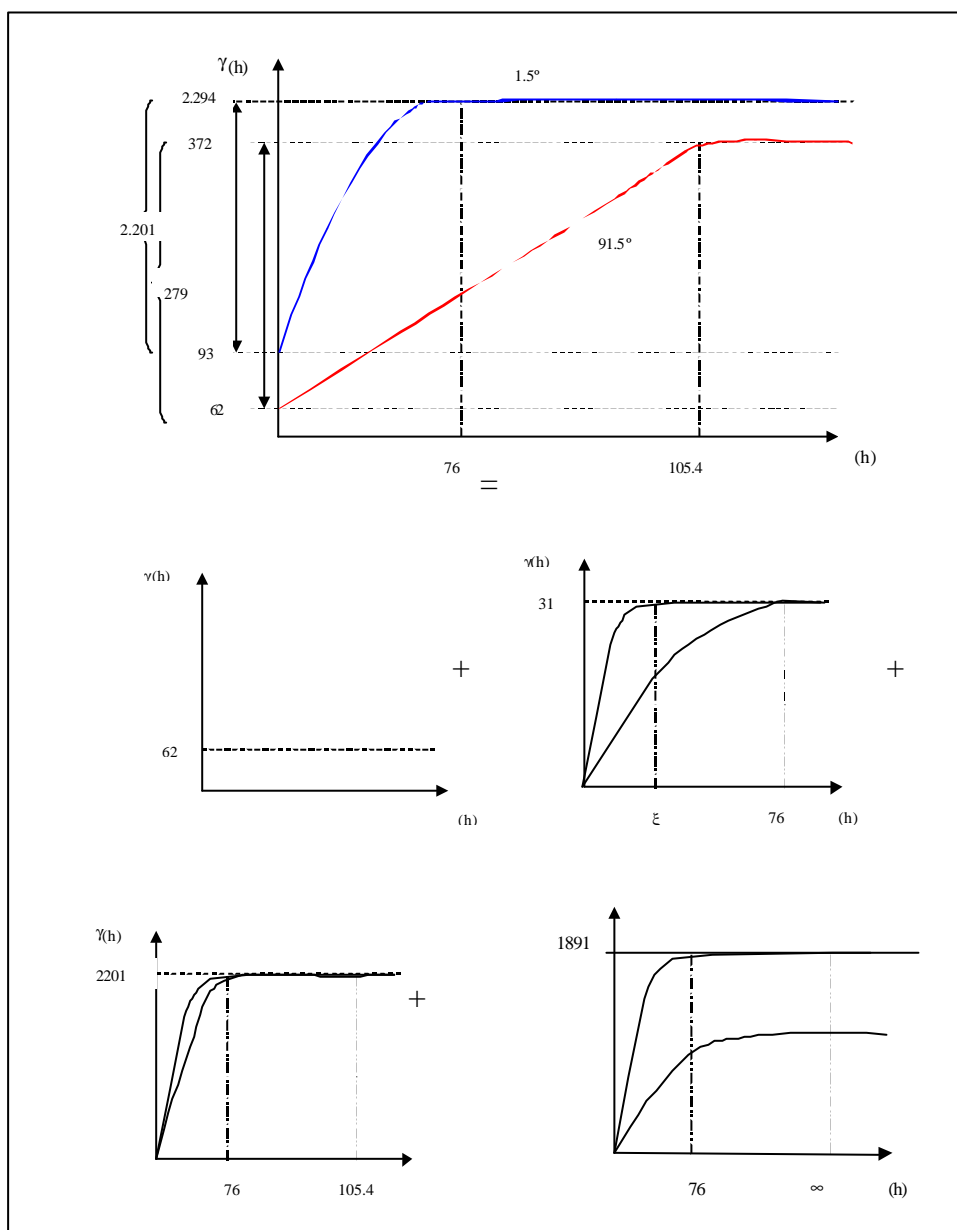


FIGURA 7.13 – MODELAGEM DA ANISOTROPIA

TABELA 7.2- PARÂMETROS DO SEMIVARIOGRAMA ANINHADO

Número de Estruturas		3	
Efeito Pepita		62	
Primeira Estrutura – Tipo: Gaussiana			
Contribuição	31	Ângulo de Anisotropia	1,5°
Alcance Mínimo	$\varepsilon = 0,00001$	Alcance Máximo	76
Segunda Estrutura – Tipo: Gaussiana			
Contribuição	2201	Ângulo de Anisotropia	1,5°
Alcance Mínimo	76	Alcance Máximo	105,4
Terceira Estrutura – Tipo: Gaussiana			
Contribuição	1891	Ângulo de Anisotropia	1,5°
Alcance Mínimo	105,4	Alcance Máximo	$\infty=100000$

A partir da decomposição gráfica anterior, define-se o modelo aninhado como mostra a equação (7.1):

$$g(h) = 62 + 3 \left[\text{Gau} \left(\sqrt{\left(\frac{h_{4,5^\circ}}{e} \right)^2 + \left(\frac{h_{9,15^\circ}}{76} \right)^2} \right) \right] + 220 \left[\text{Gau} \left(\sqrt{\left(\frac{h_{1,5^\circ}}{76} \right)^2 + \left(\frac{h_{9,15^\circ}}{105,4} \right)^2} \right) \right] + 189 \left[\text{Gau} \left(\sqrt{\left(\frac{h_{4,5^\circ}}{105,4} \right)^2 + \left(\frac{h_{9,15^\circ}}{\infty} \right)^2} \right) \right] \quad (7.1)$$

O resultado da interpolação e o mapa de variância da krigagem obtidos pelo método de KOA utilizando o software SPRING 3.6.03 podem ser observados nas figuras 7.14 e 7.15, respectivamente. De acordo com a figura 7.15, pode-se notar que a variância da krigagem é maior que a obtida no processo anterior, mas ainda apresenta valores menores próximos às localizações dos elementos amostrais.




FIGURA 7.14 - INTERPOLAÇÃO POR KRIGAGEM ORDINÁRIA ANISOTRÓPICA




FIGURA 7.15 – MAPA DE VARIÂNCIA DA KRIGAGEM ORDINÁRIA ANISOTRÓPICA

7.2.4. Krigagem Indicadora Isotrópica (KII)

No processo de KII, são definidos diversos cortes. No caso deste experimento, para o rendimento da cultura de soja foram definidos 10 cortes, gerando os semivariogramas para 9 deles, pois o valor máximo dos elementos amostrais já é atingido nesse corte, sendo que o décimo compreende a amostra completa e é, portanto, constituído somente de valores codificados como 1. O comportamento desses semivariogramas podem ser observados nas figuras 7.16 a 7.24.




FIGURA 7.16 - CORTE 1




FIGURA 7.17 - CORTE 2




FIGURA 7.18 - CORTE 3




FIGURA 7.19 - CORTE 4




FIGURA 7.20 - CORTE 5




FIGURA 7.21 - CORTE 6




FIGURA 7.22 - CORTE 7




FIGURA 7.23 - CORTE 8




FIGURA 7.24 - CORTE 9

Ajustando os semivariogramas para cada um dos cortes, obtêm-se os parâmetros mostrados na Tabela 7.3.

TABELA 7.3 – PARÂMETROS DE AJUSTE DOS SEMIVARIOGRAMAS

	Corte 1 – 3207.3804 – 3227.78007	Corte 2 – 3227.78007 – 3248.1797
Direção	Omnidirecional	Omnidirecional
Efeito Pepita	0,008	0,012
Modelo	Esférico	Esférico
Alcance	32,2	111,8
Patamar	0,084	0,132
Contribuição	0,076	0,12
	Corte 3 – 3248.179 – 3268.57941	Corte 4 - 3268.57941 – 3288.97908
Direção	Omnidirecional	Omnidirecional
Efeito Pepita	0,012	0,00299
Modelo	Esférico	Esférico
Alcance	134,4	240
Patamar	0,154	0,279
Contribuição	0,142	0,2761
	Corte 5 – 3288.97908 - 3309.37875	Corte 6 – 3309.37875 – 3329.77842
Direção	Omnidirecional	Omnidirecional
Efeito Pepita	0,009	0,039
Modelo	Esférico	Esférico
Alcance	238	217,6
Patamar	0,273	0,246
Contribuição	0,264	0,207
	Corte 7 – 3329.77842 – 3350.17809	Corte 8 - 3350.17809 – 3370.57776
Direção	Omnidirecional	Omnidirecional
Efeito Pepita	0,05999	0,022
Modelo	Esférico	Esférico
Alcance	233,6	62,4
Patamar	0,204	0,086
Contribuição	0,14401	0,064
	Corte 9 – 3370.57776 – 3390.97743	
Direção	Omnidirecional	
Efeito Pepita	0,0003	
Modelo	Esférico	
Alcance	50,4	
Patamar	0,0276	
Contribuição	0,0273	

Utilizando os parâmetros da Tabela 7.3 é realizado o processo de KII.

O resultado do processo de KII é mostrado na figura 7.25, assim como o mapa de incerteza gerado durante o processo na figura 7.26.




FIGURA 7.25 - INTERPOLAÇÃO POR KRIGAGEM INDICADORA ISOTRÓPICA




FIGURA 7.26 – MAPA DE INCERTEZA DA KRIGAGEM INDICADORA ISOTRÓPICA

7.2.5. Análise dos Resultados Obtidos pelos Processos de Interpolação do Experimento 1

Como produto final dos processos de interpolação por krigagem, foram gerados três mapas temáticos: KOI, KOA e KII, respectivamente, os quais são mostrados nas figuras 7.27, 7.28 e 7.29 e utilizam os mesmos intervalos adotados para a geração do mapa de verdade terrestre gerado com base no resultado da interpolação com o conjunto total de elementos, mostrado na figura 7.30. Os intervalos escolhidos foram: para a classe com baixo rendimento, 3207,3804 – 3275,3793 kg/ha; para classe de médio rendimento, 3275,3793 – 3343,3782 kg/ha e finalmente para a classe de alto rendimento, 3343,3782 – 3411,3771 kg/ha.




FIGURA 7.27 – MAPA TEMÁTICO DA KRIGAGEM ORDINÁRIA ISOTRÓPICA




FIGURA 7.28 - MAPA TEMÁTICO DA KRIGAGEM ORDINÁRIA ANISOTRÓPICA




FIGURA 7.29 - MAPA TEMÁTICO DA KRIGAGEM INDICADORA ISOTRÓPICA




FIGURA 7.30 – MAPA DO CONJUNTO TOTAL DE ELEMENTOS AMOSTRAIS

Numa primeira análise visual, pode-se comparar os tres mapas temáticos gerados pelos métodos de krigagem com o mapa temático de referência apresentado na figura 7.30. Tendo em vista que, dos 6609 elementos amostrais, foram usados apenas 119, pode-se concluir, que os resultados obtidos pelos processos de krigagem são bastante satisfatórios.

Após a geração dos mapas temáticos, realizou-se a tabulação cruzada entre o mapa de referência e os mapas gerados pelos processos de krigagem, sendo que esse processo faz uma verificação célula a célula, isto é, quais foram classificadas coincidentemente e quais foram classificadas incorretamente, fornecendo matrizes de confusão proporcional. As Tabelas 7.4, 7.5 e 7.6 mostram as matrizes resultantes da comparação entre a verdade terrestre e os processos de KOI, anisotrópica e KII respectivamente. Nas colunas estão as proporções dos pixels classificados na imagem de referência e nas linhas as proporções dos pixels nas imagens obtidas pelos diversos processos de krigagem.

A partir da matriz de confusão pode-se calcular os erros de inclusão e de omissão para cada imagem resultante dos processos de krigagem realizados. O erro de inclusão é obtido a partir da razão entre a soma das proporções dos pixels incorretamente classificados como pertencentes a classe “n” e o total da soma das proporções associadas à mesma classe. Por outro lado, o erro de omissão para essa mesma classe é estimado pela razão entre a soma das proporções dos pixels incluídos nas demais classes, mas que na realidade são da classe “n”, pelo total da soma das proporções dos pixels corretamente associados à classe “n”.

A Tabela 7.4 apresenta a matriz de confusão para a KOI. A classe “0” que aparece nas tabelas a seguir representa os locais nos mapas interpolados que não foram classificados. Esses locais aparecem em “branco” nos mapas das figuras 7.27, 7.28 e 7.29, e correspondem à áreas muito pequenas.

TABELA 7.4 – MATRIZ DE CONFUSÃO PARA KRIGAGEM ORDINÁRIA ISOTRÓPICA

		Imagem de Referência				
		0	1	2	3	Total
Classificação	1	0,0000	0,3101	0,0539	0,0000	0,3640
	2	0,0000	0,0917	0,2971	0,0067	0,3955
	3	0,0002	0,0000	0,0406	0,1997	0,2405
	Total	0,0002	0,4018	0,3917	0,2064	1,0000

Os resultados da tabela 7.4, para KOI, mostram que a classe crítica para o diagnóstico em agricultura de precisão, classe 3 de baixo rendimento, apresentou erro de inclusão de 16,9 % e erro de omissão de 3,2 %. Pode-se dizer que esses erros são aceitáveis para os propósitos da agricultura de precisão. O erro de omissão, o qual é considerado o mais grave, pois nesse caso a área omitida não é considerada na análise do produto final, é baixo.

A tabela 7.5 apresenta a matriz de confusão para a KOA.

TABELA 7.5 - MATRIZ DE CONFUSÃO PARA KRIGAGEM ORDINÁRIA ANISOTRÓPICA

		Imagem de Referência				Total
		0	1	2	3	
Classificação	0	0,0000	0,0009	0,0000	0,0000	0,0009
	1	0,0002	0,3502	0,0785	0,0000	0,4289
	2	0,0000	0,0511	0,2664	0,0026	0,3202
	3	0,0002	0,0000	0,0451	0,2047	0,2500
	Total	0,0004	0,4023	0,3900	0,2074	1,0000

A tabela 7.5 mostra que os resultados obtidos KOA são os melhores dentre os três processos. O erro de inclusão é de 18,1 % e o erro de omissão é de 1,2 % que é menor que o obtido no processo anterior.

E por fim, a tabela 7.6 apresenta a matriz de confusão para a KII.

TABELA 7.6 - MATRIZ DE CONFUSÃO PARA KRIGAGEM INDICADORA ISOTRÓPICA

		Imagem de Referência				Total
		0	1	2	3	
Classificação	0	0,0000	0,0000	0,0017	0,0000	0,0017
	1	0,0000	0,3467	0,0713	0,0000	0,4180
	2	0,0000	0,0551	0,2521	0,0006	0,3078
	3	0,0002	0,0000	0,0665	0,2058	0,2725
	Total	0,0002	0,4018	0,3917	0,2064	1,0000

Neste caso, o erro de omissão da classe 3 é o menor dentre os processos comparados, sendo ele de 0,29 %. Apesar do erro de inclusão ser de 24,4 % contra 16,9 % e 18,1 % dos processos anteriores de KOI e anisotrópica, respectivamente, esse tipo de erro não compromete, em excesso, o diagnóstico da

situação do sistema produtivo. Nesse estudo de caso, a área total é de 13,5 ha e a área incluída como sendo baixo rendimento da soja de 0,89 ha.

Na Tabela 7.7 são mostrados os valores do índice kappa, calculados para cada um dos processos de krigagem.

TABELA 7.7 – ÍNDICE DE CONCORDÂNCIA KAPPA

	KOI	KOA	KII
Kappa	70,26 %	72,54 %	70,19 %

Observa-se, na tabela 7.7, que os índices de concordância kappa indicam que os resultados da KOA foram os melhores deste estudo de caso. Entretanto, as pequenas diferenças obtidas demonstram que a escolha do melhor processo de interpolação deve se basear em outro critério, como por exemplo, a questão da complexidade para realização de tais processos. O processo mais simples foi o de krigagem ordinária isotrópica e o mais complexo o de krigagem ordinária anisotrópica.

7.3. Coleta dos Dados de Rendimento e das Imagens para o Segundo Experimento – Londrina - PR

Neste experimento, inicialmente, o objetivo era realizar um vôo, no qual seriam obtidas as imagens utilizadas no processo de cokrigagem, além disso a área a ser utilizado seria bem maior e os dados seriam coletados com o auxílio de uma colhedeira como no primeiro experimento. Mas, infelizmente isso não foi possível devido à falta de recursos financeiros, os quais foram reduzidos justamente na época da realização do trabalho de campo para a obtenção dos dados. Então, para que o processo de cokrigagem pudesse ser realizado, a única solução encontrada foi realizar o levantamento de campo na área então disponibilizada pela EMBRAPA. E para simular

o vôo foi utilizada uma plataforma terrestre na qual foi adaptado um suporte sobre o qual a câmara foi acoplada.

Então, foram coletados elementos amostrais de seis linhas de plantio da soja, o que corresponde a aproximadamente 2,70 m de largura, com duas fileiras de 19 pontos conhecidos, espaçados entre si de 3 m em 3 m, o que soma aproximadamente 57 m de comprimento, totalizando uma área de 153,9 m². As linhas de plantio foram divididas em quadros de aproximadamente 1 m por 1m, onde foram colhidas e pesadas as amostras de rendimento da soja. As coordenadas para cada uma dessas áreas amostrais foram coletadas utilizando como referência a posição de uma estaca a qual foi coletada com um receptor GPS, procedimento descrito nos próximos itens.

Além dos elementos amostrais do rendimento, foram adquiridas também imagens da área utilizando o Sistema de Aquisição de Imagens, descrito no item de Materiais e Métodos.

Como o segundo experimento é um tanto mais complexo que o primeiro será descrito em etapas.

7.3.1. Aquisição das Imagens

No levantamento de campo foram tomadas imagens da área descrita no item anterior, com estacas colocadas de 1,5 m em 1,5 m, no sentido do comprimento, identificadas por plaquetas com números, para facilitar a identificação dos pontos durante o processo de georreferenciamento. Foram adquiridas imagens das seis linhas de plantio, como mostra a figura 7.31.



FIGURA 7.31 – ÁREA IMAGEADA

Foram obtidas no total 180 imagens, para garantir o recobrimento de toda área e ainda uma sobreposição longitudinal de 30 %, de forma que, em cada imagem, estivessem contidos no mínimo quatro pontos sinalizados e que, desses quatro, pelo menos dois fossem repetidos na imagem seguinte. Das 180 imagens foram selecionadas somente 30, pois várias delas recobriam a mesma área do terreno, ou seja, eram repetidas, assim não fizeram falta no processo fotogramétrico. As imagens foram obtidas com uma resolução espacial aproximada de 0,05 m ou 5 cm.

7.3.2. Levantamento Geodésico e Coleta dos Dados de Rendimento

No levantamento geodésico do segundo experimento foi realizada a implantação de um ponto de coordenada conhecida, a partir do transporte de coordenadas, utilizando três bases de monitoramento contínuo pertencentes à rede RBMC. A área foi sinalizada com bambus, para simular uma linha de vôo.

O equipamento utilizado para o transporte de coordenadas, foi o receptor GPS de dupla frequência Astech ZXII, estacionado sobre um ponto escolhido na fazenda experimental da Embrapa Soja, localizada próxima à cidade de Londrina, no

estado do Paraná. O receptor foi configurado com taxa de coleta de 15 segundos, para que não houvesse problemas de memória do equipamento ao armazenar os dados coletados. Para o transporte foram escolhidas 3 bases, para que fosse feito o ajuste de uma rede geodésica e, com isso, garantir uma maior integridade ao ponto transportado. Assim, foram obtidos os dados GPS das bases UEPP (na cidade de Pres. Prudente/SP), Curitiba/PR e Viçosa/MG. Os dados GPS obtidos se encontram no formato RINEX. A coordenada do ponto transportado foi utilizada, posteriormente, para realizar o levantamento GPS dos pontos de sinalização, localizados sobre a plantação de soja.

Antes da realização do levantamento dos pontos a área foi sinalizada utilizando-se de estacas de bambu, como dito antes, acrescidas de placas de papelão numeradas. O objetivo da disposição das estacas era sinalizar a área a ser imageada para viabilizar a fototriangulação e o georreferenciamento.

A coleta de coordenadas geodésicas dos pontos foi realizada sobre as estacas fixadas na plantação de soja. Para a coleta dos pontos sobre as estacas foi utilizado o receptor *GPS 4600LS da Trimble*, com o coletor TDC dispondo a antena a uma altura de 1,70 m sobre o bambu. Como base, utilizou-se o receptor GPS de dupla frequência *Astech ZXII* localizado sobre o ponto transportado, a uma altura de 1,75 m do solo. Em ambos os aparelhos a altura da antena foi configurada como *True Vertical*, sendo a taxa de coleta configurada para 5 segundos. A figura 7.32 mostra a coleta das posições das estacas.



FIGURA 7.32 – LEVANTAMENTO DOS PONTOS COM O RECEPTOR GPS

Os dados de rendimento da soja foram obtidos por meio da divisão da área em outras pequenas áreas de cerca de 1 m². Dentro dessas pequenas áreas as plantas foram colhidas e seus grãos foram retirados e pesados, tendo-se assim o rendimento para cada uma dessas áreas. A posição desses dados de rendimento foi atribuída à coordenada da estaca numerada, referente ao local da colheita somada a determinadas distâncias, por exemplo para área (a), 1,35 m, para área (b), 2.67 m e para área (c) 4.06 m. A figura 7.33 mostra melhor esse processo.

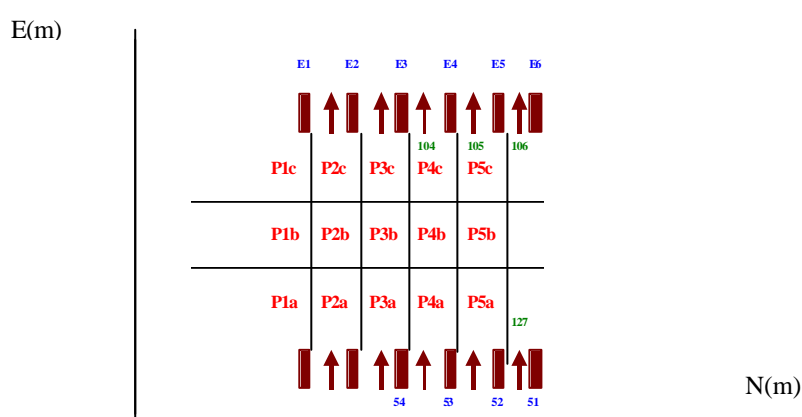


FIGURA 7.33 – CROQUI DO LEVANTAMENTO DOS DADOS DE RENDIMENTO

7.4. Processamento Digital das Imagens

Para garantir que as imagens tivessem as condições adequadas para serem utilizadas, as mesmas passaram por vários processamentos, os quais são descritos nos próximos itens.

7.4.1. Fototriangulação e Retificação das Imagens

As imagens selecionadas foram fototrianguladas utilizando um programa desenvolvido pelo Prof. Júlio K. Hasegawa, como está descrito no capítulo de Materiais e Métodos. Durante a fototriangulação foram identificados os pontos de controle nas imagens e suas coordenadas coletadas. Utilizando o programa especificado acima, foram obtidas as coordenadas dos centros perspectivos da câmera, as coordenadas corrigidas para os pontos de controle utilizados e os parâmetros kappa (k), ϕ (ϕ) e ω (ω), os quais corrigem a atitude da câmera no processo de retificação, deixando as imagens verticais, uma vez que as mesmas foram obtidas com a câmera posicionada num ângulo oblíquo, assumindo que o terreno é plano.

Os parâmetros obtidos no processo de fototriangulação foram utilizados para retificação das imagens. Utilizando a distância focal de 88,2272 mm, o tamanho do pixel (0,025 m) e os parâmetros k , ϕ e ω as imagens foram retificadas uma a uma. Porém, para que fosse viável a realização do processo de retificação foi necessário reduzir a resolução das imagens de 0,025 m para 0,05 m.

Nas figuras 7.34 e 7.35 pode ser notada a diferença entre uma imagem não retificada e uma imagem retificada, respectivamente. A figura 7.35 mostra o resultado da retificação para uma das imagens. Lembrando que as imagens mostradas

nas figuras 7.34 e 7.35 são as combinações das três bandas: infravermelho (Red), vermelho (Green) e verde (Blue).



FIGURA 7.34 – IMAGEM NÃO RETIFICADA




FIGURA 7.35 – IMAGEM RETIFICADA

7.4.2. Estimativa do Fator de Reflectância

As imagens devem ter sua reflectância transformada para fator de reflectância, considerando como referência o valor de radiância da placa de sulfato de bário utilizada durante as tomadas. Para isso será considerado o conceito descrito no item 6.2.2 do capítulo 6, assim como a equação (6.1) vista no mesmo capítulo.

Uma rotina desenvolvida em *Matlab*, um software utilizado para realização de processamento digital de imagens, retira os ruídos causados no processo de retificação, nesse caso, a partir da utilização de um filtro mediana. Então, são extraídas amostras referentes à placa, calcula-se a média desses valores e por fim é realizado o processo de estimativa do fator de reflectância para cada uma das bandas, separadamente. É necessário lembrar que a banda do verde foi descartada pelo fato de que no processo de geração da imagem razão ser utilizada a razão simples, a qual só utiliza as bandas do infravermelho próximo e do vermelho em sua composição matemática.

Para ilustrar melhor a seqüência do processo, um diagrama é mostrado na figura 7.36.

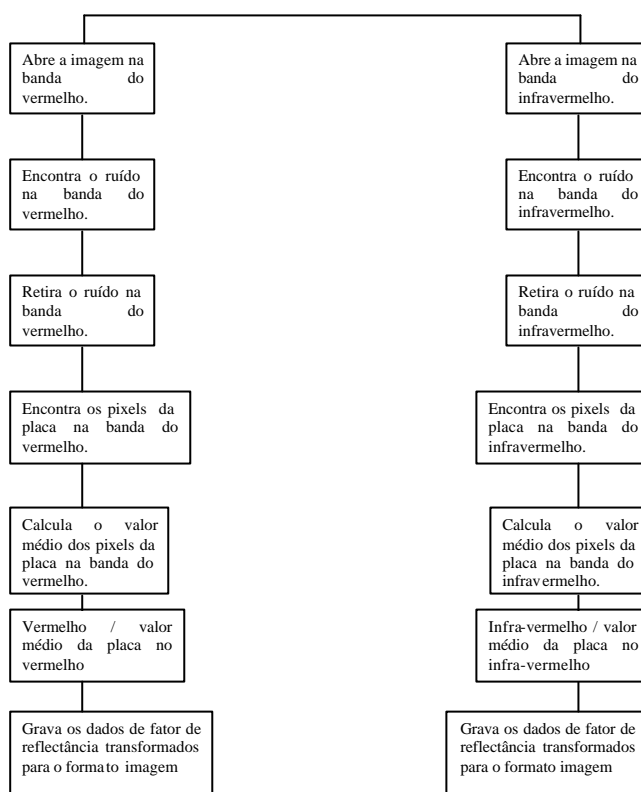


FIGURA 7.36 – DIAGRAMA DA ROTINA PARA TRANSFORMAÇÃO DAS IMAGENS

7.4.3. Normalização das Imagens

Durante a tomada das imagens ocorreram variações de ângulos de visada da câmara e, com isso, a resposta da vegetação para uma mesma imagem varia conforme aumenta a distância da visada da câmara, como mostra a figura 7.37.




FIGURA 7.37 – VARIAÇÃO DO ÂNGULO DE VISADA DA CÂMERA

Devido à essa variação foi necessário realizar o processo de normalização.

Para realizar a normalização das imagens foram extraídas a média e o desvio padrão de uma amostra dos fatores de reflectância em cada uma das cenas. As Tabelas 7.8 e 7.9 mostram os valores das médias e dos desvios padrão da amostra de cada cena nas bandas do vermelho e do infravermelho próximo respectivamente, considerando que os valores apresentados são inteiros. Na primeira coluna é mostrado o identificador das imagens, o qual foi atribuído pelo autor.

TABELA 7.8 – MÉDIA E DESVIO PADRÃO DOS FATORES DE REFLECTÂNCIA NA BANDA DO VERMELHO ANTES DA NORMALIZAÇÃO

IDENTIFICADOR DAS IMAGENS	MÉDIA	DESVIO-PADRÃO
30	0	2,21
38	0	2,03
42	0	1,76
45	0	2,18
49	0	2,02
53	0	2,64
64	0	2,02
67	0	1,85
73	0	1,77
74	0	1,79
79	0	1,90
88	8	3,75
95	8	3,56
99	0	1,51
108	0	1,64
112	0	1,46
115	0	1,27
118	0	1,81
119	0	1,37
123	8	3,54
127	7	3,08
131	8	3,32
137	0	1,38
142	0	1,14
145	7	3,23
148	8	3,93
155	7	3,20
158	8	3,37
162	7	3,37
165	7	3,39

Na tabela 7.8 é possível notar que existem algumas imagens na banda do vermelho, as quais possuem médias dos fatores de reflectância bem diferentes das demais, em torno de 8. Essa diferença nos valores das médias e dos desvios padrão, faz com que as imagens razão fiquem escuras.

TABELA 7.9 – MÉDIA E DESVIO PADRÃO DOS FATORES DE REFLECTÂNCIA NA BANDA DO INFRAVERMELHO ANTES DA NORMALIZAÇÃO

IDENTIFICADOR DAS IMAGENS	MÉDIA	DESVIO-PADRÃO
30	152	23,84
38	153	24,01
42	151	24,47
45	154	24,33
49	149	23,68
53	151	22,91
64	159	23,4
67	157	23,60
73	152	24,16
74	146	22,71
79	149	23,81
88	158	23,47
95	155	22,08
99	148	21,30
108	151	2254
112	138	21,15
115	142	21,88
118	153	21,35
119	145	22,65
123	168	23,95
127	147	20,88
131	170	23,67
137	144	22,47
142	140	21,35
145	150	20,73
148	157	22,02
155	146	20,11
158	148	20,15
162	147	21,16
165	144	21,50

Mesmo depois de realizada a normalização nas bandas, as imagens continuaram com média diferente e conseqüentemente a imagens razão continuaram escuras. Contudo, esse processamento deveria corrigir as variações na resposta espectral das imagens, deixando-as todas padronizadas. Todas as imagens deveriam ter um comportamento similar no histograma, ou seja, um comportamento padrão para as

imagens na banda do vermelho e um outro comportamento para as imagens na banda do infravermelho. Não entanto, isso não ocorreu para todas as imagens, devido ao deslocamento na posição da câmara durante a tomada resultar em estimativas do fator de reflectância cujas variações não são lineares.

Através da análise dos valores médios, antes da normalização, pode-se concluir que o deslocamento da câmara em alguns locais, causou um aumento nos fatores de reflectância na banda do vermelho, o qual o modelo de normalização (linear) não conseguiu representar.

Para avaliar o problema, foram gerados os histogramas para todas as imagens, tanto para as imagens obtidas sem a variação de ângulo quanto para as obtidas com variação de ângulo, somente na banda do vermelho, a qual apresentou problemas. Verificou-se que, os histogramas para as imagens sem variação de ângulo apresentavam um tipo de comportamento e outro comportamento era percebido para as imagens com variação de ângulo. As figuras 7.38 e 7.39 mostram o histograma, somente para a área de vegetação, para uma das imagens claras e para uma das imagens escuras, respectivamente.




FIGURA 7.38 – HISTOGRAMA PADRÃO DAS IMAGENS SEM VARIAÇÃO DE ÂNGULO




FIGURA 7.39 – HISTOGRAMA PADRÃO DAS IMAGENS COM VARIAÇÃO DE ÂNGULO

Como é possível observar nos histogramas, os valores de brilho na banda do vermelho para o conjunto de imagens com ângulo de visada θ_1 (ângulo de

visada determinado pela configuração correta), estão concentrados em sua maioria no valor 0 (zero) e alguns no valor 12. Enquanto que para a banda do vermelho, no conjunto de imagens com ângulo de visada θ_2 (ângulo de visada decorrente do balanço da câmara no suporte), o histograma tem um comportamento bem diferente; os valores estão distribuídos entre o valor 0 (zero) e o 16, com a maior parte dos valores concentrados no 9. Os ângulos θ_1 e θ_2 , podem ser observados na figura 7.37. Os histogramas mostrados nas figuras 7.38 e 7.39, apresentam os valores do eixo x com uma diferença de escala, eles deveriam ser de 0 – 255, porém esse equívoco ocorre devido as configurações do *Matlab*.

A solução, então, encontrada para resolver esse problema foi aplicar uma translação dos valores de fator de reflectância (*offset*) em todos os valores da área de vegetação, fazendo assim com que os histogramas das imagens com ângulo θ_2 ficassem semelhantes aos das imagens com ângulo θ_1 . A figura 7.40 mostra o histograma de uma imagem com variação de ângulo após o processamento.




FIGURA 7.40 – HISTOGRAMA DA IMAGEM CORRIGIDA

Depois de realizado o deslocamento do histograma para as imagens adquiridas com ângulo indesejável, o processo de normalização foi realizado para as duas bandas, obtendo-se um resultado bastante satisfatório, como mostram as Tabelas 7.10 e 7.11 para as bandas do vermelho e do infravermelho respectivamente.

Lembrando que, no processo de normalização, a imagem utilizada como referência foi a imagem 30, por esta apresentar maior contraste, o que leva a um melhor resultado, de acordo com Galo (2000).

TABELA 7.10 – MÉDIA E DESVIO PADRÃO DOS FATORES DE REFLECTÂNCIA PARA A BANDA DO VERMELHO DEPOIS DA NORMALIZAÇÃO

IDENTIFICADOR DAS IMAGENS	MÉDIA	DESVIO-PADRÃO
30	0	2,15
38	0	2,13
42	0	2,15
45	0	2,10
49	0	2,16
53	0	2,18
64	0	2,07
67	0	2,15
73	0	2,07
74	0	2,06
79	0	2,03
88	0	2,13
95	0	2,13
99	0	2,04
108	0	2,18
112	0	2,15
115	0	2,12
118	0	2,08
119	0	2,14
123	0	2,08
127	0	2,13
131	0	2,20
137	0	2,17
142	0	2,18
145	0	2,14
148	0	2,24
155	0	2,26
158	0	2,21
162	0	2,12
165	0	2,13

TABELA 7.11 – MÉDIA E DESVIO PADRÃO DOS FATORES DE REFLECTÂNCIA PARA A BANDA DO INFRAVERMELHO DEPOIS DA NORMALIZAÇÃO

IDENTIFICADOR DAS IMAGENS	MÉDIA	DESVIO-PADRÃO
30	152	23,80
38	152	23,55
42	152	23,80
45	152	23,87
49	152	24,02
53	152	23,75
64	152	24,28
67	152	23,95
73	152	23,45
74	152	23,73
79	152	24,46
88	152	24,05
95	152	23,80
99	152	24,26
108	152	23,87
112	152	24,11
115	152	23,65
118	152	23,73
119	152	23,63
123	152	23,04
127	152	23,74
131	152	24,11
137	152	23,50
142	152	23,49
145	152	23,99
148	152	23,48
155	152	23,80
158	152	23,76
162	152	23,63
165	152	23,74

O deslocamento do histograma foi necessário, pois a normalização é linear, assim não conseguiu modelar o movimento involuntário da câmara (decorrente do balanço da câmara no suporte), que neste caso provocou uma transformação mais complexa nos valores de fator de reflectância da vegetação (plantas de soja).

Após todos os processamentos realizados anteriormente, gerou-se a razão simples para cada cena. A figura 7.41 mostra o resultado da razão obtido para uma das cenas.




FIGURA 7.41 – RESULTADO DA RAZÃO DE BANDAS PARA UMA DAS IMAGENS

7.4.4. Georreferenciamento e Geração do Mosaico

Nesta etapa do trabalho novamente foi necessário realizar uma reamostragem das imagens, de 0,05 m para 0,1 m, ou seja, as imagens ficaram com uma resolução espacial de aproximadamente 10 cm no terreno.

As imagens da razão, obtidas no item anterior, foram georreferenciadas (ou registradas) utilizando o software SPRING 3.6.03, desenvolvido pelo Instituto Nacional de Pesquisas Espaciais – INPE e disponibilizado gratuitamente na internet.

Para o georreferenciamento das imagens foram utilizados os pontos de controle coletados em campo, como já descrito anteriormente. O processo teve um resultado aparentemente bom, pois sua precisão foi de ± 20 cm. Tal resultado pode ser considerado preciso, pois as áreas de cada elemento amostral coletadas do campo de soja são de 1 m² aproximadamente, assim um erro de 20 cm é tolerável. Além disso a agricultura de precisão, não exige precisão milimétrica.

Depois do georreferenciamento, foi realizada a geração de um mosaico, também utilizando o software SPRING 3.6.03.

O resultado do mosaico, utilizando as imagens razão simples, é mostrado na figura 7.42.




FIGURA 7.42 – MOSAICO COM AS IMAGENS RAZÃO SIMPLES

Depois de construído o mosaico, foi realizado um perfil para verificar se todas as imagens possuíam realmente o mesmo padrão radiométrico, como mostra a figura 7.43. Através da figura 7.43, pode-se notar que as imagens possuem em média os mesmos valores de brilho, sem levar em consideração as eventuais variações bruscas, as quais são decorrentes dos valores de brilho onde estão localizados alguns ruídos e as pessoas que seguravam a placa de sulfato de bário, como pode ser visto na figura 7.42.

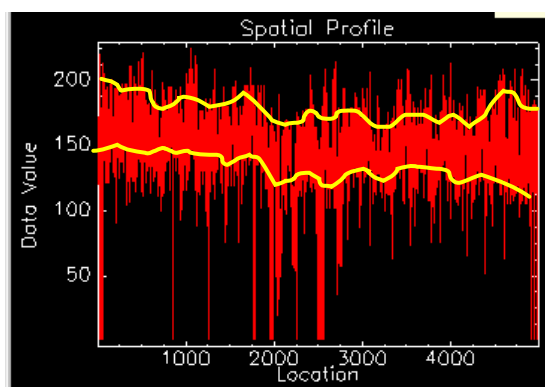


FIGURA 7.43 – PERFIL DO MOSAICO NORMALIZADO

7.5. Realização dos processos de Interpolação para o Experimento 2

No segundo experimento a área foi consideravelmente menor que a do primeiro experimento. O total de elementos amostrais utilizados para a realização dos processos de interpolação foi bastante reduzido, cerca de 57 elementos amostrais, como mostrado na figura 7.44. Desse total foram extraídos 24 elementos amostrais utilizando o método de amostragem regular estratificada, ou seja, pouco mais que 1/3 da amostra total, mostrada na figura 7.45. Neste experimento o objetivo é comparar os resultados obtidos nos processos de krigagem com um número reduzido de amostras, com os obtidos no processo de cokrigagem, utilizando dados de imagens multiespectrais como informações adicionais.




FIGURA 7.44 – CONJUNTO TOTAL DE ELEMENTOS AMOSTRAIS




FIGURA 7.45 – SUBCONJUNTO DE ELEMENTOS AMOSTRAIS

A representação na forma de matriz regular foi obtida pela aplicação do método do inverso do quadrado da distância aplicado nos dados da amostra completa como é mostrado na figura 7.46. O método de krigagem não foi utilizado por este não possibilitar a interpolação de dados utilizando um número excessivo de amostras.




FIGURA 7.46 – INTERPOLAÇÃO DO CONJUNTO TOTAL DE ELEMENTOS AMOSTRAIS

7.5.1. Análise Exploratória do Subconjunto de Amostras

Para avaliar o comportamento do subconjunto dos elementos amostrais, realizou-se uma análise exploratória, com a construção de um histograma e de um gráfico de probabilidade normal, mostrados nas figuras 7.47 e 7.48, respectivamente.




FIGURA 7.47 – HISTOGRAMA




FIGURA 7.48 – GRÁFICO DA PROBABILIDADE NORMAL

Como no primeiro experimento, pode ser notado que a aderência dos dados à curva normal não é muito boa.

Os gráficos das figuras 7.49 e 7.50 mostram que os dados possuem um comportamento anisotrópico, como pode ser visto no semivariograma de superfície.




FIGURA 7.49 – SEMIVARIOGRAMA DE SUPERFÍCIE




FIGURA 7.50 – CONVENÇÕES GEOMÉTRICAS UTILIZADAS EM GEOESTATÍSTICA

O semivariograma de superfície mostra que tal conjunto de dados contribuirá pouco para a modelagem dos dados e os processos de interpolação, visto que os menores valores de variografia estão presentes somente nas extremidades, será difícil encontrar uma direção onde os dados tenham uma alta correlação. Isso porque, quanto maior a correlação entre os elementos amostrais próximos do ponto a ser interpolado, menor o valor de variografia.

7.5.2. Krigagem Ordinária Isotrópica (KOI)

Neste processo é gerado somente um semivariograma, pois nessa abordagem o grau de correlação pode variar somente com a distância e não com a direção. O semivariograma foi gerado para a direção de maior alcance, 10°, mostrado na figura 7.51.




FIGURA 7.51 – SEMIVARIOGRAMA PARA A DIREÇÃO DE MAIOR ALCANCE

Os parâmetros obtidos com o ajuste do semivariograma são mostrados na Tabela 7.12.

	Direção de Maior Alcance (10°)
Modelo	Esférico
Efeito Pepita (C_0)	88800
Alcance	12,65
Patamar	310800
Contribuição (C_1)	222000

Para realizar a interpolação, foi utilizado um número mínimo de 1 e máximo de 3 pontos no elipsóide de busca. Os raios máximos e mínimos de busca utilizados foram de 10, na direção de maior continuidade e de 6, na direção perpendicular a mesma, sendo que isso insere um fator de anisotropia no processo isotrópico.

O resultado do processo de interpolação é ilustrado na figura 7.52 e o respectivo mapa de variância da krigagem na figura 7.53.




FIGURA 7.52 – KRIGAGEM ORDINÁRIA ISOTRÓPICA




FIGURA 7.53 – MAPA DE VARIÂNCIA DA KRIGAGEM ORDINÁRIA ISOTRÓPICA

7.5.3. Krigagem Ordinária Anisotrópica (KOA)

No processo de KOA, além de variar com a distância a correlação pode variar com a direção, sendo necessário gerar semivariogramas para as direções de maior e menor alcances. Devido ao número limitado de elementos amostrais foi difícil perceber qual a direção de anisotropia, analisando somente o semivariograma de superfície. Porém, os resultados da interpolação por KOI indicam que, a direção de maior continuidade já foi identificada como, 10° , sabe-se então, que a direção de menor continuidade é a perpendicular a ela. Portanto a direção de menor continuidade é aproximadamente 100° . Gerando diversos semivariogramas, conclui-se que, a direção de menor alcance é mais precisamente 106° .

Os semivariogramas gerados para ambas as direções são ilustrados nas figuras 7.54 e 7.55.




FIGURA 7.54 – SEMIVARIOGRAMA PARA A DIREÇÃO DE MAIOR ALCANCE




FIGURA 7.55 – SEMIVARIOGRAMA PARA A DIREÇÃO DE MENOR ALCANCE

Os parâmetros obtidos com o ajuste dos semivariogramas são dados na Tabela 7.13. Lembrando que os semivariogramas, tanto para o processo isotrópico quanto para o anisotrópico, foram gerados e ajustados no software VarioWin 2.2.

TABELA 7.13 – PARÂMETROS DOS SEMIVARIOGRAMAS DE MAIOR E MENOR ALCANCES

	Direção de Maior Alcance (10°)	Direção de Menor Alcance (106°)
Modelo	Esférico	Esférico
Efeito Pepita (C_0)	88800	170200
Alcance	12,65	6,79
Patamar	310800	333000
Contribuição (C_1)	222000	162800

Utilizando os parâmetros obtidos no ajuste dos semivariogramas, realizou-se a modelagem da anisotropia. Isto porque existem dois conjuntos de parâmetros, um para cada direção e a modelagem da anisotropia fundirá os dois modelos, em único consistente, que descreva a variabilidade em qualquer direção.

A modelagem da anisotropia, como dito antes, é realizada de forma interativa, dividindo em faixas convenientes o gráfico de semivariogramas, de tal modo que em cada faixa reste somente a anisotropia geométrica. A figura 7.56 mostra os gráficos da modelagem da anisotropia e a Tabela 7.14 descreve os parâmetros obtidos para o modelo aninhado.

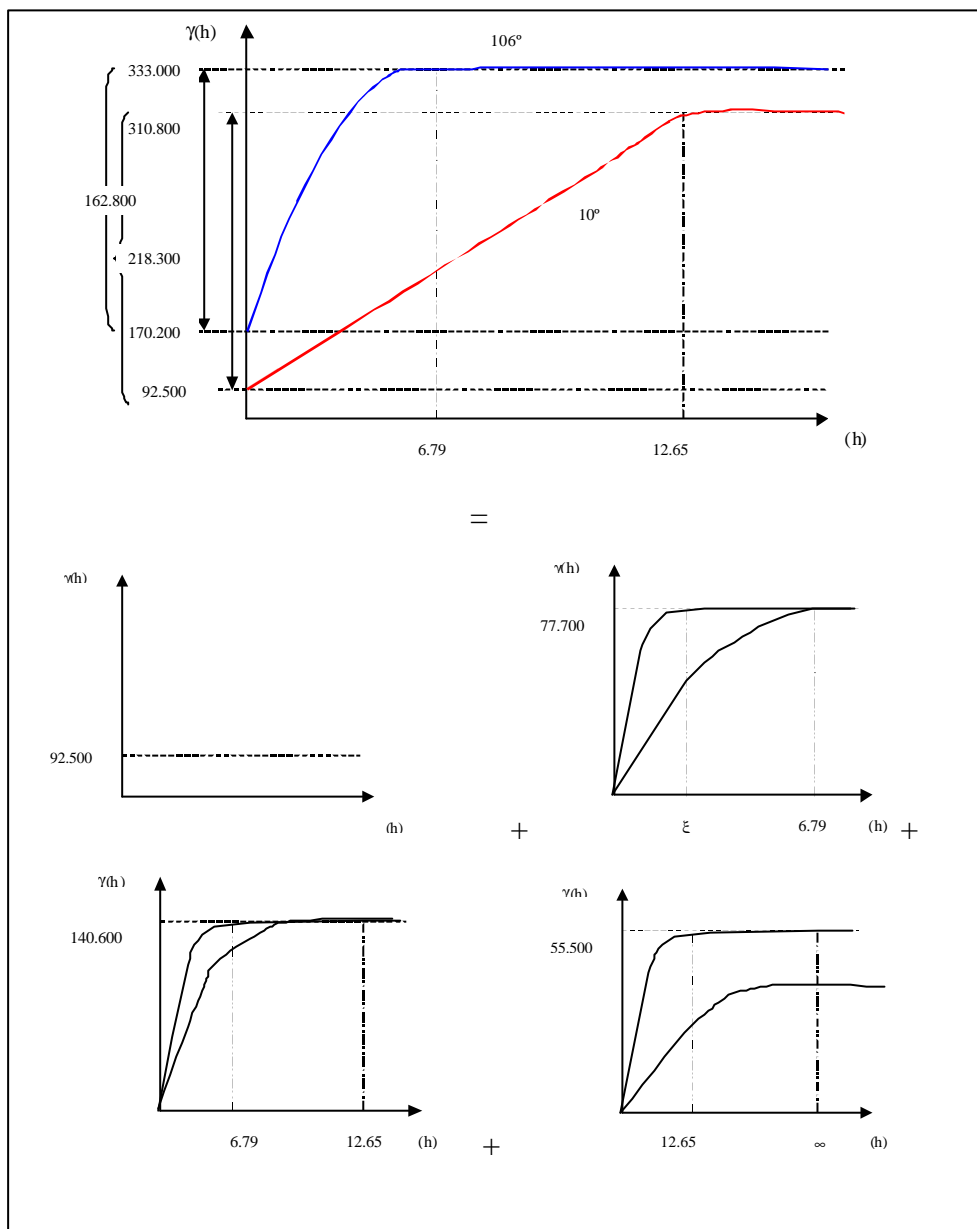


FIGURA 7.56 – MODELAGEM DA ANISOTROPIA

TABELA 7.14 – PARÂMETROS DO SEMIVARIOGRAMA ANINHADO

Número de Estruturas	3		
Efeito Pepita	92500		
Primeira Estrutura – Tipo: Esférica			
Contribuição	77700	Ângulo de Anisotropia	10°
Alcance Mínimo	$\epsilon = 0,00001$	Alcance Máximo	6,79
Segunda Estrutura – Tipo: Esférica			
Contribuição	140600	Ângulo de Anisotropia	10°
Alcance Mínimo	6,79	Alcance Máximo	12,65
Terceira Estrutura – Tipo: Gaussiana			
Contribuição	55500	Ângulo de Anisotropia	10°
Alcance Mínimo	12,65	Alcance Máximo	$\infty = 100000$

A partir de tal decomposição gráfica, tem-se o modelo aninhado dado pela equação 7.2.

$$g(h) = 92500 + 77700 \left[Sph \left(\sqrt{\left(\frac{h_{10^\circ}}{e} \right)^2 + \left(\frac{h_{106^\circ}}{6,79} \right)^2} \right) \right] + 140600 \left[Sph \left(\sqrt{\left(\frac{h_{10^\circ}}{6,79} \right)^2 + \left(\frac{h_{106^\circ}}{12,65} \right)^2} \right) \right] + 55500 \left[Sph \left(\sqrt{\left(\frac{h_{10^\circ}}{12,65} \right)^2 + \left(\frac{h_{106^\circ}}{\infty} \right)^2} \right) \right] \quad (7.2)$$

Após a realização da interpolação utilizando o modelo aninhado, obtém-se a superfície, mostrada na figura 7.57 e seu respectivo mapa de variância da krigagem, mostrado na figura 7.58. Para tal processo de interpolação utilizou-se um raio máximo de 9 m para direção de maior alcance e um raio mínimo de 7 m, para a de menor alcance. Essa pequena diferença entre o raio máximo e mínimo se deu devido ao pequeno número de elementos amostrais, pois se fosse adotado um valor menor para o segundo, a interpolação não seria realizada em algumas áreas. Quanto ao número máximo e mínimo de elementos amostrais considerados para a interpolação, utilizou-se 1 e 3 respectivamente, pois se o mínimo fosse maior que 1, algumas regiões também não seriam interpoladas e se o número máximo fosse maior que 3 ocorreria um processo mais acentuado de suavização da superfície interpolada.




FIGURA 7.57 - INTERPOLAÇÃO POR KRIGAGEM ORDINÁRIA ANISOTRÓPICA




FIGURA 7.58 – MAPA DE VARIÂNCIA DA KRIGAGEM ORDINÁRIA ANISOTRÓPICA

7.5.4. Krigagem Indicadora Isotrópica (KII)

No processo de KII, o conjunto de elementos amostrais é subdividido em diversos cortes. Para este experimento, foram atribuídos somente 3 valores de corte, devido ao número reduzido de elementos e também a sua baixa variabilidade. Os valores de corte para o processo de KII, que foram baseados no histograma dos dados, mostrado na figura 7.47, são os seguintes: para a classe de baixo rendimento foi considerado o intervalo de 460 – 2292,4 (corte 1), para a classe médio: 2292,4 – 2903,2 (corte 2) e finalmente para a classe alto: 2903,2 – 3200 (corte 3).

Os semivariogramas gerados para cada um dos cortes são mostrados nas figuras 7.59, 7.60 e 7.61 e os parâmetros obtidos com os respectivos ajustes na Tabela 7.15.




FIGURA 7.59 – CORTE 1




FIGURA 7.60 – CORTE 2




FIGURA 7.61 – CORTE 3

TABELA 7.15 – PARÂMETROS DE AJUSTE DOS SEMIVARIOGRAMAS

	Corte 1 – 460 – 2292.4	Corte 2– 2292.4 – 2903.2
Direção	Omnidirecional	65°
Efeito Pepita	0,06	0,063
Modelo	Exponencial	Esférico
Alcance	4,4	8,25
Patamar	0,18	0,1
Contribuição	0,12	0,037
	Corte 3 – 2903.2 - 3200	
Direção	65°	
Efeito Pe pita	0,0296	
Modelo	Esférico	
Alcance	11,6	
Patamar	0,0504	
Contribuição	0,0208	

Para essa interpolação foram utilizados também, raios máximo e mínimo de 10 e 6 m, respectivamente e número mínimo e máximo de elementos amostrais exigidos na interpolação de 1 e 3, respectivamente.

O resultado do processo de interpolação é mostrado na figura 7.62, assim como seu mapa de variância da krigagem na figura 7.63.




FIGURA 7.62 - INTERPOLAÇÃO POR KRIGAGEM INDICADORA ISOTRÓPICA




FIGURA 7.63 – MAPA DE VARIÂNCIA DA KRIGAGEM INDICADORA ISOTRÓPICA

7.5.5. Cokrigagem

A cokrigagem é um processo geoestatístico no qual diversas variáveis regionalizadas podem ser estimadas em conjunto, com base na correlação espacial existente entre as mesmas.

O processo de cokrigagem torna-se evidente quando algumas posições possuem duas ou mais variáveis amostradas nos mesmos locais, no caso, dados de rendimento da soja e o valor do índice de vegetação razão espectral, em um único domínio espacial e apresentam um grau de correlação significativo. Tal processo minimiza o problema de sub-amostragem. O objetivo é melhorar a estimativa da variável sub-amostrada, nesse caso o rendimento, utilizando aquela mais densamente amostrada, o valor da razão.

Como colocado por Landim et al. (2002), fundamental na utilização da cokrigagem é a verificação da correlação existente entre as variáveis, a qual deve ser alta para que as estimativas sejam consistentes. Segundo o mesmo autor, a melhoria de interpretação somente é significativa quando uma das variáveis tem um número extremamente reduzido de casos em relação à outra.

7.5.5.1. Verificação da Correlação entre as Variáveis

Os valores da razão deveriam ser correlacionados com o rendimento de culturas, pelo fato das bandas do vermelho e do infravermelho próximo apresentarem alta correlação com o mesmo. Porém, isso não foi constatado neste estudo de caso. Os dados para a variável primária, rendimento e para a variável secundária, valor da razão, apresentados na Tabela 7.16, dão origem ao gráfico da figura 7.64, que mostra a baixa correlação existente entre as variáveis.

TABELA 7.16 – VALORES DO RENDIMENTO E DA RAZÃO

E (m)	N (m)	Rendimento (kg/há)	Razão(Níveis de Cinza)
481360.0769	7434393.567	2372.439336	174
481362.6019	7434392.402	2382.988506	167
481359.4437	7434390.587	2582.188165	152
481356.317	7434388.807	3513.226905	158
481358.9124	7434387.701	2505.180928	167
481355.8907	7434386.032	2078.544061	167
481354.0619	7434383.635	2744.12516	153
481350.9823	7434381.885	3034.776501	158
481348.6738	7434376.14	462.4265645	166
481349.9455	7434375.557	3348.544061	159
481345.8888	7434373.976	3050.012771	140
481347.1332	7434373.491	2603.767561	148
481344.3697	7434371.141	2780.893997	167
481345.8077	7434367.549	2948.710089	155
481344.6888	7434364.869	3091.340996	158
481342.1261	7434362.283	1725.070243	141
481339.8215	7434359.747	2624.653044	143
481342.4503	7434359.054	2480.842912	154
481340.043	7434356.446	2349.425287	157
481339.1465	7434353.484	1947.43295	141
481340.5055	7434353.177	2874.338016	145
481336.9815	7434350.941	3102.916135	156
481336.153	7434348.133	2743.891017	136
481338.7727	7434347.435	2545.785441	152

A ausência da correlação entre as variáveis primária e secundária, pode ter ocorrido devido a diversos fatores. Existem várias hipóteses que devem ser consideradas para tentar explicar tal fato; a primeira é devido ao fato da área utilizada para o experimento ter pouca variabilidade, ou seja, ser bastante homogênea, com isso fica muito difícil associar uma relação entre o rendimento da soja e o valor da razão. Outra hipótese deve ser remetida ao fato de que as imagens foram tomadas com a câmara em posição inclinada; isso pode influenciar a resposta espectral da soja, mesmo depois dos processos de retificação e normalização. Tal fato foi melhor esclarecido no capítulo 5, item 5.1, que fala sobre a reflectância bidirecional. No caso de serem

utilizadas imagens da satélite, essas variações no ângulo de visada da câmara podem não influenciar na resposta espectral, pois se comparadas, as imagens de satélites tem uma variação no ângulo quase que imperceptível, pois a visada é vertical e a plataforma muito estável. Enquanto que as imagens obtidas de plataformas terrestres, que trafegam sobre terreno irregular, como o de plantações. Além dos fatores descritos acima, outros podem ter influenciado, como por exemplo, as condições de iluminação e as condições atmosféricas do dia em que foram tomadas as imagens, apesar de todos os cuidados tomados durante a aquisição das imagens e de o tempo estar limpo e sem nuvens no momento das tomadas.




FIGURA 7.64 – GRÁFICO DA CORRELAÇÃO

Como pode ser observado, pelo gráfico da figura 7.66, não existe correlação visível, sendo que essa afirmação pode ser demonstrada pelo coeficiente de correlação, que é de $-0,1269$. Portanto, a inexistência de correlação entre a variável primária e variável secundária inviabiliza o processo de cokrigagem. Nesse caso, nem mesmo a geração do semivariograma cruzado é possível e mesmo que isso pudesse ser feito, a estimativa não seria consistente.

7.5.5.2. Geração dos Semivariogramas

Mesmo depois de verificada a inexistência de correlação, gerou-se os semivariogramas, apenas a título de ilustração. Nas figuras 6.65 e 6.66, são mostrados os semivariogramas individuais para a variável primária, rendimento e para a variável secundária, valor da razão. E na figura 6.67 é mostrado o semivariograma cruzado para ambas as variáveis.




FIGURA 7.65 – SEMIVARIOGRAMA INDIVIDUAL PARA A VARIÁVEL PRIMÁRIA (RENDIMENTO)




FIGURA 7.66 – SEMIVARIOGRAMA INDIVIDUAL PARA A VARIÁVEL SECUNDÁRIA (VALOR DA RAZÃO)




FIGURA 7.67 – SEMIVARIOGRAMA CRUZADO PARA A VARIÁVEL PRIMÁRIA E SECUNDÁRIA

Como pode ser observado nas figuras 6.65, 6.66 e 6.67, somente para o semivariograma individual da variável rendimento poderia ser ajustado um modelo teórico. Enquanto o semivariograma individual para a variável secundária valor da razão, apresenta um comportamento atípico, devido ao pequeno grau de variação

apresentado. No caso do semivariograma cruzado, não seria possível ajustar nenhum modelo teórico existente, pois a ausência de correlação entre as variáveis não permitiu a geração de um semivariograma que se ajustasse a qualquer modelo teórico.

Assim, levando em consideração as condições descritas anteriormente, não foi possível realizar o processo de cokrigagem, utilizando como informações adicionais dados das imagens obtidas com uma câmara digital multiespectral com visada inclinada.

7.5.6. Análise dos Resultados Obtidos pelos Processos de Interpolação do Experimento 2

Para cada um dos processos de krigagem, KOI, KOA e krigagem indicadora isotrópica, foram obtidos mapas temáticos, mostrados nas figuras 6.68, 6.69 e 6.70, respectivamente. Esses mapas possuem três classes de rendimento que foram classificados com os mesmos intervalos utilizados para o mapa temático com o conjunto total de elementos amostrais e é considerado como mapa de referência. As classes utilizadas para gerar os mapas temáticos são as seguintes: baixa (462 – 2528,2), médio (2528,2 – 3217,6) e alto (3217,6 – 3907,0). Esses mapas foram comparados com o mapa temático gerado com o conjunto total de elementos amostrais, o qual é mostrado na figura 7.71.




FIGURA 7.68 – MAPA TEMÁTICO DA KRIGAGEM ORDINÁRIA ISOTRÓPICA




FIGURA 7.69 – MAPA TEMÁTICO DA KRIGAGEM ORDINÁRIA ANISOTRÓPICA




FIGURA 7.70 – MAPA TEMÁTICO DA KRIGAGEM INDICADORA ISOTRÓPICA




FIGURA 7.71 – MAPA TEMÁTICO DO CONJUNTO TOTAL DE ELEMENTOS AMOSTRAIS

Para verificar a qualidade dos resultados obtidos no segundo experimento pelos processos de krigagem, utilizou-se as matrizes de confusão e o índice de concordância kappa. Comparando os mapas das figuras anteriores com o mapa de referência (figura 7.71), verifica-se que os resultados não foram satisfatórios como no primeiro experimento no qual se utilizou uma área bem maior. As Tabelas 7.17, 7.18 e

7.19 apresentam as matrizes de confusão proporcional resultantes da comparação entre o mapa de referência e os mapas obtidos pelos processos de KOI, anisotrópica e indicativa isotrópica, respectivamente. Nas colunas estão as proporções dos pixels classificados da imagem de referência e nas linhas estão as proporções dos pixels na imagem resultante dos processos de krigagem.

A Tabela 7.17 apresenta a matriz de confusão para a KOI.

TABELA 7.17 – MATRIZ DE CONFUSÃO PARA KRIGAGEM ORDINÁRIA ISOTRÓPICA

	1	2	3	Total
1	0,0205	0,0058	0,0158	0,0422
2	0,2135	0,4323	0,2923	0,9381
3	0,0000	0,0017	0,0182	0,0199
Total	0,2340	0,4399	0,3264	1,0000

Para os fins da agricultura de precisão a classe que merece maior atenção, ou seja, a classe mais crítica, é a classe 3, a qual classifica as áreas de baixo rendimento, a qual deverá receber maiores cuidados, como adubos, fungicidas, etc. Na Tabela 7.17 pode-se observar que essa classe apresentou um erro de inclusão 8,8 % e erro de omissão de 94,4 %. Pode-se considerar que o resultado obtido com o processo de KOI não é satisfatório pois, embora o erro de inclusão seja baixo, o erro de omissão, cuja área omitida não é considerada na análise, é muito alto, com isso a parte da área que foi desconsiderada não receberá os cuidados necessários.

A Tabela 7.18 apresenta a matriz de confusão para a KOA.

TABELA 7.18 – MATRIZ DE CONFUSÃO PARA KRIGAGEM ORDINÁRIA ANISOTRÓPICA

	1	2	3	Total
1	0,0252	0,0123	0,0252	0,0627
2	0,2088	0,4229	0,2605	0,8922
3	0,0000	0,0041	0,0405	0,0447
Total	0,2340	0,4393	0,3262	1,0000

A Tabela 7.18 mostra que os resultados obtidos com o processo de KOA são um pouco melhores que o anterior, pois o erro de inclusão nesse processo foi

de 9,2 % e o erro de omissão foi de 87,5 %, mas ainda possuindo um erro de omissão muito alto.

A Tabela 7.19 apresenta a matriz de confusão para a KII.

TABELA 7.19 – MATRIZ DE CONFUSÃO PARA KRIGAGEM INDICADORA ISOTRÓPICA

	1	2	3	Total
1	0,0563	0,0931	0,0511	0,2005
2	0,1874	0,3271	0,1909	0,7054
3	0,0000	0,0280	0,0655	0,0935
Total	0,2437	0,4482	0,3075	1,0000

Neste caso, o erro de omissão da classe 3 é o menor entre os três processos comparados, sendo de 78,69 %. Porém, o erro de inclusão é o maior: 29,9 % contra 8,8 % e 9,2 % dos processos de KOI e anisotrópica, respectivamente. O erro de inclusão não compromete, de forma relevante, o diagnóstico da situação da produção quanto o erro de omissão, que deve ser tratado com mais cuidado.

Na Tabela 7.20 são apresentados os índices de concordância kappa, calculados para cada um dos processos de krigagem.

TABELA 7.20 – ÍNDICE DE CONCORDÂNCIA KAPPA

	KOI	KOA	KII
Kappa	7,35 %	11,6 %	9,09 %

Por meio da tabela 7.20 é possível verificar que os índices de concordância kappa indicam que o melhor processo nesse caso foi o da KOA, com uma diferença de aproximadamente 4 % e 2,5 % em relação aos processos de KOI e KII, respectivamente. Porém, os resultados obtidos não foram satisfatórios; isso pode ter ocorrido devido ao fato de a resolução espacial ser muito elevada para modelar um fenômeno cuja variabilidade é melhor compreendida e representada em outra escala, com menor grau de detalhamento; além da área ser extremamente pequena e de ter uma

geometria irregular, bem como de possuir um número de elementos amostrais bastante reduzido. Tais fatos dificultam a tarefa do interpolador, pois o mesmo não consegue encontrar elementos amostrais suficientes em um raio de busca pequeno, sendo necessário que este seja aumentado, o que acaba influenciando no resultado da interpolação. O que se esperava era melhorar os resultados com o uso de valores do índice de vegetação das imagens da área. Porém, como visto anteriormente, isto não foi possível devido à ausência de correlação entre os dados de rendimento e os valores de índice de vegetação, advindos das imagens da razão, impossibilitando o processo de Cokrigagem.

8. CONSIDERAÇÕES FINAIS, CONCLUSÕES E RECOMENDAÇÕES

8.1. Considerações Finais

A presente pesquisa apresenta uma fundamentação teórica dos conceitos relacionados a geoestatística, desde variáveis regionalizadas, passando pela geração e ajuste dos semivariogramas até a realização dos processos de krigagem e cokrigagem. Dentro dessa etapa da fundamentação, são descritos ainda os conceitos de anisotropia, como detectá-la e qual a sua importância na reconstrução de superfícies utilizando métodos de interpolação. Em uma outra etapa da fundamentação é apresentado o comportamento espectral da vegetação e do solo e a função distribuição da reflectância bidirecional, assim como suas causas e efeitos.

Os dados utilizados nessa pesquisa foram coletados em dois locais distintos, cedidos pela EMBRAPA, o primeiro em uma cooperativa localizada no município de Palotina – PR e o segundo na EMBRAPA – SOJA de Londrina – PR, onde também foram coletadas imagens, além dos dados de rendimento.

Para o primeiro experimento utilizou-se somente dados do rendimento de soja, com os quais foram realizados os processos de Krigagem Ordinária Isotrópica, anisotrópica e indicadora isotrópica.

No segundo experimento utilizou-se além da amostra de rendimento de soja, imagens obtidas da plantação, utilizando a câmara DuncaTech MS-3100. É importante salientar que tais imagens foram coletadas com visada inclinada, ou seja, a câmara não estava em posição vertical, como seria o caso de um voo ou de uma imagem de satélite. Diversos processamentos foram realizados nas imagens, antes de gerar os valores de razão espectral que seriam utilizados no processo de cokrigagem. Antes de realizar os processamentos, as imagens foram selecionadas, porém muitas foram

descartadas, devido ao fato de não ser possível a identificação dos pontos para a realização da fototriangulação, com isso uma parte da área foi perdida.

As imagens foram retificadas, para corrigir a atitude da câmara em relação ao terreno; depois seus valores de radiância foram transformados em fator de reflectância, utilizando como reflectância padrão o valor da resposta da placa de sulfato de bário; enfim as imagens foram normalizadas, para que todas ficassem aproximadamente com a mesma função de resposta, com condições atmosféricas e de iluminação padronizadas. Só então, depois de todos os processamentos descritos anteriormente, gerou-se as imagens da razão espectral entre as bandas do vermelho e do infravermelho e o mosaico com as mesmas. Lembrando que houve a necessidade de realizar aproximações e mudanças do intervalo dinâmico dos dados a fim de compatibilizá-los com o tipo de arquivo de imagem adotado: RGB com 24 bits de profundidade.

Para ambos os experimentos foram realizados os processos de Krigagem Ordinária Isotrópica, Anisotrópica e Indicadora Isotrópica, possibilitando realizar a análise dos processos realizados em conjuntos de dados de tamanhos e geometrias bem diferentes, o que pode ter influenciado nos resultados das interpolações.

Ainda no segundo experimento, não foi possível chegar ao fim do processo de cokrigagem, devido ao fato das variáveis utilizadas, rendimento da soja e valor da razão espectral, não terem apresentado correlação para este estudo de caso.

8.2. Conclusões

No primeiro experimento, mesmo tendo reduzido drasticamente o número de elementos, os resultados obtidos foram bastante satisfatórios. Os mapas temáticos gerados utilizando-se os resultados das interpolações foram comparados com

um mapa de referência, gerado com o conjunto total de elementos amostrais, tais mapas foram divididos em três classes de rendimento: alto, médio e baixo.

A análise dos resultados voltou-se, principalmente, para a classe mais crítica, ou seja, a de baixo rendimento, pois é nela que são necessários maiores cuidados. A análise utilizando o índice de concordância kappa e a matriz de confusão mostrou que, o processo de Krigagem Ordinária Isotrópica obteve o maior erro de omissão dentre todos os processos, considerado o mais grave por desconsiderar as áreas que foram classificadas erroneamente. Enquanto que os processo de Krigagem Indicadora Isotrópica obteve um erro de omissão de 0,29 %, o menor de todos.

O índice de concordância kappa mostrou que o melhor resultado entre os três processos, ainda no primeiro experimento, foi o obtido pela Krigagem Ordinária Anisotrópica, no qual 72,54 % da área foi classificada corretamente, contra 70,26 % e 70,19% das Krigagem Ordinária Isotrópica e indicadora isotrópica. Entretanto, como a diferença entre os três é muito pequena, apenas 2%, o que deve ser analisada nesse caso é a praticidade e o tempo gasto para realizar os processos, assim como o conhecimento exigido para cada um.

No segundo experimento, os resultados obtidos pela krigagem não foram satisfatórios. Isso pode ser explicado devido ao número reduzido de elementos amostrais e ao tamanho muito pequeno da área. Do conjunto total de elementos amostrais foram extraídos apenas 24 elementos, de forma regular estratificada. A redução do conjunto total de elementos amostrais, associada ao tamanho pequeno da área, dificultaram a realização dos processos de interpolação.

Analisando, também a classe de baixo rendimento, a classe 3, tem-se o processos de Krigagem Ordinária Isotrópica obteve o maior erro de omissão. A maior

parte da área pertencente à classe 3, para esse processo, foi classificada incorretamente, cerca de 94.4 %.

O índice kappa confirma essas análises: 7,35 %, 11,6 % e 9,09 % para os processos de Krigagem Ordinária Isotrópica, Krigagem Ordinária Anisotrópica e Krigagem Indicadora Isotrópica, respectivamente. Eles mostram que uma parcela mínima da área foi classificada corretamente.

Uma hipótese explicativa para resultados tão diferentes para os dois experimentos pode ser obtida pela comparação entre os tamanhos das áreas. O tamanho da primeira área é de aproximadamente 135000 m², enquanto que a da segunda é de 153 m². A largura da segunda área é de 2,70 m e a da primeira é de aproximadamente 270 m, ou seja, dez vezes maior.

Analisando os mapas temáticos, o nível de resolução espacial e as dimensões da área, levando em consideração que o fenômeno possui dimensões maiores, e talvez só possa ser percebido com amostragem de áreas maiores e com menor resolução espacial, como é ilustrado em Forman (1995). A largura da menor faixa no mapa temático do primeiro experimento é de 8 m, aproximadamente, bem maior que a largura total da área do segundo experimento. É como se um zoom muito grande tivesse sido dado na primeira área para gerar a segunda. A variabilidade aparente da segunda área pode ser considerada resultado do efeito aleatório, devido a grau de detalhamento ser muito alto.

Foram utilizadas para o segundo experimento apenas 3 linhas de plantio, o que pode ser considerado uma área sem nenhuma variação modelável se comparada com a primeira. Devido a esses fatores, o segundo experimento não obteve um resultado satisfatório, pois os métodos de interpolação não conseguiram modelar tal “variabilidade”, pelo fato dela constituir-se somente da componente aleatória.

Ainda no segundo experimento, verificou-se a dificuldade dos interpoladores para estimar as posições não amostradas devido ao pequeno número de elementos amostrais e ao tamanho da área. Devido ao pequeno número de elementos amostrais, os raios de busca atribuídos nos processos de interpolação com o subconjunto de elementos, foram de no mínimo 6 m e no máximo de 10 m, onde muitas vezes não havia elementos que pudessem contribuir o suficiente com a estimativa das posições não amostradas.

Tais fatos devem ser sempre condicionados ao manejo realizado na área, pois quanto melhor tratada, mais uniforme e mais homogênea será a área, dificultando a modelagem da superfície, como é o caso das áreas de cultivo da EMBRAPA.

Infelizmente o processo de cokrigagem não pôde ser realizado devido a diversos fatores. Primeiro o tamanho da área onde foi realizado o levantamento da amostra de rendimento, bem como das imagens não foi adequado. Outro fator que é de relevante importância lembrar, é que as imagens foram obtidas com a câmara na posição inclinada, o que realmente contribuiu negativamente para o experimento.

Em suma os métodos de krigagem testados se mostraram bastante aptos a estimar superfícies de rendimento, reduzindo significativamente o número de elementos amostrais que devem ser coletadas em campo, ajudando, assim, a reduzir os custos envolvidos no processo. Salvo a consideração que a modelagem está condicionada às dimensões do campo, ou seja, do domínio, pois o fenômeno “modelável” ou que se pode representar não ocorre em áreas muito pequenas e não é detectável com alta resolução. Pode-se dizer que uma ordem de grandeza adequada para a componente determinística (modelável) é de dezenas a centenas de metros. Quanto ao método de cokrigagem, não é possível afirmar com base nestes experimentos, que não

possa ser realizado com sucesso utilizando imagens de câmaras digitais multiespectrais, ou mesmo que possa. Mas pode-se dizer, com certeza, que a tomada das imagens com visada inclinada não é ideal, devido a reflectância bidirecional.

8.3. Recomendações

Com a experiência adquirida durante a execução dessa pesquisa, a partir da análise dos resultados e das dificuldades encontradas, deixa-se algumas recomendações para trabalhos futuros, visando melhorar os resultados obtidos:

- Para a aplicação da cokrigagem utilizando como informações adicionais imagens multiespectrais, obter as imagens de uma plataforma com a câmara em posição vertical ou mesmo de uma aeronave, o que facilitará a correção do ângulo de visada e das atitudes da câmara (retificação);
- A componente determinística da variação é mais facilmente observada com distâncias entre dezenas e centenas de metros, por isso é aconselhável utilizar áreas de tamanhos maiores que a utilizada no primeiro experimento;
- Testar os métodos de krigagem para outras culturas, como milho, trigo, etc.

REFERÊNCIAS BIBLIOGRÁFICAS

ANDRADE, J. B. *Fotogrametria*. Curitiba, SBEE, Universidade Federal do Paraná, 1998. 258p.

ANTUNES, A. F. B.; LINGNAU, C. Uso de Índices de Acurácia para Avaliação de Mapas Temáticos Obtidos por Meio de Classificação Digital. In: *Anais GIS BRASIL*. Curitiba – PR. 1997.

ARRUDA, J. E. R. de. “*Mosaicagem*” *Entre Imagens Digitais*. Dissertação de Mestrado. Presidente Prudente – SP, 2002.

BURROUGH, P. A. *Principles of geographical information systems for land resources assessment* - Oxford, Clarendon Press, 1987.

CAMARGO, E. C. G. *Desenvolvimento, Implementação e Teste de Procedimentos Geoestatísticos (Krigagem) no Sistema de Processamento de Informações Georreferenciadas (SPRING)*. Cap. 2. São José dos Campos, 1997 – Ministério da Ciência e Tecnologia – INPE.

CAMARGO, E. C. G. *Apostila do curso – geoprocessamento para projeto ambientais*. Cap. 12. São José dos Campos, 1998. INPE.

CAMARGO, E. C. G. *Análise Espacial de Dados Geográficos – Laboratório – Módulo: Geoestatística Linear*. Divisão de Processamento Digital de Imagens – DPI – INPE. São José dos Campos, 2000.

CURRAN, P. J.. *Principles of Remote Sensing*, Londres and New York, 1983.

DETUSCH, C. V., JOURNEL, A. G. *GSLIB – Geostatistical Software Library and User’s Guide*. e. 2, 1998. Oxford University Press, New York, Oxford.

FELGUEIRAS, C. A. *Modelagem ambiental com tratamento de incertezas em sistemas de informação geográfica: o paradigma geoestatístico por indicação*. Tese de Doutorado, 1999. São José dos Campos – INPE

FORMAN, R. T. T. *Land Mosaics: The Ecology of Landscapes and Regions*. Melbourne, Austrália, 1995. Cambridge University Press.

GAMON, J. A., et al. Estimation of vegetation water content and photosynthetic tissue area from spectral reflectance: a comparison of indices based on liquid water and chlorophyll absorption features. *Remote Sensing of Environment, Elsevier*. v. 83, p. 526 – 537, 2002.

IMAI, N. N. I., SARTORI, L. R., SILVA, E. A. da, GALO, M. de L. B. T. Espectroradiometria de Campo no Visível e Infravermelho Próximo: Um Estudo da Resposta Espectral da Soja. In:, 2003.

ISAAKS, E. H., SRIVASTAVA, M. R. *Applied geostatistics*. Oxford, New York, 1989. Oxford University Press.

JENSEN, R. J. *Remote Sensing of the Environment: na Earth Resource Perspective*. Upper Sadle River: Prentice Hall. 2002. 544p.

LANDIM, P. M. B. *Análise Estatística de Dados Geológicos*. São Paulo: UNESP, 1998, 226 p.

LANDIM, P. M. B.; STURARO, J. R.; MONTEIRO, R. C. *Exemplos de Aplicação da Cokrigagem*. 2002. Rio Claro – SP : UNESP. Texto Didático. 18p.

MONTGOMERY, G.; SCHUCH, C. *Gis Data Conversion Handbook*. Fort Collins: Gis Word Books. 1993.

MOREIRA, M. A.. *Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação*, 2001, São José dos Campos – SP: Instituto de Pesquisas Espaciais (INPE).

NOVO, E.M.L.M. *Sensoriamento Remoto: princípios e aplicações*. São Paulo: Edgard Blucher, 1992.

SCHOTT, J. R.; SALVAGGIO, C.; WOLCHOK, W. J. Radiometric Scene Nomraliztion Using Psudoinvariant Features. In: *Remote Sensing of Environment*, New York. v.26 (1), p. 1-16. 1988.

SPIEGEL, M. R. *Estatística*. McGrawhill, 3ªedição, 1993.

SPRING. *Ajuda do Software Spring 3.6.03*. São José dos Campos – SP. Instituto Nacional de Pesquisas Espaciais. 2003.

STURARO, J. R. *Mapeamento geoestatístico de propriedades geológico-geotécnicas obtidas de sondagens de simples reconhecimento*. Tese de Doutorado, 1993. São Carlos – USP.

TEILLET, P. M.; STAENZ, K.; WILLIANS, D. J. Efect of Spectral, Spatial an Radiometric Characterisitcs on Remote Sensing Vegetation on Indices of Forest Regions. In: *Remote Sensing of Environment*, New York, v. 61, p. 139 – 149, 1997.

WOLF, P. R. *Elements of Phtotogrammetry*. Singapure: McGraw-Hill Book Company, 1983. 628p.

WOLF, P. R. e DEWIT, B. A. *Elements of Photogrammetry: With Applicions in GIS*, 3 ed. USA.: MacGraw-Hill Book Company, 2000, 607 p.

BIBLIOGRAFIA CONSULTADA

ATKISON, P. M.; LEWIS, P.. Geostatistical classification for remote sensing: na introduction. *Computers & Geosciences. Pergamon.* v. 26, p.361-371, 2000.

CHEN, C. S.; TARDIN, A. T.; BATISTA, G. T. *Índices de Vegetação e suas aplicações na agricultura.* São José dos Campos, 1986. 24p. Instituto Nacional de Pesquisas Espaciais – INPE. (INPE 3912-MD/030).

CONDIT, H. R. The spectrla reflectance of American soils. *Photogrammetric Engineering and Remote Sensing.* v. 36, nº. 9, 955 – 966, 1970.

DUNCAN TECH, MS-3100 User manual (Software nVer.1.02h). Auburn, CA: Duncan Tech, 2001(CD-Rom).

ELVIDGE, C. D. Visible and near infrared reflectance characteristics of dry plant materials. *International Journal of Remote Sensing.* v. 11, nº. 10, 1775 – 1795, 1990.

ESTRADA-PEÑA, A. Geoestatics and remote sensing using NOAA-AVHRR satellite imagery as predictive tools in tick distribution and habitat suabilit estimations for *Boophilus microplus* (Acari: Ixodidae) in South America. *Veterinary Parasitology. Elsevier,* v. 81, p. 73-82, 1999.

FONSECA, L. M. G. *Segmentação e Classificação.* Divisão de Processamento de Imagens. INPE. 2000. Disponível em <http://www.dpi.inpe.br/leila.htm>> Acesso em: abril de 2002.

GALO, M. L. B. T.; NOVO, E. M. L. de M.; Normalização Radiométrica de Imagens: Uma Meio de Integrar Dados Multitemporais de Sensoriamento Remoto para Monitoramento Ambiental. In: *Revista do Instituto Florestal.* São Paulo, v.12, p. 67 – 75, 2000.

HOLDEN, N. B.; TUCKER, J. C.. Spectral Assessment of Soybean Leaf Area and Leaf Biomass. *Photogrammetric Engineering and Remote Sensing,* v.46, n.5, p. 651-656, 1980.

KNIPLING, E. B. Physical and phisiological basis for the reflectande of visible and near-infrared radiation from vegetation. *Remote Sensing of Enviroment,* v.1, n.3, p. 155-59, 1970.

KOLLENKARK, J.C.; VANDERBILT, V.C.; BAUER, M.E.; HOUSLEY, T.L. Effect of cultural pratices on agronomic; reflectance characteristics of soybean canopy. *Agronomy Journal,* , 1982, v.74, n.4, p.751-758.

NETTO, J. de S. M.; FUKUHARA, M.; EXPINOZA, W.. Assinaturas Espectrais de Quatro Variedades de Soja. *II Simpósio Brasileiro de Sensoriamento Remoto,* v.3, 1982, Brasília – DF

PINTER, jr., P.J.; JACKSON, R. D.; EZRA, C. E.; GAUSMAN, H. W. Sun-angle; canopy-architecture effects on the spectral reflectance of six wheat cultivars. *Internatinonal Journal of Remote Sensing*, v.6, n.12, p.1813-25, Dec. 1985.

POZDNYAKOVA A. L. et al; Estimation of spatial and spectral properties of phytophthora root rot and its effects on cranberry yield. *Computers and eletronicis in Agriculutre, Elesevier*. v. 37, p. 57-70, 2002.

RICHARDS, J. A.; JIA, X.; *Remote sensing digital image analysis: an introduction*. e. 3. New York: Springer Verlag, 1999.

SARTORI, L. R.; VICENTE, J.; IMAI, N. N.; GALO, M. L. B. T.; SILVA, E. A. da. Sig em Agricultura de Precisão: Um Estudo do Comportamento Espectral da Soja Como Contribuição ao Mapeamento do Rendimento de Uma Cultura. In: *Anais do IV Fórum de Ciências da Universidade Estadual Paulista. Presidente Prudente*. 2003 .

STAFFORD, J. V. Essencial Technology for Precision Agriculture. In: *International Conference on Precision Farming*, 3., Miniapolis. Proceedings. Madison: ASA, CSSA, SSSA, p 595-604, 1996.

STEFFEN, C.A. *Introdução ao Sensoriamento Remoto*. Instituto Nacional de Pesquisas Espaciais, Disponível em <http://www.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm>, acessado em 15/05/2003.

TUCKER, C.J.; HOLBEN B.N. Spectral assessment of soybean leaf area and leaf biomass: *Photogrammetric Engineering and Remote Sensing*, Baltimore, v.46, n.5, p.651-656, may 1980.

VYODSKAYA, N. N.; GORSHKOVA, I.; FADEYEVA, Ye, V.. Theoretical estimates of senitivity in some vegetation indices to variation in canopy condition. In: *International Journal of Remote Sensing*, v.10, n.12, p.1857-72, 1989.

WARDLEY, N. W.; CURRAM, P. J. The estimation of green-leaf-area index from remotely sensed airborne multiespectral scanner data. *International Journal of Remote Sensing*, v.5, n.4, p. 671-679.