

unesp



UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Ciências e Tecnologia
Câmpus de Presidente Prudente

DANIEL LUÍS DE LIMA



**SENSORIAMENTO REMOTO E GEOESTATÍSTICA
NA CARACTERIZAÇÃO ESPAÇO-TEMPORAL
DE PLANTAS AQUÁTICAS**

Dissertação de Mestrado

**Presidente Prudente
2006**

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

Daniel Luís de Lima

**SENSORIAMENTO REMOTO E GEOESTATÍSTICA
NA CARACTERIZAÇÃO ESPAÇO-TEMPORAL
DE PLANTAS AQUÁTICAS**

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

Orientadora: Prof^a. Dr^a. Maria de Lourdes Bueno Trindade Galo.

Co-orientadora: Prof^a. Dr^a. Vilma Mayumi Tachibana.

**Presidente Prudente
2006**

Daniel Luís de Lima

**SENSORIAMENTO REMOTO E GEOESTATÍSTICA
NA CARACTERIZAÇÃO ESPAÇO-TEMPORAL
DE PLANTAS AQUÁTICAS**

**BANCA EXAMINADORA
DEFESA DA DISSERTAÇÃO DE MESTRADO**

Prof^a. Dr^a. Maria de Lourdes Bueno Trindade Galo
- Presidente e orientadora -

Prof. Dr. Paulo Justiniano Ribeiro Júnior (UFPR)
- 2º Examinador -

Prof. Dr. Edivaldo Domingues Velini (Unesp/FCA)
- 3º Examinador -

Presidente Prudente, _____ de _____ de 2006.

Ofereço

À Deus.

Aos meus pais, Luiz e Fátima.

Às minhas irmãs, Jussara e Talita.

Ao meu avô, José Quintino.

À família Costa.

Dedico

*À Elaine, minha doce e amada noiva,
que está ao meu lado em
todos os momentos.
Te amo.*

AGRADECIMENTOS

Meus sinceros agradecimentos à minha orientadora Prof^a. Dr^a. Maria de Lourdes Bueno Trindade Galo e à minha co-orientadora Prof^a. Dr^a. Vilma Mayumi Tachibana, pela dedicação e paciência, pelo incentivo durante esta jornada e pela amizade.

Ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico), pela bolsa concedida.

A CPFL (Companhia Paulista de Força e Luz) e ao INPE (Instituto Nacional de Pesquisas Espaciais), pelas imagens disponibilizadas para a realização deste trabalho.

Aos professores do PPGCC e do Departamento de Cartografia, que contribuíram para a minha formação e evolução pessoal, especialmente ao Prof. Dr. Nilton Nobuhiro Imai, pela sua participação como co-orientador “informal”.

A todos os amigos que contribuíram direta ou indiretamente para a realização deste trabalho.

Em especial, à minha família e à família Costa pelo apoio e incentivo.

*“O tempo muda tudo, exceto algo dentro de nós que
sempre se surpreende com a mudança.”*

Thomas Hardy

RESUMO

Devido ao seu caráter sinóptico e repetitivo, as imagens de satélite constituem-se em um recurso valioso no processo de mapear e monitorar a dispersão de plantas aquáticas em reservatórios de hidrelétricas, cuja ocorrência é um problema de importância crescente no Brasil. Considerando que a disponibilidade de imagens multiespectrais e multitemporais representa o registro de um fenômeno particularmente importante no contexto da utilização da água para geração de energia, a proposta deste trabalho é buscar um método que permita usar dados multiespectrais adquiridos em diferentes momentos do tempo para caracterizar a infestação por plantas aquáticas em reservatórios. Para isso, foram utilizadas técnicas de análise de imagens multiespectrais e geoestatística, no sentido de se obter um modelo do comportamento, no espaço e no tempo, da ocorrência dessas plantas aquáticas. No entanto, a modelagem da distribuição espaço-temporal de fenômenos dinâmicos não é trivial, principalmente quando a variável deve ser analisada em diferentes domínios: multiespectral, espacial e temporal. Para verificar a hipótese de que a abordagem geoestatística é aplicável neste contexto, foi realizado um experimento utilizando imagens multiespectrais, de diferentes sensores e satélites, abrangendo o Reservatório de Salto Grande em Americana/SP. O conjunto de dados foi submetido a uma série de pré-processamentos a fim de garantir a consistência geométrica e radiométrica das análises, bem como diminuir sua dimensionalidade no domínio multiespectral. Em seguida, foram ajustadas as componentes (ou modelos) espacial e temporal, separadamente, e integradas em um único modelo espaço-temporal, que caracteriza a estrutura da dispersão espaço-temporal do fenômeno. Por fim, o modelo obtido foi utilizado na previsão do fenômeno em um futuro próximo através de uma interpolação por krigagem. Esta previsão foi comparada à imagem de data coincidente, resultando em uma concordância apenas razoável para a classe planta aquática. No entanto, deve-se ressaltar que, por se tratar de um fenômeno ambiental, sujeito a perturbações, e não de um experimento controlado, eventuais intervenções no ambiente aquático podem comprometer a aplicação do modelo e de qualquer previsão sobre a ocorrência das plantas.

Palavras-chave: Modelo espaço-temporal. Geoestatística. Krigagem. Análise de imagens multiespectrais. Índice de vegetação. Plantas aquáticas.

ABSTRACT

Due to their synoptic and repetitive character, the satellite images consist in a valuable resource in the mapping and monitoring process of the aquatic plants dispersion in hydroelectric reservoirs, whose occurrence is an increasing importance problem in Brazil. Considering that multispectral and multitemporal images availability represent a particularly important phenomenon register in the use of water for energy generation context, this work proposes the establishment of a method to use multispectral data acquired at different moments of the time to characterize aquatic plants infestation in reservoirs. Multispectral images analysis and geostatistics techniques are used aiming the construction of an aquatic plants occurrence behavior space-time model. However, the space-time modeling of dynamic phenomena distribution is not trivial, principally when the variable must be analyzed in different domains: multispectral, spatial and temporal. To verify the hypothesis that geostatistics approach is applicable in this context, an experiment was performed using multispectral images, of different sensors and satellites, enclosing Salto Grande reservoir, Americana, São Paulo, Brazil. Data set was submitted to a series of preprocessing in order to certify the geometric and radiometric consistency of the analyses, as well as reducing its dimensionality in the multispectral domain. After that, the spatial and temporal components (or models) were adjusted, separately, and integrated in a space-time model, who characterizes the phenomenon space-time dispersion structure. Finally, space-time model was used to forecast the phenomenon in a close future by kriging interpolation. This forecast was compared to reference image, with coincident date, resulting in a just reasonable agreement for the aquatic plants thematic class. However, it is important to emphasize that aquatic plants occurrence is an ambient phenomenon, subject to disturbances, in opposition to a controlled experiment. In this sense, eventual interventions in the aquatic environment can compromise the model application and any forecast on plants occurrence.

Keywords: Space-time models. Geostatistics. Kriging. Multiespectral image analysis. Vegetation index. Aquatic plants.

LISTA DE FIGURAS

Figura 1 – Comportamento espectral dos principais tipos de alvos.	18
Figura 2 – Representação k-dimensional de uma imagem multiespectral.	24
Figura 3 (a e b) – Principais componentes da variação espacial.	32
Figura 4 – Parâmetros do semivariograma.	36
Figura 5 – Parâmetros para o cálculo do semivariograma.	38
Figura 6 – Representação gráfica de anisotropia geométrica.	43
Figura 7 – Superfície de semivariograma com anisotropia geométrica.	43
Figura 8 – Representação gráfica da anisotropia geométrica em duas dimensões. .	44
Figura 9 – Representação gráfica de anisotropia zonal.	44
Figura 10 – Representação gráfica de anisotropia combinada.	45
Figura 11 – Superfície de semivariograma com anisotropia combinada.	45
Figura 12 – Área de estudo.	63
Figura 13 – Detalhe de uma área com infestação de plantas aquáticas marginais e flutuantes.	63
Figura 14 – Fluxograma representando o método proposto inicialmente.	67
Figura 15 – Distribuição dos pontos de controle.	70
Figura 16 – Média e desvio-padrão (d.p.) dos ND's antes e depois da normalização (banda 3).	72
Figura 17 – Média e desvio-padrão (d.p.) dos ND's antes e depois da normalização (banda 4).	72
Figura 18 – Imagens resultantes dos processamentos iniciais: NDVI's.	74
Figura 19 – Imagens de máximos e distribuição dos elementos amostrais.	76
Figura 20 – Correlação temporal.	78
Figura 21 – Semivariogramas experimentais.	79
Figura 22 – Distribuição das imagens ao longo do tempo.	81
Figura 23 – Segmento da imagem, em cada data, para modelagem no tempo.	82
Figura 24 – Histograma do segmento de imagem para cada data.	83
Figura 25 – Máximos e médias dos NDVI's ao longo do tempo para o segmento selecionado.	83
Figura 26 – Desvios-padrão dos NDVI's ao longo do tempo para o segmento selecionado.	84
Figura 27 – Semivariograma empírico (no tempo).	85
Figura 28 – Modelagem temporal.	86
Figura 29 – Superfície do semivariograma espaço-temporal.	88
Figura 30 – Modelo espaço-temporal.	89
Figura 31 – Imagem de DEZ / 2005.	91
Figura 32 – Classificação cruzada.	92

LISTA DE TABELAS

Tabela 1 – Bandas do sensor TM e suas aplicações.	22
Tabela 2 – Exemplo: continuidade.	31
Tabela 3 – Imagens disponíveis.	65
Tabela 4 – Erros Médios Quadráticos (EMQ's) da etapa de registro.	71
Tabela 5 – Matriz de correlação.	77
Tabela 6 – Parâmetros dos modelos ajustados.	79

SUMÁRIO

RESUMO.....	6
ABSTRACT.....	7
LISTA DE FIGURAS	8
LISTA DE TABELAS	9
1 INTRODUÇÃO	12
1.1 CONTEXTUALIZAÇÃO E HIPÓTESE	12
1.2 OBJETIVO	13
1.3 JUSTIFICATIVA	14
1.4 ESTRUTURA DO TRABALHO	15
2 SENSORIAMENTO REMOTO	17
2.1 COMPORTAMENTO ESPECTRAL DA ÁGUA E DA VEGETAÇÃO AQUÁTICA.....	18
2.2 SISTEMAS SENSORES.....	20
2.3 PROCESSAMENTO DIGITAL DE IMAGENS MULTIESPECTRAIS	23
2.3.1 Registro.....	24
2.3.2 Normalização radiométrica.....	25
2.4 TRANSFORMAÇÕES ESPECTRAIS: ÍNDICE DE VEGETAÇÃO	26
3 GEOESTATÍSTICA.....	29
3.1 VARIÁVEIS REGIONALIZADAS	29
3.1.1 Hipótese de estacionariedade de ordem 2.....	33
3.1.2 Hipótese de estacionariedade intrínseca	34
3.2 SEMIVARIOGRAMA	35
3.2.1 Características do semivariograma.....	36
3.2.2 Cálculo do semivariograma a partir de elementos amostrais irregularmente espaçados.....	38
3.3 MODELOS TEÓRICOS.....	39
3.4 ANISOTROPIA	42
3.4.1 Anisotropia geométrica.....	42
3.4.2 Anisotropia zonal.....	44
3.4.3 Anisotropia combinada.....	45
3.5 KRIGAGEM	46
3.5.1 Krigagem ordinária.....	47
4 GEOESTATÍSTICA EM ANÁLISES ESPAÇO-TEMPORAIS.....	51
4.1 GEOESTATÍSTICA NO TEMPO	51
4.2 MODELOS ESPAÇO-TEMPORAIS.....	52
4.3 MODELO PRODUTO-SOMA GENERALIZADO.....	58
5 EXPERIMENTO: DESCRIÇÃO, MÉTODO E RESULTADOS	61
5.1 ÁREA DE ESTUDO	61
5.2 IMAGENS MULTIESPECTRAIS E MULTITEMPORAIS UTILIZADAS.....	65

5.3 MÉTODO PROPOSTO	66
5.4 EXPERIMENTO REALIZADO	69
5.4.1 <i>Processamentos iniciais</i>	69
5.4.1.1 Reamostragem	69
5.4.1.2 Registro	70
5.4.1.3 Normalização radiométrica	71
5.4.1.4 Geração dos NDVI's e recorte da área de estudo	73
5.4.2 <i>Análise da correlação no tempo</i>	75
5.4.3 <i>Modelagem no espaço</i>	78
5.4.4 <i>Modelagem no tempo</i>	80
5.4.5 <i>Modelo espaço-temporal</i>	86
5.4.6 <i>Previsão</i>	90
6 CONCLUSÕES E RECOMENDAÇÕES	93
REFÊRENCIAS.....	96

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO E HIPÓTESE

A ocorrência de plantas aquáticas em reservatórios de hidrelétricas é um problema de importância crescente no Brasil. Alguns reservatórios já têm sua eficiência comprometida pela elevada infestação de plantas aquáticas tanto marginais e flutuantes como submersas.

Grandes reservatórios se caracterizam por apresentar um gradiente espacial na carga de sedimentos e nutrientes ao longo de seu corpo o que, aliado ao tamanho dos reservatórios brasileiros, tornam seu monitoramento extremamente caro e demorado. Nesse sentido, o Sensoriamento Remoto pode se constituir em uma fonte complementar de dados para o monitoramento da qualidade da água em grandes reservatórios (NOVO et al., 1989).

Devido ao seu caráter sinóptico e repetitivo, as imagens de satélite podem se constituir, então, em um recurso auxiliar no processo de mapear e monitorar a distribuição espacial de alguns componentes presentes no corpo d'água, como por exemplo, a ocorrência de plantas aquáticas em reservatórios de hidrelétricas.

Levando-se em conta o exposto e a disponibilidade de imagens multiespectrais e multitemporais como um valioso registro sobre a ocorrência de um fenômeno particularmente importante no contexto da utilização da água para navegação e geração de energia, principalmente, deve-se considerar a possibilidade de utilizar tais dados para avaliar a dinâmica deste problema.

A proposta deste trabalho é buscar um método que permita usar

dados multiespectrais adquiridos em diferentes momentos do tempo para monitorar a evolução de áreas infestadas por plantas aquáticas em reservatórios. Para isso, são utilizadas técnicas de análise de imagens multiespectrais e geoestatística, no sentido de verificar a possibilidade de estimar um modelo do comportamento, no espaço e no tempo, da ocorrência dessas plantas aquáticas.

A modelagem da distribuição espaço-temporal de fenômenos dinâmicos é reconhecidamente importante em vários campos científicos e das engenharias, porém, sua implementação não é trivial, principalmente quando a variável em questão deve ser analisada em diferentes domínios: multiespectral, espacial e temporal. Nesta proposta, o aspecto multiespectral é tratado a fim de caracterizar a dimensão espacial do fenômeno analisado e, a partir dessa caracterização, é ajustado um modelo para representar sua variabilidade temporal. Por fim, as componentes espacial e temporal, obtidas separadamente, são integradas em um único modelo espaço-temporal, conforme proposto por De Iaco, Myers e Posa (2001), que permite caracterizar a estrutura da dispersão espaço-temporal do fenômeno.

Diante do exposto, a idéia central deste trabalho baseia-se na hipótese de que, identificado um fenômeno passível de ser registrado em imagens multiespectrais e uma variável correlacionada no espaço e no tempo a qual represente este fenômeno, a geoestatística pode ser utilizada para se obter um modelo que mostre o comportamento desta variável no espaço e no tempo.

1.2 OBJETIVO

O objetivo deste trabalho é obter um modelo que represente o

comportamento, no espaço e no tempo, de uma variável relacionada com a ocorrência de plantas aquáticas em um reservatório no qual o fenômeno se manifeste. Para viabilizar esse propósito, é utilizada uma combinação de técnicas de transformação de imagens multiespectrais e de geoestatística, contribuindo, deste modo, com estudos que envolvam a identificação, caracterização e monitoramento de plantas aquáticas em grandes reservatórios.

1.3 JUSTIFICATIVA

O manejo das plantas aquáticas tornou-se alvo de estudos nos últimos anos, devido à disseminação de áreas infestadas e aos prejuízos provocados por esse tipo de vegetação em reservatórios de usinas hidrelétricas. Infestações por plantas afetam prejudicialmente o consumo, a recreação de contato direto, a navegação e a geração de energia elétrica e, nesse último caso, o controle dessas infestações exige constante manutenção de grades de tomada de água das turbinas de hidrelétricas, o que muitas vezes interrompe o processo de geração de energia. Devido a esses problemas e ao alto custo do controle mecânico, vários estudos vêm sendo realizados com o intuito de otimizar o processo, ou mesmo encontrar alternativas para um possível manejo.

O Sensoriamento Remoto pode se constituir em uma ferramenta útil para monitorar a ocorrência dessas plantas, já que a presença de áreas infestadas por plantas aquáticas marginais e flutuantes é facilmente perceptível em imagens tomadas no intervalo espectral do infravermelho próximo. Assim, a partir de imagens adquiridas por sensores orbitais é possível avaliar a evolução das comunidades e subsidiar estimativas do potencial atual e futuro de danos causados por essas

populações ao meio ambiente e à utilização da água para suas várias finalidades, especialmente para a geração de energia elétrica (ESPINHOSA, 2004).

Outro aspecto a ser considerado é que a grande maioria dos trabalhos relacionados com a aplicação da geoestatística trata somente da componente espacial (localização geográfica) do fenômeno de interesse, visando apenas sua espacialização. Por outro lado, trabalhos que relacionam a aplicação da geoestatística em análises de séries temporais, quase sempre, não utilizam a componente espacial, sendo a geoestatística apenas uma ferramenta complementar. Já a concepção proposta neste trabalho visa contribuir com estudos em que se busque caracterizar um fenômeno *no espaço e no tempo, integrando-se as duas dimensões em um único modelo*. Além disso, por se tratar de um fenômeno ambiental, registrado em imagens multiespectrais e multitemporais, cada uma das etapas necessárias para se chegar ao modelo final é cuidadosamente avaliada, garantindo-se maiores consistência e domínio do processo.

1.4 ESTRUTURA DO TRABALHO

Neste capítulo introdutório, é delineado o assunto a ser tratado, sendo feitas algumas considerações que sustentam a hipótese formulada, bem como explicitados o objetivo e a justificativa do trabalho.

No segundo capítulo são apresentados os conceitos relativos ao Sensoriamento Remoto que fundamentam o trabalho, tais como o comportamento espectral da água e da vegetação aquática, a descrição dos sistemas sensores envolvidos no experimento, as principais técnicas de processamento digital de imagens multiespectrais, bem como a utilização dos índices de vegetação.

No terceiro capítulo são abordados os conceitos relacionados à Geoestatística, considerando apenas o aspecto espacial do fenômeno. Fez-se uma revisão detalhada e abrangente, iniciando-se pelas variáveis regionalizadas e hipóteses de estacionariedade – que constituem a base da geoestatística – passando-se pela função semivariograma e modelos teóricos, até o método de interpolação por krigagem.

No quarto capítulo são destacadas algumas abordagens temporais e espaço-temporais que utilizam como ferramenta principal a geoestatística. Também neste capítulo são apresentados alguns modelos de covariância que integram as componentes espaciais e temporais, dando ênfase ao modelo produto-soma generalizado, utilizado no experimento.

No quinto capítulo é apresentado o experimento realizado, destacando a área de estudo, o material utilizado, o método inicialmente proposto, as etapas desenvolvidas no experimento e os respectivos resultados.

No sexto e último capítulo são apresentadas as conclusões do trabalho, confrontando com o objetivo proposto e, com base na experiência acumulada, são feitas recomendações no sentido de aprofundar algumas questões tratadas no trabalho, bem como sugestões para investigações futuras.

2 SENSORIAMENTO REMOTO

O Sensoriamento Remoto pode ser definido como a utilização conjunta de modernos sensores, equipamentos para processamento e transmissão de dados, aeronaves e espaçonaves, que tem por objetivo o estudo das interações no ambiente terrestre, sem o contato físico direto com as feições, entre a radiação eletromagnética e as substâncias componentes do planeta em suas diversas manifestações (NOVO, 1989). Em outras palavras, nada mais é do que “identificar à distância”, ou seja, identificar alvos da superfície através de medições realizadas por sensores que registram a radiação eletromagnética, a fim de se obter informações e apresentá-las de forma prática, como por exemplo, através de imagens, mapas, gráficos, etc.

Ao interagir com a superfície terrestre, a radiação eletromagnética pode sofrer absorção, reflexão e transmissão, dependendo das propriedades dessa superfície e do intervalo espectral considerado. Os comprimentos de onda nos quais a radiação é refletida e transmitida são utilizados na identificação dos alvos em Sensoriamento Remoto.

Assim, a reflectância espectral, caracterizada dentro de um intervalo de comprimento de onda e segundo uma determinada geometria de aquisição, define o comportamento espectral de um alvo, sendo esta definição amplamente utilizada para a caracterização dos diversos componentes da superfície terrestre. A Figura 1 apresenta o comportamento espectral dos principais tipos de alvos:

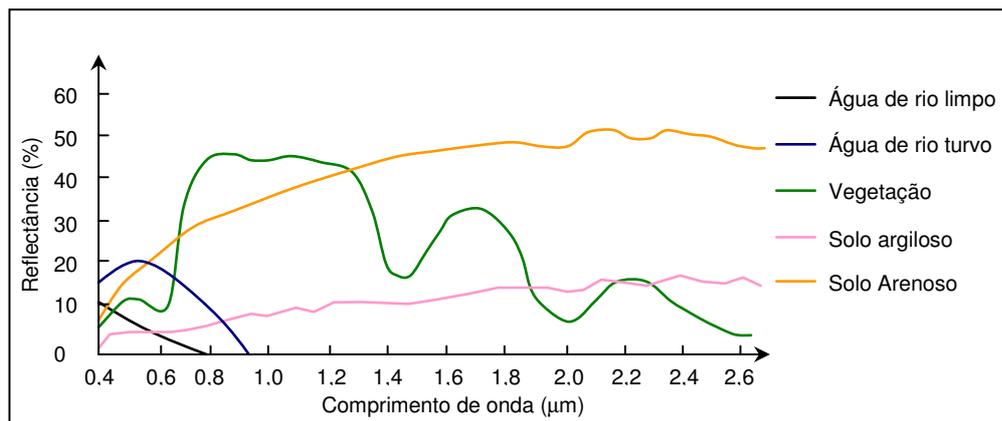


Figura 1 – Comportamento espectral dos principais tipos de alvos. (Adaptado de FLORENZANO, 2002).

2.1 COMPORTAMENTO ESPECTRAL DA ÁGUA E DA VEGETAÇÃO AQUÁTICA

Diferente do solo e da vegetação, a maior parte do fluxo radiante incidente sobre a água não é refletida, mas absorvida ou transmitida. Nos comprimentos de onda do visível, pouca luz é absorvida, uma pequena quantidade é refletida e a maior parte é transmitida. Moreira (2001) destaca que a água no estado líquido absorve toda a radiação eletromagnética abaixo de 380nm e acima de 700nm e que, mesmo nessa faixa intermediária, a reflectância da água é relativamente pequena, ultrapassando pouco mais de 5%. Especificamente para a água pura, a reflectância no espectro visível decresce cerca de 5% no azul para menos de 1% no infravermelho próximo (NOVO et al., 1989). Desse modo, a forte absorção da radiação do infravermelho próximo e médio pela água resulta em um forte contraste entre a água e os limites de terra.

Segundo Robin (1995), a água pura tem uma resposta espectral característica: sua reflectância é elevada no intervalo espectral correspondente à luz azul, diminui no verde, é fraca no vermelho e quase nula no infravermelho próximo. Na realidade, a água absorve inteiramente a radiação do infravermelho próximo incidente já nos primeiros milímetros da coluna d'água.

Novo et al. (1994) relatam que os componentes da água absorvem seletivamente a luz que chega a coluna d'água. Os pigmentos fotossinteticamente ativos são responsáveis pela absorção nas regiões espectrais do azul e do vermelho, de modo que um aumento na quantidade de fitoplâncton na água produz uma redução na quantidade dessa energia. A matéria orgânica dissolvida também altera o coeficiente de absorção da água, ocorrendo um máximo na região do azul e decrescendo com o comprimento de onda.

Quanto à vegetação aquática marginal e flutuante, esta se comporta com o mesmo padrão da vegetação fotossinteticamente ativa: apresenta, geralmente, um nível de reflectância mais baixo na faixa espectral do visível, com um pico de reflexão entre 0,5 a 0,6 μm (luz verde) e valores menores nas regiões correspondentes ao azul (0,4 a 0,5 μm) e vermelho (0,6 a 0,7 μm), em função das absorções de energia pelos pigmentos foliares. Na região do infravermelho próximo (0,7 a 1,3 μm) verifica-se um nível mais elevado na reflectância da vegetação devido à interferência da estrutura histológica das folhas. Nos comprimentos de onda entre 1,3 a 2,5 μm , essa reflectância é dominada pelo conteúdo de água das folhas (NOVO, 1989).

Tentativas de correlacionar a resposta espectral com a ocorrência de componentes que indiquem a qualidade da água em grandes reservatórios têm sido relatadas desde que as imagens orbitais do sensor MSS (*MultiSpectral Scanner*) do satélite Landsat tornaram-se disponíveis. Com a disponibilidade das imagens do sensor TM (*Thematic Mapper*), foram realizados experimentos para verificar se o aumento na resolução espacial dessas imagens permitiria estimativas da concentração dos componentes individuais da água. No entanto, conforme salienta NOVO et al. (1994), a maior limitação desses dados é sua resolução espectral

inadequada para estudos da água, a qual não permite discriminar componentes opticamente ativos, principalmente quando ocorrem simultaneamente altas concentrações de clorofila e material inorgânico.

Por outro lado, Galo et al. (2002) destacam que muito embora o sensor TM não tenha sido projetado para estudos da água, os dados obtidos permitem detectar apropriadamente áreas infestadas por plantas aquáticas em grandes reservatórios, principalmente macrófitas marginais e flutuantes. Além disso, a possibilidade de aquisição sistemática de imagens de uma mesma área geográfica, constitui um aspecto de grande importância no monitoramento dos grandes reservatórios, além de ser uma fonte imprescindível de dados históricos.

2.2 SISTEMAS SENSORES

Os sistemas de aquisição de dados de Sensoriamento Remoto, definidos como sistemas sensores, constituem-se de qualquer equipamento capaz de transformar a radiação eletromagnética refletida pelos alvos da superfície terrestre em um sinal passível de ser convertido em informações sobre o meio ambiente (NOVO, 1989). Dentre a grande variedade de equipamentos que apresentam essa capacidade, podem ser destacados os sensores imageadores, os quais fornecem como produto uma imagem da cena observada.

Conforme descreve Novo (1989), os diferentes sistemas sensores são caracterizados pela sua resolução, definida como uma medida da habilidade que o sensor possui de distinguir entre respostas espectralmente semelhantes e espacialmente próximas. Além da resolução espacial que mede a menor separação linear ou angular entre dois objetos da superfície terrestre, os sistemas de varredura

instalados em satélites podem ser caracterizados em termos de sua resolução espectral, que é uma medida da largura das faixas espectrais nas quais o sensor opera; resolução radiométrica, relacionada com a sensibilidade do sensor em distinguir entre dois níveis de intensidade do sinal de retorno; e a resolução temporal, relativa ao intervalo de tempo entre a aquisição de duas imagens de uma mesma área.

A aquisição de dados de Sensoriamento Remoto, com aplicação em recursos naturais pode ser feita através de sensores instalados em plataformas orbitais, como é o caso dos sistemas Landsat, CBERS e Ikonos.

Os satélites do sistema Landsat adquirem imagens dos alvos terrestres através de dois sensores: TM (*Thematic Mapper*) e ETM+ (*Enhanced Thematic Mapper Plus*).

O sensor TM possui um sistema de varredura multiespectral com uma resolução espacial de 30m. Possui sete bandas, sendo que as bandas 1, 2, 3, 4, 5 e 7 possuem resolução espacial de 30m e a banda 6 possui resolução espacial de 120m.

A Tabela 1 mostra as faixas espectrais do sensor TM e suas principais aplicações.

O sensor ETM+ possui as mesmas bandas do sensor TM, com pequenas alterações nas faixas espectrais, além da banda Pan (banda pancromática com resolução espacial de 15m), que permite aplicações que envolvem a área urbana. A banda termal (banda 6) passa a ter 60m de resolução espacial. A resolução temporal é de 26 dias.

Tabela 1 – Bandas do sensor TM e suas aplicações.
(Adaptado e modificado de NOVO, 1989).

Banda	Faixa Espectral (μm)	Principais Aplicações
1	0,45 - 0,52 (luz visível - azul/verde)	Mapeamento de águas costeiras Diferenciação entre solo e vegetação Boa penetração em corpos d'água
2	0,52 - 0,60 (luz visível - verde)	Reflectância de vegetação verde sadia Identificação de sedimentos em suspensão na água Noção de qualidade da água
3	0,63 - 0,69 (luz visível - vermelho)	Absorção de clorofila Diferenciação de espécies vegetais Mapeamento de drenagens através das matas ciliares
4	0,76 - 0,90 (infravermelho próximo)	Levantamento de biomassa Delineamento de corpos d'água Mapeamento de feições geológicas e estruturais
5	1,55 - 1,75 (infravermelho médio)	Medidas de umidade da vegetação Diferenciação entre neve e nuvens Medidas de estresse hídrico da vegetação Estudos de fenologia
6	10,4 - 12,5 (infravermelho distante)	Mapeamento de estresse térmico em plantas Outros mapeamentos térmicos
7	2,08 - 2,35 (infravermelho próximo)	Mapeamento hidrotermal Estudos de geologia e geomorfologia

Os satélites do sistema CBERS (*China-Brazil Earth Resources Satellite* ou satélite sino-brasileiro de recursos terrestres) – CBERS-1 e CBERS-2, lançados respectivamente em 1999 e 2003 – adquirem imagens através de três sensores: CCD (que é uma câmara imageadora de média resolução), IRMSS (um imageador por varredura de baixa resolução) e WFI (uma câmara imageadora de amplo campo de visada). O sensor CCD adquire imagens com uma resolução espacial de 20 m, podendo orientar seu campo de visada dentro de $\pm 32^\circ$. Opera em 5 bandas, sendo 1 banda pancromática, com abrangência espectral de 0,51 a 0,73 μm , e 4 bandas espectrais: 0,45 a 0,52 μm (luz visível - azul), 0,52 a 0,59 μm (luz visível - verde), 0,63 a 0,69 μm (luz visível - vermelho) e 0,77 a 0,89 μm (infravermelho próximo). As resoluções espacial (de 20m) e radiométrica (de 8 bits)

são as mesmas para todas as bandas. A resolução temporal é de 26 dias, usando visada vertical, ou de 3 dias usando a visada lateral (CENTENO, 2003).

Também em 1999, com o sucesso do lançamento do satélite Ikonos II, a comunidade de Sensoriamento Remoto passou a dispor das imagens de alta resolução geradas a partir dessa plataforma. Os dados orbitais do Ikonos são disponibilizados em dois modos de aquisição: pancromático e multiespectral. Os dados pancromáticos apresentam resolução espacial de 1m no terreno e abrangência espectral de 0,53 a 0,93 μ m. As imagens multiespectrais têm resolução espacial de 4m e são obtidas em 4 bandas espectrais correspondentes aos intervalos de comprimento de onda entre 0,45 a 0,52 μ m (luz visível - azul), 0,52 a 0,60 μ m (luz visível - verde), 0,63 a 0,69 μ m (luz visível - vermelho) e 0,76 a 0,90 μ m (infravermelho próximo). Independente do modo de aquisição, a resolução radiométrica é de 11 bits (2048 níveis de cinza), proporcionando um maior poder de contraste e discriminação para as imagens produzidas. A resolução temporal é de aproximadamente 3 dias para o modo pancromático e 1,5 dias para o modo multiespectral (MOREIRA, 2001).

2.3 PROCESSAMENTO DIGITAL DE IMAGENS MULTIESPECTRAIS

Os dados de Sensoriamento Remoto obtidos em diferentes bandas, que registram a radiação eletromagnética em diferentes intervalos espectrais, constituem uma imagem multiespectral, a qual é formada por conjunto de imagens tomadas simultaneamente de uma mesma área. Assim, uma imagem multiespectral pode ser entendida como uma representação k-dimensional, ou seja, cada pixel na imagem é constituído por k valores de brilho (ou nível digital – ND), um em cada

banda, formando um vetor espectral. Uma representação de uma imagem multiespectral é apresentada na Figura 2:

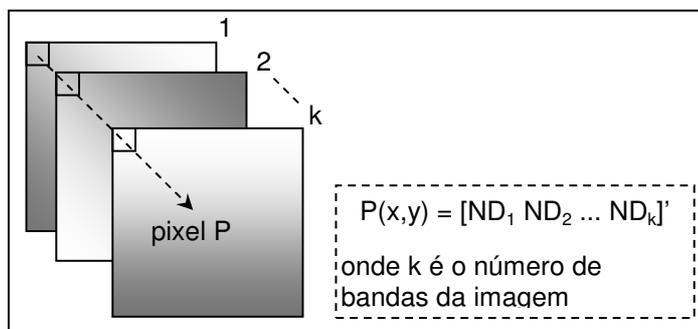


Figura 2 – Representação k-dimensional de uma imagem multiespectral.
(Adaptado de RICHARDS, 1986).

Dois tipos de processamentos de imagens multiespectrais são imprescindíveis em qualquer estudo que envolva o aspecto temporal: o registro e a normalização radiométrica, a fim de garantir a consistência geométrica e radiométrica, respectivamente.

2.3.1 Registro

O registro, pressuposto básico para a análise simultânea de cenas adquiridas em diferentes épocas, assegura que os pixels que compõem o conjunto de imagens multitemporais analisadas contemplem uma mesma região da superfície terrestre. Esse procedimento difere do georreferenciamento pelo fato de considerar uma das datas de aquisição de dados como referência, e não necessariamente um sistema de referenciamento conhecido.

Richards (1986), descreve o registro de imagens digitais, como um procedimento desenvolvido a partir da identificação de feições, denominadas pontos de controle, com localização definida em termos de coordenadas em um

determinado referencial e que podem ser posicionadas nas imagens, em termos de coordenadas X e Y. Esses valores que apresentam correspondência nos dois sistemas – da imagem de referência ou mapa e da imagem a ser registrada – são submetidos uma análise de regressão pelo método dos mínimos quadrados, a fim de se determinar os coeficientes das equações de transformação de coordenadas (usualmente transformações polinomiais de 1º ou 2º grau). Posteriormente, é utilizado um processo de reamostragem para determinar os valores apropriados de intensidade radiométrica para as novas posições na imagem transformada, com base nos valores presentes na imagem original.

2.3.2 Normalização radiométrica

Procedimentos de correção radiométrica são empregados na tentativa de remover as variações externas e independentes da cena. Tais técnicas, em geral, prevêm a aquisição de parâmetros extra-cena durante a passagem do satélite, o que pode inviabilizar algumas aplicações de dados multitemporais. Na tentativa de viabilizar a análise de séries temporais, Schott et al. (1988)¹ apud Galo e Novo (2000), desenvolveram uma técnica de normalização radiométrica cena a cena que resulta em uma alteração das imagens para que estas pareçam ter sido imageadas nas mesmas condições atmosféricas e de iluminação de uma imagem de referência da mesma área, aproximando os valores de média e desvio-padrão da imagem tomada como referência com os das imagens a serem normalizadas. Esta normalização radiométrica é feita, pixel a pixel, através da seguinte expressão (Galo e Novo, 2000):

¹ Schott, J. R.; Salvaggio, C.; Volchok, W. J. Radiometric scene normalization using pseudoinvariant features. *Remote Sensing of Environment*, 26(1), p. 1-16, 1988.

$$I_{(i,j)_N} = \frac{S_R}{S_{AN}} (I_{(i,j)_{AN}} - \overline{I_{AN}}) + \overline{I_R} \quad (1)$$

onde $I_{(i,j)_N}$ representa o valor de brilho do pixel (i,j) da imagem resultante da normalização; S_R e S_{AN} são os desvios-padrão da imagem de referência e da imagem a ser normalizada, respectivamente; e $\overline{I_R}$ e $\overline{I_{AN}}$ referem-se às médias da imagem de referência e da imagem a ser normalizada, respectivamente.

Devido ao caráter multiespectral da maioria das imagens de Sensoriamento Remoto é possível executar transformações espectrais que produzem novos conjuntos de componentes ou imagens. As principais características dessas transformações é que o novo conjunto de imagens pode evidenciar feições que não são discerníveis nos dados originais, ou alternativamente, podem preservar as informações essenciais contidas na cena (para determinadas aplicações), diminuindo-se a dimensionalidade dos dados. Uma destas transformações é a geração dos índices de vegetação.

2.4 TRANSFORMAÇÕES ESPECTRAIS: ÍNDICE DE VEGETAÇÃO

Os índices de vegetação foram criados como uma tentativa de ressaltar o comportamento espectral da vegetação em relação ao solo e outros alvos da superfície terrestre. São quantidades obtidas através da razão, diferença ou de qualquer outra transformação espectral de dados, para a representação das características da cobertura vegetal, tais como: índice de área foliar, fitomassa, peso da vegetação úmida, peso da vegetação seca, porcentagem de cobertura vegetal, etc. Os índices de vegetação podem ser calculados tanto a partir de dados orbitais, quanto de medições radiométricas de campo.

Segundo Moreira (2001), o uso de índices de vegetação para caracterizar e quantificar um dado parâmetro biofísico da vegetação permite reduzir a dimensão das informações multiespectrais para um único número, além de minimizar o efeito das condições de iluminação e visada, bem como fornecer um número que é altamente correlacionado com parâmetros agronômicos.

As técnicas de realce de imagem por meio de índices de vegetação aumentam o brilho das áreas vegetadas, melhorando a aparência da distribuição espacial de informações das imagens tornando-as de fácil interpretação visual e computacional (SHIMABUKURO, 1991).

Em função de várias alternativas (tipo de sensor, aplicações) foram desenvolvidos muitos modelos de índices de vegetação, dentre eles o que mais se destaca é o da diferença normalizada.

O índice de vegetação da diferença normalizada ou *Normalized Difference Vegetation Index* (NDVI) é um dos índices mais utilizados em Sensoriamento Remoto, devido a seu bom desempenho em realçar a vegetação. É dado pela razão da diferença entre os valores representados em duas bandas – a banda do infravermelho próximo (IVP), na qual os valores de brilho aumentam com o aumento da vegetação, e a banda do vermelho (V), onde os valores de brilho decrescem com o aumento da vegetação – e a soma destes mesmos valores nessas duas bandas, sendo portanto altamente sensível à vegetação. O parâmetro ou índice, calculado pixel a pixel, é expresso por (RICHARDS, 1986):

$$\text{NDVI} = \frac{\text{IVP} - \text{V}}{\text{IVP} + \text{V}} \quad (2)$$

Este índice se diferencia dos demais principalmente pelo fato de seus valores estarem todos representados no intervalo numérico de -1 a 1, onde

valores próximos a -1 são associados à água e os próximos a 1 à vegetação sadia.

3 GEOESTATÍSTICA

Segundo Camargo (1997), Daniel G. Krige, em 1951, trabalhando com dados de concentração de ouro, verificou que somente a informação dada pela variância seria insuficiente para explicar o fenômeno em estudo. Para tal, seria necessário levar em consideração a distância entre as observações. Baseado nos estudos de Krige, Georges Matheron desenvolve, em 1971, a Teoria das Variáveis Regionalizadas, segundo a qual os valores assumidos por uma variável estão, de alguma maneira, relacionados à sua disposição espacial e, portanto, as observações tomadas a curta distância se assemelham mais do que aquelas tomadas a distâncias maiores. Tal teoria é a base da geoestatística, que leva em consideração a *localização geográfica e a dependência espacial*. Matheron (1971)² apud Monteiro (2003) define a geoestatística como sendo a aplicação do formalismo matemático de funções aleatórias ao reconhecimento e predição de fenômenos naturais. Neste contexto, assume-se que fenômenos naturais são aqueles caracterizados pela distribuição espacial de uma ou mais variáveis, denominada variável regionalizada.

3.1 VARIÁVEIS REGIONALIZADAS

Uma variável regionalizada é uma função numérica com distribuição espacial, que varia de um ponto a outro com continuidade aparente, mas cujas variações não podem ser representadas por uma função matemática simples (MATHERON, 1971 apud MONTEIRO, 2003).

As variáveis regionalizadas possuem características específicas,

² MATHERON, G. *The theory of regionalized variables and its applications*. Paris: École de Mines de Paris, 1971. 211 p.

como:

- **Localização:** ainda que a variável regionalizada seja contínua no espaço, geralmente não é possível conhecer seus valores em todos os pontos, mas sim apenas em alguns que foram obtidos por amostragem. O tamanho, a forma, a orientação e o arranjo espacial dos elementos da amostra constituem o suporte da variável regionalizada, que apresentará características diferentes se qualquer um desses atributos for modificado (LANDIM, 1998);
- **Anisotropia:** diversas variáveis regionalizadas são anisotrópicas, isto é, sua variabilidade espacial ocorre mais intensamente numa direção e menos intensamente em outra, sendo esta uma característica muito freqüente em fenômenos naturais (DRUCK et al., 2004);
- **Continuidade:** está diretamente relacionada ao conceito de dependência espacial, ou seja, elementos próximos espacialmente tendem a assumir valores mais similares do que elementos que estão distantes entre si (ISAACS e SRIVASTAVA, 1989). Dependendo do fenômeno observado, a variabilidade espacial de uma variável regionalizada pode ser grande (implicando em baixa continuidade) ou pequena (alta continuidade). Apesar da complexidade das flutuações, uma continuidade média geralmente está presente. Esta continuidade é exemplificada por Olea (1975)³ apud Camargo (1997), em um caso hipotético, onde observações amostrais de solo, de mesmo tamanho, forma e orientação são coletadas em intervalos regulares ao longo de linhas imaginárias. Essas amostras podem originar duas séries distintas para a percentagem de H₂O (água) encontrada, conforme apresentado na Tabela 2, abaixo:

³ OLEA, R. A. *Optimum mapping techniques using regionalized variable theory*. Lawrence: University of Kansas, 1975. 137 p. (Series on Spatial Analysis, 2)

Tabela 2 – Exemplo: continuidade.
(Fonte: OLEA, 1975 apud CAMARGO, 1997)

Série A (% H₂O)	5	10	15	20	25	20	15	10	5
Série B (% H₂O)	10	25	15	10	20	5	15	5	20

Na Tabela 2, os valores individuais nas duas amostras são exatamente os mesmos. Portanto a média e a variância amostral, assim como o histograma de freqüência da variável observada nas amostras A e B, são rigorosamente idênticos. Qualquer análise que não leve em consideração outras estatísticas além da média, da variância e do histograma, não diferencia as duas séries. Este exemplo enfatiza a importância da medida da continuidade espacial da variável regionalizada. Assim, torna-se necessário considerar a posição espacial relativa de cada uma das observações nas duas amostras, para que as mesmas sejam diferenciadas. A continuidade espacial da variável regionalizada pode ser analisada a partir do semivariograma, a ser apresentado adiante na Seção 3.2.

A teoria das variáveis regionalizadas pressupõe que a variação de uma variável pode ser expressa pela soma de três componentes (BURROUGH, 1987⁴ apud CAMARGO, 1997): a) uma componente estrutural, associada a um valor médio constante ou a uma tendência constante; b) uma componente aleatória, espacialmente correlacionada; e c) um ruído aleatório ou erro residual.

Seja s uma posição numa área A , ou seja, s representa (para maiores simplificações) um par de coordenadas locais (x, y) . Sendo $z(s)$ o valor de uma variável aleatória Z na posição s , $z(s)$ é uma variável regionalizada. O conjunto dessas variáveis aleatórias pode ser considerado uma função aleatória, simbolizada por $Z(s)$, e prevendo-se que a dependência entre elas seja regida por algum mecanismo probabilístico (ISAAKS e SRIVASTAVA, 1989), tem-se que:

$$Z(s) = m(s) + \varepsilon'(s) + \varepsilon'' \quad (3)$$

onde,

- $m(s)$ é uma função determinística que descreve a componente estrutural de Z em s ;
- $\varepsilon'(s)$ é o termo estocástico que varia localmente e depende espacialmente de $m(s)$;
- ε'' é um ruído aleatório não correlacionado (com distribuição normal).

A Figura 3 (a e b) ilustra essas três componentes, sendo que na Figura 3.a a variável regionalizada apresenta uma componente determinística que varia abruptamente, enquanto a componente determinística na Figura 3.b apresenta uma tendência constante.

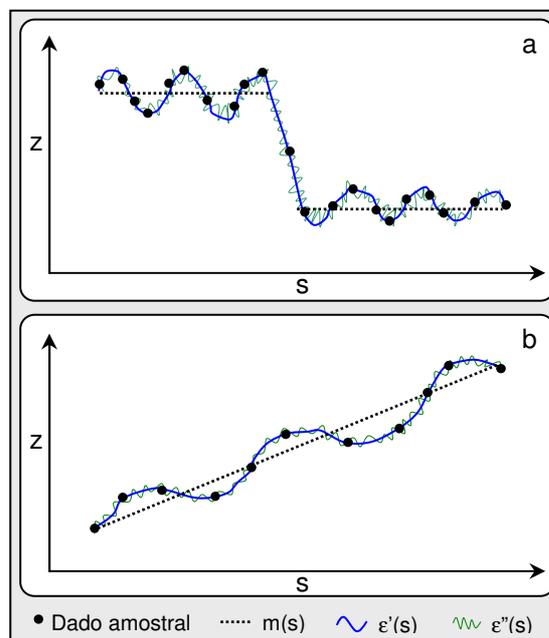


Figura 3 (a e b) – Principais componentes da variação espacial.
(Modificada de BURROUGH, 1987 apud CAMARGO, 1997).

⁴ BURROUGH, P. A. *Principles of geographical information systems for land resources assessment*. Oxford: Clarendon Press, 1987.

De fato, tem-se acesso a uma única realização $z(s)$ da função aleatória $Z(s)$, por não ser possível inferir a lei de distribuição de probabilidades da variável aleatória considerada. Assim sendo, para que seja possível qualquer forma de inferência baseada em dados disponíveis, o modelo adotado para a função aleatória deve ser estacionário.

Uma variável regionalizada é considerada estacionária se os momentos estatísticos da variável aleatória $Z(s+h)$ forem constantes para qualquer vetor h . De acordo com o número k de momentos estatísticos que são constantes, a variável é chamada estacionária de ordem k (CAMARGO, 1997). Vale-se ressaltar que se uma variável é estacionária de ordem k , isto implica que ela seja estacionária de ordem $k-1$. Em geoestatística a estacionariedade de ordem 2 é ideal, no entanto, a estacionariedade intrínseca já é suficiente.

3.1.1 Hipótese de estacionariedade de ordem 2

Uma função aleatória $Z(s)$ é estacionária de ordem 2 se:

- A esperança matemática de $Z(s)$ é constante (não há tendências na região considerada, ou seja, a componente determinística $m(s) = \text{constante}$) e não depende da posição s , caracterizando a estacionariedade da média (estacionariedade de ordem 1):

$$E\{Z(s)\} = E\{Z(s+h)\} = m(s) = m \quad \text{e} \quad E\{Z(s)-Z(s+h)\} = 0 \quad (4)$$

- Para cada par de variáveis $Z(s)$ e $Z(s+h)$, a covariância deve existir e depender somente de h , caracterizando a estacionariedade da covariância:

$$C(h) = \text{Cov}[Z(s), Z(s+h)] = \{Z(s) \cdot Z(s+h)\} - m^2, \forall s \quad (5)$$

A estacionariedade da covariância também implica na estacionariedade do variograma, definido por:

$$2\gamma(h) = E\{[Z(s) - Z(s+h)]^2\} \quad (6)$$

onde $2\gamma(h)$ representa uma função conhecida como variograma, sendo que $\gamma(h)$ representa a função semivariograma (metade do variograma), que será detalhada na Seção 3.2.

Se a hipótese de estacionariedade de ordem 2 for satisfeita, a covariância e o semivariograma são formas alternativas para caracterizar a dependência espacial, ou seja, a correlação dos pares $Z(s)$ e $Z(s+h)$ separados pelo vetor h .

No entanto, nem todos os fenômenos apresentam variância finita, isto é, algumas variáveis têm capacidade infinita de dispersão. Porém, o semivariograma $\gamma(h)$ pode existir. Nesses casos, deve-se trabalhar com uma hipótese menos restritiva, mas suficiente à maior parte das aplicações de geoestatística linear: a hipótese de estacionariedade intrínseca.

3.1.2 Hipótese de estacionariedade intrínseca

Uma função aleatória $Z(s)$ é estacionária intrínseca se:

- Atender o critério de estacionariedade de ordem 1 (estacionariedade da média), de acordo com a Equação 4;

- Para todo vetor h , a diferença $[Z(s)-Z(s+h)]$ tem uma variância finita, que não depende de s , mas unicamente do vetor h :

$$\text{Var}[Z(s)-Z(s+h)] = E\{[Z(s)-Z(s+h)]^2\} = 2\gamma(h) \quad (7)$$

Esta hipótese requer apenas a estacionariedade do variograma, sem nenhuma restrição quanto à variância.

3.2 SEMIVARIOGRAMA

O semivariograma é uma ferramenta básica de suporte às técnicas de geoestatística, que permite representar quantitativamente a variação de um fenômeno regionalizado no espaço.

De acordo com a Equação 6, tem-se que o variograma é definido como sendo a esperança matemática do quadrado da diferença entre pontos separados no espaço por um vetor h (definido por sua orientação e tamanho). Desse modo, o semivariograma é dado pela metade do variograma, ou seja:

$$\gamma(h) = \frac{1}{2} E\{[Z(s)-Z(s+h)]^2\} \quad (8)$$

Se as condições especificadas pela hipótese intrínseca são contempladas, então o semivariograma pode ser estimado através de um conjunto de elementos amostrais $z(s_i)$, $i=1,2,\dots,n$, por:

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [z(s) - z(s+h)]^2 \quad (9)$$

sendo $\hat{\gamma}(h)$ o *semivariograma experimental* estimado a partir dos elementos amostrais; e $N(h)$ o número de pares de pontos $z(s)$ e $z(s+h)$ separados por um vetor h .

3.2.1 Características do semivariograma

De acordo com Druck et al. (2004), as hipóteses de estacionariedade levam a postular um comportamento idealizado para o semivariograma experimental, como pode ser observado na Figura 4. Espera-se que observações mais próximas geograficamente tenham um comportamento mais semelhante entre si do que aquelas separadas por maiores distâncias. Assim, o valor absoluto da diferença entre dois elementos amostrais $z(s)$ e $z(s+h)$ deveria crescer à medida que aumenta a distância entre eles, até um valor em que os efeitos locais não teriam mais influência. À exceção dos fenômenos com dispersão infinita, nesse caso, sempre haveria alguma influência.

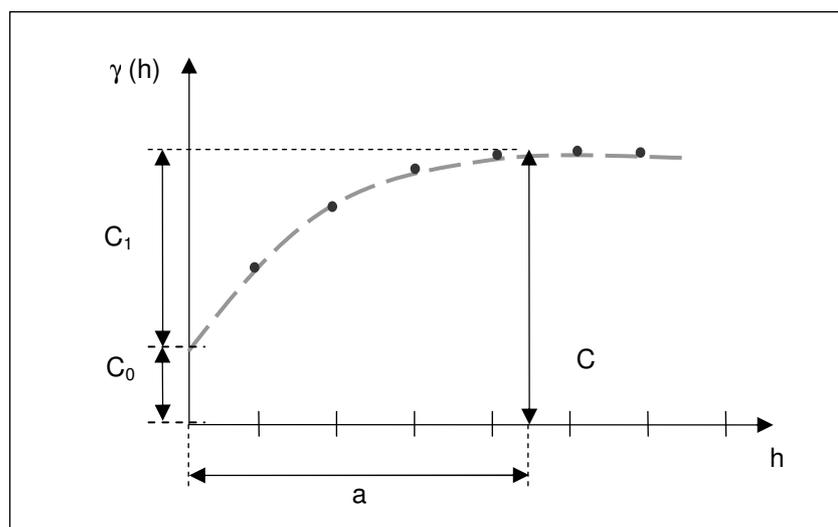


Figura 4 – Parâmetros do semivariograma.
(Fonte: DRUCK et al., 2004).

Os parâmetros do semivariograma, apresentados na Figura 4, são:

- **Efeito pepita (C_0):** quando h tende a zero, $\gamma(h)$ se aproxima de um valor positivo chamado efeito pepita. O valor de C_0 revela a descontinuidade do semivariograma para distâncias menores do que a menor distância entre os elementos amostrais. O efeito pepita é o valor da semivariância para a distância zero e representa a componente da variabilidade espacial que não pode ser correlacionada com uma causa específica (variabilidade ao acaso). Parte dessa descontinuidade pode ser também devida a erros de medição, sendo impossível quantificar se a maior contribuição provém dos erros de medição ou da variabilidade de pequena escala não captada pelo suporte espacial da amostragem;
- **Alcance (a):** é a distância dentro da qual os elementos amostrais apresentam-se correlacionados espacialmente;
- **Patamar (C):** é o valor do semivariograma correspondente a seu alcance (a). Deste ponto em diante, considera-se que não existe mais dependência espacial entre os elementos amostrais, porque a variância da diferença entre pares de elementos ($\text{Var} [Z(s) - Z(s+h)]$) torna-se aproximadamente constante;
- **Contribuição (C_1):** é a diferença entre o patamar (C) e o efeito pepita (C_0).

Casos particulares de semivariograma podem ocorrer. O semivariograma pode ser constante e igual ao patamar. É o que se chama de efeito pepita puro e indica a ausência de dependência espacial.

Por outro lado, o semivariograma pode crescer sem limites, ou seja, nunca atingir o patamar. Este semivariograma mostra que o fenômeno em estudo tem capacidade infinita de dispersão (não possui variância finita e a covariância não pode ser definida).

3.2.2 Cálculo do semivariograma a partir de elementos amostrais irregularmente espaçados

Ao considerar uma amostra constituída por elementos irregularmente espaçados, para determinar um semivariograma experimental (Equação 9) unidirecional, é necessário introduzir limites de tolerância para a direção (tolerância angular) e para a distância (tolerância do *lag*), conforme ilustra a Figura 5:

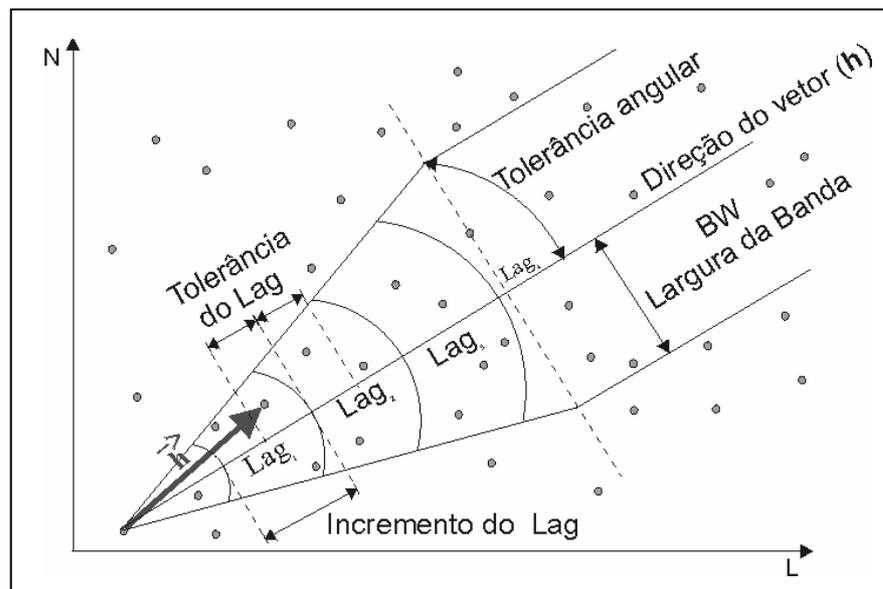


Figura 5 – Parâmetros para o cálculo do semivariograma.
(Modificada de DEUTSCH e JOURNEL,1992).

Analisando-se a Figura 5, pode-se perceber que, devido ao espaçamento irregular dos elementos amostrais, a distância h entre cada par de elementos varia. Devido a esse fato, adota-se uma distância pré-definida que serve de base para estabelecer o número de elementos que serão incluídos no cálculo do semivariograma experimental, denominada *lag*. Para tanto é estabelecida uma tolerância ao *lag* a fim de que se inclua um maior número de elementos amostrais.

Normalmente adota-se para tolerância do *lag* a metade do valor adotado para seu tamanho (ou incremento do *lag*). É necessário também escolher o ângulo, que fornece a direção do vetor h , e sua respectiva tolerância angular.

Tomando-se como referência o Lag_2 na Figura 5, supondo-se um incremento de *lag* igual a 100m com tolerância de 50m e considerando-se ainda a direção de medida 45° com tolerância angular de $22,50^\circ$, então, qualquer par de observações cuja distância esteja compreendida no intervalo 150m→250m e cuja direção esteja no intervalo $22,50^\circ \rightarrow 67,50^\circ$ seria incluído no cálculo do semivariograma do Lag_2 . Este mesmo processo é utilizado para todos os *lags*.

Outro parâmetro que pode ser utilizado no cálculo do semivariograma experimental é a largura de banda (BW), que se refere a um valor de ajuste a partir do qual se restringe o número de pares de observações para o cálculo do semivariograma, conforme observado na Figura 5. Este parâmetro, BW, não é utilizado no cálculo de semivariogramas experimentais omnidirecionais (calculado para todas as direções), onde a tolerância angular é fixada em 90° .

3.3 MODELOS TEÓRICOS

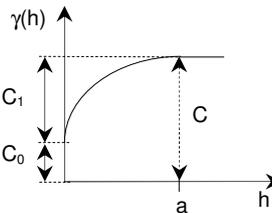
O gráfico do semivariograma experimental, $\hat{\gamma}(h)$, calculado pela Equação 9, é formado por uma série de pontos, conforme ilustra a Figura 4, sobre os quais se objetiva ajustar uma função contínua. É importante que o modelo ajustado represente a tendência de $\hat{\gamma}(h)$ em relação a h .

De acordo com Bailey e Gatrell (1995), a união dos pontos sucessivos de um semivariograma experimental produz um modelo teórico de semivariograma, mas que não é necessariamente um modelo válido. Somente

determinadas funções matemáticas constituem modelos admissíveis para funções de covariância e, da mesma forma, somente algumas funções são válidas para os semivariogramas. As condições necessárias e suficientes para uma função de covariância de um processo espacial geral são: ser simétrica, ou seja, para dois pontos particulares s_i e s_j , $C(s_i, s_j) = C(s_j, s_i) = C(h)$ é igual a $C(s_j, s_i) = C(s_i - s_j) = C(-h)$; e ser não-negativa definida, isto é, $\sum_{i,j=1}^{N(h)} \alpha_i \alpha_j C(s_i, s_j) \geq 0$, para todo $N(h)$, α_i e s_i .

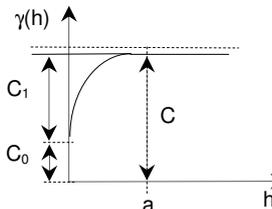
Qualquer combinação linear de covariâncias entre os pares de pontos da área de interesse é sempre positiva ou nula. No caso de processos estacionários, como é o caso, apenas um restrito conjunto destas funções se aplica, isto é, algumas poucas funções podem ser utilizadas como modelo válido de semivariograma. Dentre estas, três dos modelos teóricos de semivariograma mais comumente utilizados, em processos estacionários, são (BAILEY e GATRELL, 1995):

- **Modelo esférico:**



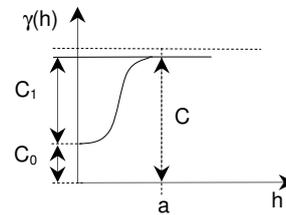
$$\gamma_{\text{sph}}(h) = \begin{cases} C \left(\frac{3h}{2a} - \frac{h^3}{2a^3} \right), & h \leq a \\ C & , h > a \end{cases} \quad (10)$$

- **Modelo exponencial:**



$$\gamma_{\text{exp}}(h) = C \left(1 - e^{-\frac{3h}{a}} \right) \quad (11)$$

▪ **Modelo gaussiano:**



$$\gamma_{\text{gau}}(h) = C \left(1 - e^{-\frac{3h^2}{a^2}} \right) \quad (12)$$

O efeito pepita pode ser introduzido em quaisquer desses modelos, adicionando-se uma constante (C_0) que representa uma descontinuidade na origem e, substituindo o patamar (C) pela contribuição (C_1).

Bailey e Gatrell (1995) observam que o modelo exponencial “atinge” mais rapidamente o patamar do que o modelo esférico. Para o modelo exponencial a reta tangente passante na origem atinge o patamar à cerca de 1/5 do alcance, enquanto que no modelo esférico esta proporção é aproximadamente 2/3. Como ambos são quase lineares próximos à origem, estas características podem auxiliar na escolha de um destes modelos.

Outras formas funcionais válidas são aceitáveis como modelos de variograma, mas são muito pouco utilizadas na prática. Em determinados fenômenos pode ser requerido um modelo mais complexo, sendo necessária a combinação de um ou mais modelos básicos. Esses são chamados de *modelos aninhados*, tais como duplo esférico, duplo exponencial, entre outros, e por serem gerados a partir de combinações lineares dos modelos básicos, têm a garantia de ser um modelo válido de semivariograma.

Modelos com funções periódicas, que incluem por exemplo as funções seno ou cosseno, geralmente são utilizados quando analisado o aspecto

temporal do fenômeno, pois são capazes de representar melhor as variações sazonais.

3.4 ANISOTROPIA

Ao gerar semivariogramas para diversas direções pode-se facilmente constatar se há anisotropia, pois, neste caso, os modelos ajustados ao semivariograma experimental são significativamente diferentes.

No entanto, ao verificar a similaridade entre os semivariogramas experimentais para diferentes direções, um único modelo pode ser ajustado para descrever a variabilidade espacial do fenômeno. Este é o chamado modelo isotrópico. Porém, se a similaridade não for constatada, trata-se de semivariogramas anisotrópicos, ou seja, o fenômeno possui um comportamento anisotrópico. Os principais tipos de anisotropia são: geométrica, zonal e combinada.

3.4.1 Anisotropia geométrica

A anisotropia geométrica ocorre quando, para duas direções diferentes (ortogonais), são ajustados semivariogramas que têm o mesmo patamar, porém, com alcances diferentes, para o mesmo modelo, como mostrado na Figura 6:

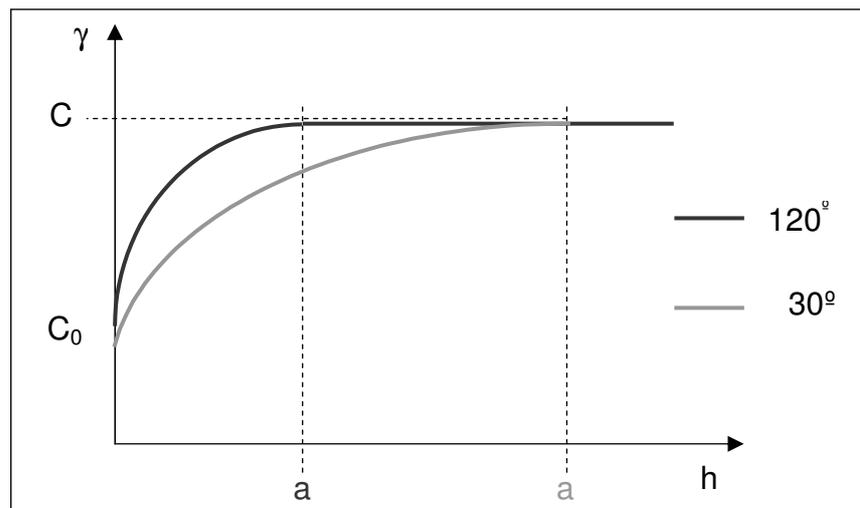


Figura 6 – Representação gráfica de anisotropia geométrica.
(Fonte: CAMARGO, 1997).

A Figura 7, na seqüência, apresenta uma representação espacial de um semivariograma cujo fenômeno em questão apresenta anisotropia geométrica. Nota-se claramente que para diferentes direções há um comportamento diferente, ou seja, a dependência espacial é maior em uma direção do que em outra.

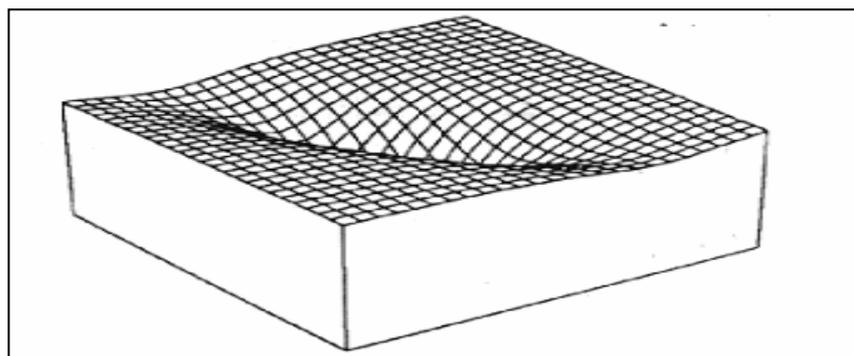


Figura 7 – Superfície de semivariograma com anisotropia geométrica.
(Fonte: ISAAKS e SRIVASTAVA, 1989).

Para visualizar o que acontece na prática, basta esboçar uma elipse tendo como eixo maior o maior alcance e como eixo menor o menor alcance, como mostra a Figura 8.

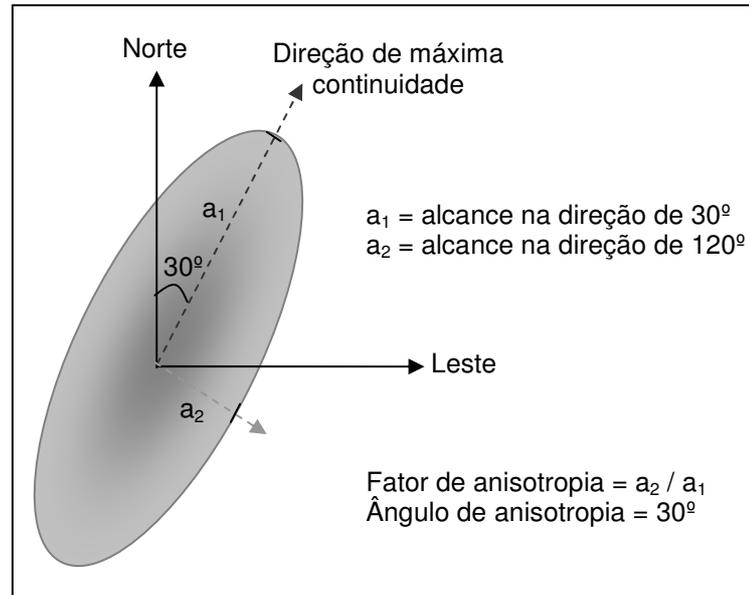


Figura 8 – Representação gráfica da anisotropia geométrica em duas dimensões.
 (Fonte: CAMARGO, 1997).

O fator de anisotropia é a relação entre o menor e o maior alcance e, a direção de maior alcance é chamada de ângulo anisotrópico.

3.4.2 Anisotropia zonal

Esse tipo de anisotropia apresenta os mesmos alcances para patamares diferentes. Mas é um caso menos freqüente.

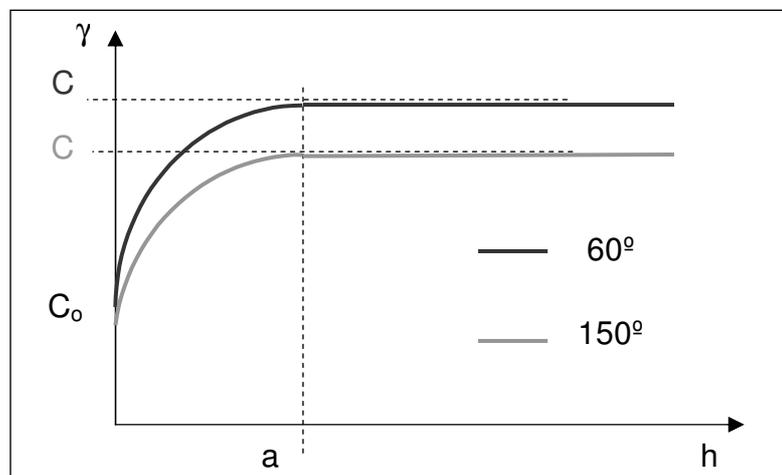


Figura 9 – Representação gráfica de anisotropia zonal.
 (Fonte: CAMARGO, 1997).

3.4.3 Anisotropia combinada

É a combinação da anisotropia geométrica e zonal. Ocorre quando se têm diferentes alcances e diferentes patamares, como ilustra a Figura 10:

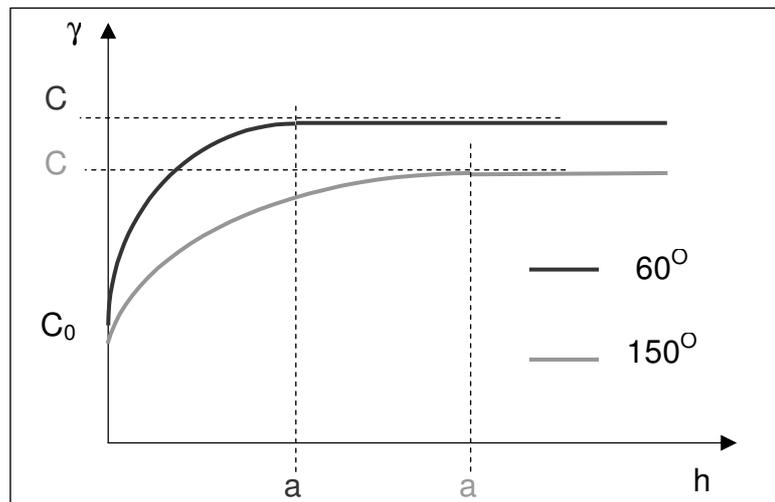


Figura 10 – Representação gráfica de anisotropia combinada.
(Fonte: CAMARGO, 1997).

A Figura 11 apresenta uma representação espacial de um semivariograma cujo fenômeno em questão apresenta anisotropia combinada:

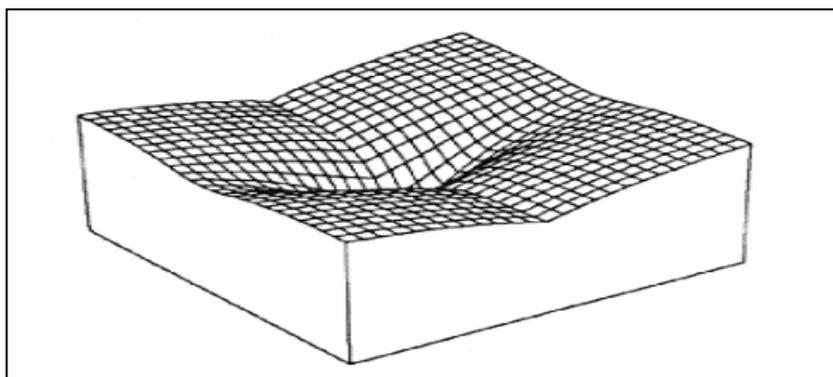


Figura 11 – Superfície de semivariograma com anisotropia combinada.
(Fonte: ISAAKS e SRIVASTAVA, 1989).

3.5 KRIGAGEM

Segundo Landim (1998), krigagem, do francês *krigeage* e do inglês *kriging*, é um termo cunhado pela escola francesa de geoestatística em homenagem ao engenheiro de minas sul-africano e pioneiro na aplicação de técnicas estatísticas em avaliação mineira, Daniel G. Krige. É um processo de estimação de valores de variáveis distribuídas no espaço, a partir de valores adjacentes, enquanto considerados como interdependentes pelo semivariograma.

Inicialmente, o método de interpolação por krigagem foi desenvolvido para solucionar problemas de mapeamentos geológicos, mas seu uso expandiu-se com sucesso no mapeamento de solos, mapeamento hidrológico, mapeamento atmosférico e outros campos correlatos.

Em todas as situações, o método fornece, além dos valores estimados, o erro associado a tal estimação, o que o distingue dos demais algoritmos à disposição. A krigagem usa informações a partir do semivariograma para encontrar os pesos ótimos a serem associados aos elementos amostrais que irão estimar um ponto, ou uma área, ou um volume. Como o semivariograma é uma função da distância entre elementos amostrais, mantendo o mesmo número de elementos, os pesos serão diferentes de acordo com o seu arranjo geográfico.

Segundo Druck et al. (2004), a krigagem engloba um conjunto de métodos de estimação que pode ser dividido em: procedimentos estacionários (krigagem simples e ordinária), não-estacionários (krigagem universal, funções intrínsecas de ordem k), univariados e multivariados (co-krigagem, etc). Neste trabalho será abordada apenas a krigagem ordinária.

3.5.1 Krigagem ordinária

A krigagem ordinária é uma estimação linear para uma variável regionalizada que satisfaz a hipótese intrínseca. Em contraste com a krigagem simples que, sob a hipótese de estacionariedade de segunda ordem, exige que a média seja conhecida, neste caso a média é desconhecida. A krigagem ordinária é usada quando a variável regionalizada é estacionária de primeira ordem. Para variáveis não estacionárias, ou seja, com tendência, mas para cujos resíduos a hipótese intrínseca se encaixa, o procedimento mais geral, denominado krigagem universal, é utilizado (LANDIM, 1998).

Considerando uma superfície sobre a qual se observa alguma propriedade física, química, ou biológica, Z , em n pontos distintos, com coordenadas representadas pelo vetor s , define-se um conjunto de valores $\{z(s_i), i=1, \dots, n\}$, onde s_i identifica uma posição, por exemplo, em duas dimensões. Supondo-se que se quer estimar o valor de Z em um ponto s_0 , ou seja, $\hat{Z}(s_0)$, este valor pode ser obtido, de acordo Deutsch e Journel (1992), a partir de uma combinação linear dos n valores observados, adicionado a um parâmetro, λ_0 , como segue:

$$\hat{Z}(s_0) = \lambda_0 + \sum_{i=1}^n \lambda_i Z(s_i) \quad (13)$$

Como se deseja um estimador não tendencioso, tem-se que:

$$E[Z(s_0) - \hat{Z}(s_0)] = 0 \quad (14)$$

Esta igualdade implica que as esperanças de $Z(s_0)$ e $\hat{Z}(s_0)$ sejam iguais. Aplicando-se a Equação 13 em 14, obtém-se:

$$E[Z(s_0)] = E\left[\lambda_0 + \sum_{i=1}^n \lambda_i Z(s_i)\right] \Rightarrow m = \lambda_0 + \sum_{i=1}^n \lambda_i m \quad (15)$$

A krigagem ordinária não requer o conhecimento prévio da média m . Assim, para que a igualdade da Equação 15 seja satisfeita é necessário que:

$$\lambda_0 = 0 \quad \text{e} \quad \sum_{i=1}^n \lambda_i = 1 \quad (16)$$

Portanto, o estimador de krigagem ordinária é:

$$\hat{Z}(s_0) = \sum_{i=1}^n \lambda_i Z(s_i), \quad \text{com} \quad \sum_{i=1}^n \lambda_i = 1 \quad (17)$$

Minimizando a variância do erro ($\text{Var}[Z(s_0) - \hat{Z}(s_0)]$) na condição de $\sum_{i=1}^n \lambda_i = 1$, os pesos λ_i são obtidos a partir do seguinte sistema de equações, denominado sistema de krigagem ordinária:

$$\begin{cases} \sum_{j=1}^n \lambda_j C(s_i, s_j) - \alpha = C(s_i, s_0) & \text{para } i = 1, \dots, n \\ \sum_{i=1}^n \lambda_i = 1 \end{cases} \quad (18)$$

onde,

- $C(s_i, s_j)$ e $C(s_i, s_0)$ são, respectivamente, a semivariância entre os pontos s_i, s_j e entre os pontos s_i, s_0 ;
- α é o multiplicador de Lagrange necessário para a minimização da variância do erro.

A correspondente variância minimizada do erro, denominada variância de krigagem ordinária (σ_{ko}^2), é dada pela seguinte expressão (DEUTSCH e JOURNAL, 1992):

$$\sigma_{ko}^2 = \text{Var}[Z(s_0) - \hat{Z}(s_0)] = C - \sum_{i=1}^n \lambda_i C(s_i, s_0) - \alpha \quad (19)$$

O sistema de krigagem ordinária (Equação 18) pode ser reescrito em notação matricial como:

$$\mathbf{K}\boldsymbol{\lambda} = \mathbf{k} \rightarrow \boldsymbol{\lambda} = \mathbf{K}^{-1}\mathbf{k}, \text{ com}$$

$$\mathbf{K} = \begin{bmatrix} C_{11} & C_{12} & \dots & C_{1n} & 1 \\ C_{21} & C_{22} & \dots & C_{2n} & 1 \\ \vdots & \vdots & & \vdots & \vdots \\ C_{n1} & C_{n2} & \dots & C_{nn} & 1 \\ 1 & 1 & \dots & 1 & 0 \end{bmatrix} \quad \boldsymbol{\lambda} = \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \\ \alpha \end{bmatrix} \quad \mathbf{k} = \begin{bmatrix} C_{10} \\ C_{20} \\ \vdots \\ C_{n0} \\ 1 \end{bmatrix} \quad (20)$$

onde, \mathbf{K} e \mathbf{k} são matrizes das covariâncias e $\boldsymbol{\lambda}$ o vetor dos pesos.

E a variância da krigagem ordinária, na forma matricial, é dada por:

$$\sigma_{ko}^2 = C - \lambda^T \mathbf{k} \quad (21)$$

A krigagem ordinária é um interpolador exato no sentido de que, quando as equações acima foram aplicadas, os valores interpolados irão coincidir com os valores dos elementos amostrais. Além disso, a variância da krigagem ordinária, indicada nas Equações 19 e 21, fornece uma informação importante sobre a confiabilidade dos valores interpolados (DRUCK et al., 2004).

Alguns autores têm buscado avaliar a aplicação de métodos geoestatísticos não só no domínio espacial, como é o caso da geoestatística “clássica”, mas também em análise de séries temporais (MINGOTI E NEVES, 1999) e em abordagens espaço-temporais (DE IACO, MYERS e POSA, 2002; GNEITING et al., 2005; MONTEIRO, 2003), as quais serão abordadas no capítulo 4.

4 GEOESTATÍSTICA EM ANÁLISES ESPAÇO-TEMPORAIS

A grande maioria dos trabalhos relacionados com a aplicação da geoestatística trata somente da componente espacial (localização geográfica) do fenômeno de interesse, visando sua espacialização. Por outro lado, os trabalhos que relacionam a aplicação da geoestatística em análises temporais, geralmente não utilizam a componente espacial, sendo a geoestatística uma ferramenta complementar, porém importante, na análise de séries temporais.

4.1 GEOESTATÍSTICA NO TEMPO

Mingoti e Neves (1999) apresentam um exemplo da utilização da geoestatística aplicada na análise de séries temporais, no qual a série temporal abordada é a do número manchas solares de Wolfer, fenômeno bastante conhecido devido a sua alta variabilidade e dificuldade de predição.

Os autores destacam que a geoestatística pode fornecer previsões de boa qualidade mesmo no contexto temporal, mas esta tem sido pouco explorada na literatura. Destacam ainda que o uso desta metodologia mostrou-se aplicável também para detecção de possíveis sazonalidades em uma série temporal. Acrescentam que, em relação a outras metodologias para análise de séries temporais, a geoestatística teria uma vantagem, devido ao fato de poder tratar de uma forma simples séries irregularmente espaçadas no tempo, uma vez que sua implementação não depende da igualdade de espaçamento entre as observações da série.

4.2 MODELOS ESPAÇO-TEMPORAIS

Vários fenômenos da natureza podem ser considerados processos espaço-temporais e há grande interesse em estudá-los no tempo e no espaço simultaneamente. Vivar-Rojas (2004) cita que a utilização de modelos de processos com interação espaço e tempo é limitada, dada a dificuldade de especificar a essa interação e da quantidade de dados disponíveis. Restringindo mais a área de atuação, De Cesare et al. (2001) comentam que a geoestatística oferece vários métodos para modelar dados espaciais, mas a aplicação de tais abordagens em processos espaço-temporais pode levar a perda de informação valiosa na dimensão temporal.

Para Gneiting et al. (2005) uma solução para esse problema é considerar o domínio de um modelo geoestístico espaço-temporal com $\mathfrak{R}^d \times \mathfrak{R}$, em que \mathfrak{R}^d é a dimensão espaço e \mathfrak{R} é o tempo. Eles consideram a estrutura de covariância das funções aleatórias espaço-temporais $Z(s,t)$, em que $(s,t) \in \mathfrak{R}^d \times \mathfrak{R}$, generalizando, uma função aleatória gaussiana espaço-temporal. A covariância entre $z(s_1,t_1)$ e $z(s_2,t_2)$, em geral, depende das coordenadas espaço-temporais (s_1,t_1) e (s_2,t_2) . Na prática são exigidas suposições simplificadoras como estacionariedade, separabilidade e simetria total, cujas definições são apresentadas a seguir.

A função aleatória espaço-temporal tem covariância espacial estacionária se $\text{Cov}\{Z(s_1,t_1), Z(s_2,t_2)\}$ depende das localidades s_1 e s_2 somente pelo vetor de separação espacial s_1-s_2 . Do mesmo modo, ela tem covariância temporal estacionária se $\text{Cov}\{Z(s_1,t_1), Z(s_2,t_2)\}$ depende dos tempos das observações t_1 e t_2 somente pelo *lag* temporal t_1-t_2 . Se um processo espaço-temporal tem ambas as covariâncias espacial e temporal estacionárias, diz-se que o processo tem

covariância estacionária. Sob essa suposição, existe uma função C definida em $\mathfrak{R}^d \times \mathfrak{R}$ tal que:

$$\text{Cov}\{Z(s_1, t_1), Z(s_2, t_2)\} = C(s_1 - s_2, t_1 - t_2) \quad (22)$$

para todo (s_1, t_1) e $(s_2, t_2) \in \mathfrak{R}^d \times \mathfrak{R}$. C é denotado por Gneiting et al. (2005) como função de covariância do processo e $C(\cdot, 0)$ e $C(0, \cdot)$ são funções de covariância puramente espacial e puramente temporal.

Um fenômeno aleatório Z tem covariância separável se existem funções de covariância puramente espacial (Cov_s) e puramente temporal (Cov_t), tal que:

$$\text{Cov}\{Z(s_1, t_1), Z(s_2, t_2)\} = \text{Cov}_s(s_1, s_2) \cdot \text{Cov}_t(t_1, t_2) \quad (23)$$

para todas as coordenadas (s_1, t_1) e $(s_2, t_2) \in \mathfrak{R}^d \times \mathfrak{R}$.

Como essa estrutura possibilita inferência e estimação computacionalmente eficientes, esses modelos foram usados até em situações nas quais a separação não era fisicamente possível.

Um processo espaço-temporal Z tem covariância totalmente simétrica se:

$$\text{Cov}\{Z(s_1, t_1), Z(s_2, t_2)\} = \text{Cov}\{Z(s_1, t_2), Z(s_2, t_1)\} \quad (24)$$

para todas as coordenadas espaço-temporais (s_1, t_1) e $(s_2, t_2) \in \mathfrak{R}^d \times \mathfrak{R}$.

A separabilidade é um caso especial de total simetria. Daí, estruturas de covariâncias que não são totalmente simétricas são não-separáveis e testes para a total simetria podem ser usados para rejeitar separabilidade.

Apresentadas as definições das estruturas de covariâncias, a relação existente entre elas: i) a maior classe é das funções de covariância estacionária ou não-estacionária; ii) as covariâncias separáveis e totalmente simétricas podem ser estacionárias ou não-estacionárias. Entretanto, uma função de covariância separável é sempre totalmente simétrica, mas a recíproca não vale.

Outra noção importante para funções de covariância estacionária é a de positiva definida. Especificamente, se $Z(s,t)$ é uma função aleatória definida em $\mathfrak{R}^d \times \mathfrak{R}$ e n for um inteiro positivo, a matriz de covariância do vetor aleatório $\{Z(s_1,t_1), \dots, Z(s_n,t_n)\}$ é não-negativa definida.

Para caracterizar funções de covariância espaço-temporal estacionárias, Gneiting et al. (2005) toma como base o teorema de Bochner que usa a classe de transformação de Fourier de uma medida simétrica, não-negativa e finita. Decorrente disso, ele apresenta teoremas para a função de covariância espaço-temporal estacionária ser separável e ser totalmente simétrica.

Cressie e Huang (1999)⁵ apud Gneiting et al. (2005) caracterizam a classe de funções de covariância espaço-temporal estacionárias sob a suposição adicional delas serem integráveis. De Cesare (2001) acrescenta que essa classe é formada por funções de covariância estacionárias não separáveis, para processos espaço-temporais.

Segundo Gneiting et al. (2005), existem processos em que a suposição de total simetria não é compatível e, nesse caso, as funções de

covariância espaço-temporal estacionárias que não são totalmente simétricas podem ser construídas com base nas equações de difusão ou equações diferenciais parciais estocásticas.

De Iaco, Myers e Posa (2002) obtiveram funções de covariância espaço-temporal estacionárias, totalmente simétricas e não separáveis, como mistura de covariâncias separáveis, e apresentam algumas classes de modelos espaço-temporais encontrados na literatura.

Inicialmente, para distinguir espaço e tempo, assume-se que $Z=\{Z(s,t), (s,t) \in D \times T\}$ seja uma função aleatória espaço-temporal estacionária de segunda ordem, onde $D \subset \mathfrak{R}^d$ e $T \subset \mathfrak{R}_+$, com valor esperado $E[Z(s,t)]=0$. Neste caso, a covariância, dada pela Equação 25, e o semivariograma, dado pela Equação 26, dependem somente do vetor h e não da localização ou do tempo.

$$C_{st}(h) = \text{Cov}[Z(s+h_s, t+h_t), Z(s,t)] \quad (25)$$

$$\gamma_{st}(h) = \text{Var}[Z(s+h_s, t+h_t) - Z(s,t)] / 2 \quad (26)$$

onde $h = (h_s, h_t)$, $(s, s+h_s) \in D^2$ e $(t, t+h_t) \in T^2$. Para que a função de covariância dada pela Equação 25 seja válida, a mesma deve ser positiva definida.

- Para o **modelo métrico**, proposto por Dimitrakopoulos e Luo (1994)⁶ apud De Iaco, Myers e Posa (2002), assume-se que:

⁵ CRESSIE, N.; HUANG, H. C. Classes of nonseparable, spatio-temporal stationary covariance functions. *Journal of the American Statistical Association*, 94, 1330-1340, 96, 784, 1999.

$$C_{st}(h_s, h_t) = C(a^2|h_s|^2 + b^2h_t^2) \quad (27)$$

onde os coeficientes $a, b \in \mathfrak{R}$. Nota-se que o mesmo modelo é assumido para as covariâncias espacial e temporal, com possíveis modificações de alcance.

- No **modelo produto** a covariância espaço-temporal é dada por:

$$C_{st}(h_s, h_t) = C_s(h_s)C_t(h_t) \quad (28)$$

onde a dependência espacial é separada da temporal. Na Equação 28, C_s é uma função positiva definida em \mathfrak{R}^d e C_t é definida positiva em \mathfrak{R} . Modelos admissíveis de covariâncias espacial e temporal podem ser encontrados em Cressie (1993)⁷ apud De Iaco, Myers e Posa (2002), os quais podem ser combinados na forma de produto determinando modelos espaço-temporais de covariância.

- No **modelo linear**, a separabilidade implica na adição das covariâncias espacial e temporal:

$$C_{st}(h_s, h_t) = C_s(h_s) + C_t(h_t) \quad (29)$$

Myers e Journel (1990)⁸ apud De Iaco, Myers e Posa (2002) apontam que, neste modelo, a função de covariância é somente positiva

⁶ DIMITRAKOPOULOS, R.; LUO, X. Spatiotemporal modelling: covariances and ordinary kriging systems. *Geostatistics for the next century*. Kluwer Academic Publishers, Dordrecht, 88-93.

⁷ CRESSIE, N. *Statistics for spatial data*. New York: Wiley, 1993.

⁸ MYERS, D. E.; JOURNEL, A. G. *Variograms with sazonal anisotropies and non-invertible kriging systems*. *Math Geol.* 22, 779-785, 1990.

semidefinida, sendo insatisfatória para predições ótimas.

- No **modelo não-separável**, uma nova abordagem permite obter classes não-separáveis. A função espaço-temporal de covariância estacionária é positiva definida e contínua, então de acordo com Matern⁹ *apud* Cressie e Huang (1999) equivale dizer que o processo tem função de distribuição espectral. Sendo a função de distribuição espectral $g(\omega, \tau) \geq 0$,

$$\begin{aligned} C_{st}(h_s, h_t) &= \iint e^{ih_s'\omega + ih_t'\tau} g(\omega, \tau) d\omega d\tau, \\ &= \int e^{ih_s'\omega} \rho(\omega, h_t) k(\omega) d\omega \end{aligned} \quad (30)$$

com $g(\omega; \tau) = (2\pi)^{-1} \int e^{-ih_s'\tau} h(\omega, h_t) dh_t$, e

$$h(\omega; h_t) = \int e^{ih_t'\tau} g(\omega, \tau) d\tau.$$

A construção de C, ou equivalentemente de g, foi feita assumindo que:

$$h(\omega; h_t) = \rho(\omega, h_t) k(\omega),$$

em que as seguintes condições devem satisfeitas:

- para cada $\omega \in \mathfrak{R}^d$, $\rho(\omega, \cdot)$ é uma função de autocorrelação contínua e $k(\omega) > 0$;
- a função positiva $k(\omega)$ satisfaz: $\int k(\omega) d\omega < \infty$.

- O **modelo produto-soma** pode ser obtido da seguinte maneira:

$$C_{st}(h_s, h_t) = k_1 C_s(h_s) C_t(h_t) + k_2 C_s(h_s) + k_3 C_t(h_t) \quad (31)$$

⁹ MATERN, B. *Spatial variation*. Meddelanden fran Statens Skogsforskningsinstitut, 49, n.5. 1960.

ou, equivalentemente, em termos da função semivariograma:

$$\gamma_{st}(h_s, h_t) = [k_2 + k_1 C_t(0)]\gamma_s(h_s) + [k_3 + k_1 C_s(0)]\gamma_t(h_t) - k_1 \gamma_s(h_s) \gamma_t(h_t) \quad (32)$$

onde C_s e C_t são as funções de covariância e γ_s e γ_t são as funções de semivariograma correspondentes; $k_1 > 0$, $k_2 \geq 0$, $k_3 \geq 0$ garantem a admissibilidade. Note que $C_{st}(0,0)$ define o patamar de γ_{st} (chamado patamar “global”), $C_s(0)$ é o patamar de γ_s e $C_t(0)$ o patamar de γ_t , sendo que $C_s(0)$ e $C_t(0)$ são denominados patamares “parciais”.

4.3 MODELO PRODUTO-SOMA GENERALIZADO

Uma generalização do modelo produto-soma, introduzido por De Cesare, Myers e Posa (2001), é dado pelo **modelo produto-soma generalizado**, ou **generalized product-sum model** (DE IACO, MYERS e POSA, 2001):

$$\gamma_{st}(h_s, h_t) = \gamma_{st}(h_s, 0) + \gamma_{st}(0, h_t) - k \gamma_{st}(h_s, 0) \gamma_{st}(0, h_t) \quad (33)$$

onde $\gamma_{st}(h_s, 0)$ e $\gamma_{st}(0, h_t)$ são os semivariogramas espacial e temporal válidos, respectivamente, e

$$k = \frac{C\gamma_{st}(h_s, 0) + C\gamma_{st}(0, h_t) - C\gamma_{st}(h_s, h_t)}{C\gamma_{st}(h_s, 0)C\gamma_{st}(0, h_t)} \quad (34)$$

onde C indica o patamar do semivariograma.

O valor de $C\gamma_{st}(h_s, h_t)$, chamado de patamar “global”, pode ser estimado graficamente, através da superfície do variograma espaço-temporal. Este valor deve escolhido de forma garantir que $\gamma_{st}(h_s, h_t)$ seja uma função positiva definida. Para isto, o seguinte critério deve ser satisfeito:

$$0 < k \leq \frac{1}{\max\{C\gamma_{st}(h_s, 0), C\gamma_{st}(0, h_t)\}} \quad (35)$$

De Iaco, Myers e Posa (2002), fazem algumas considerações em relação aos modelos previamente descritos (na Seção 4.2):

- Se a função de autocorrelação ρ (Equação 30) for puramente uma função de h_t , então o *modelo produto* é obtido;
- Os *modelos produto* e *linear* são facilmente obtidos a partir do *modelo produto-soma* adotando, respectivamente, $k_2=k_3=0$, e $k_1=0$;
- Os *modelos produto-soma “simplificado”* e *generalizado* são não-separáveis e, em geral, não-integráveis, uma vez que não podem ser obtidos a partir da representação de Cressie-Huang. Além disso, estes modelos não requerem o uso de uma métrica no espaço-tempo;
- Os *modelos produto-soma “simplificado”* e *generalizado* são mais flexíveis do que o *modelo não-separável* na estimação e modelagem de estruturas de correlação espaço-temporais.

Na literatura não foram encontrados resultados de trabalhos que envolvam a geoestatística em análises espaço-temporais conjuntamente com dados

sensoriamento remoto. A única referência encontrada foi Myers e Dibakor (2003). Trata-se um projeto apresentando algumas idéias para pesquisas a serem desenvolvidas na Universidade do Arizona nos EUA. O objetivo do trabalho apresentado neste projeto é detectar mudanças globais na vegetação, através no uso de semivariogramas espaço-temporais, numa determinada área de estudo para a qual se dispõe de um conjunto de imagens NDVI, derivadas de dados de baixa resolução obtidos por satélite meteorológico e cobrindo um período de 10 anos.

De acordo com Myers e Dibakor (2003), quando se estende o semivariograma para o espaço-tempo há duas abordagens que podem ser usadas: uma é tratar o espaço-tempo simplesmente como um espaço euclidiano com uma dimensão a mais e a outra é “separar” espaço e tempo. A desvantagem da primeira abordagem é a necessidade de se ter uma métrica ou norma no espaço-tempo, o que essencialmente significa tratar o tempo como uma “dimensão” euclidiana, contradizendo algumas das percepções usuais de tempo. Neste sentido, neste trabalho será utilizada a segunda abordagem, ou seja, modelar separadamente espaço e tempo, e integrar essas duas dimensões através do modelo produto-soma generalizado descrito em De Iaco, Myers e Posa (2001).

5 EXPERIMENTO: DESCRIÇÃO, MÉTODO E RESULTADOS

5.1 ÁREA DE ESTUDO

Caracterizado o fenômeno de interesse, ou seja, a dispersão espacial de plantas aquáticas em reservatórios destinados à geração de energia, é necessário identificar uma área de estudo na qual esse fenômeno esteja adequadamente representado.

Inicialmente, no projeto de pesquisa, previa-se a utilização de um conjunto de imagens orbitais TM e ETM+/Landsat as quais englobam a confluência dos rios Tietê e Paraná, incluindo parte dos reservatórios das usinas hidrelétricas de Três Irmãos, Jupia e Ilha Solteira, todas no Estado de São Paulo. Essas imagens compreendem um período de tempo entre 1985 e 2002, irregularmente distribuídas no tempo, totalizando 10 cenas. Além disto, contava-se também com um mosaico de imagens Ikonos de 2001.

A partir deste conjunto de imagens, foram realizados alguns experimentos visando a detecção de plantas aquáticas submersas a partir da utilização de técnicas de processamento e análise de imagens. No entanto, ao avaliar todo o conjunto de imagens apresentado no projeto de pesquisa, notou-se que cinco das cenas TM ou ETM+/Landsat apresentavam algum tipo de problema que inviabilizava a detecção de plantas aquáticas (no caso submersas). Dentre estes, pode-se citar a ocorrência de ventos causando ondulações na superfície do corpo d'água. Assim, apenas um pequeno número de imagens multitemporais permitia a detecção do fenômeno de interesse, o que reduziu consideravelmente a dimensão temporal, prejudicando a modelagem do fenômeno e o desenvolvimento

do trabalho.

Por esse motivo, foi necessário buscar uma nova área de estudo, a qual também representasse o fenômeno de interesse e que possuísse uma maior consistência no aspecto temporal. Nesse sentido, foi identificada uma área de estudo, na qual o fenômeno (presença de plantas aquáticas, exclusivamente marginais e flutuantes) está melhor caracterizado no tempo. Trata-se do reservatório da Usina Hidrelétrica de Salto Grande, em Americana/SP, para o qual se dispõe de 18 cenas (sendo 7 ETM+/Landsat, 2 Ikonos - multiespectrais e 9 CCD/CBERS), tomadas no período de junho de 2000 a outubro de 2005. Esta área foi objeto de estudo recente realizado por Cruz (2005).

A Figura 12 apresenta uma composição colorida da cena multiespectral Ikonos, de 2004, representando a área de estudo, destacando o contorno do reservatório de Salto Grande (em vermelho). Um detalhe da área em que ocorre infestação por plantas aquáticas marginais e flutuantes (em amarelo na Figura 12) pode ser observado na Figura 13, na qual também se observa a presença de uma barreira flutuante, construída no início de 2004, com o intuito de evitar a concentração de plantas próximas à barragem.



Figura 12 – Área de estudo.

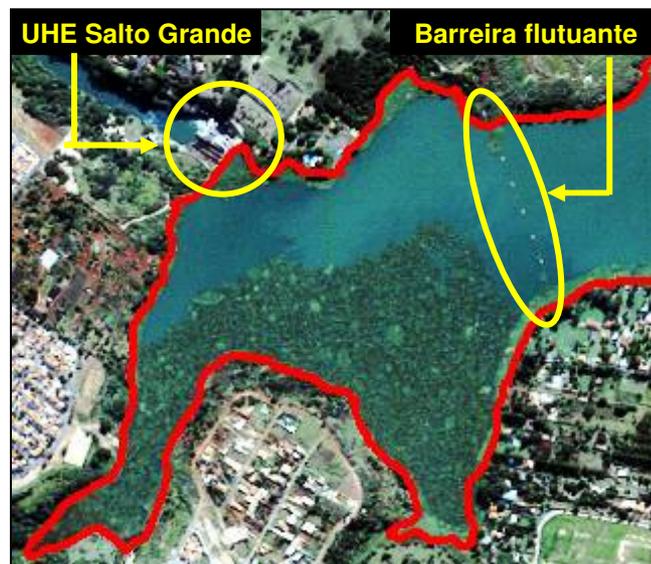


Figura 13 – Detalhe de uma área com infestação de plantas aquáticas marginais e flutuantes.

O reservatório de Salto Grande localiza-se no município de Americana/SP e está inserido na sub-bacia do rio Atibaia, o qual pertence à bacia hidrográfica do rio Piracicaba. Sua localização geográfica é definida pelas coordenadas $22^{\circ} 44'$ de latitude Sul e $47^{\circ} 15'$ de longitude Oeste, a uma altitude de

530 m. A área do reservatório é de aproximadamente 1135 ha. A região se caracteriza pelo clima temperado brando, sem estação seca e com verão suave. A temperatura média anual varia de 18° a 20° C. Com relação às precipitações, o valor médio para época chuvosa é de 1500 mm/ano e para a época seca é de 1300 mm/ano.

A barragem localiza-se próxima a foz do rio Atibaia, que por sua vez deságua no rio Jaguari, formando o rio Piracicaba. Quando a usina hidrelétrica de Americana entrou em funcionamento em 1949, seu objetivo era gerar cerca de 30 MW/dia de energia elétrica. Com o decorrer dos anos, várias outras atividades foram incorporando-se à represa, como o abastecimento de cidades como Sumaré, irrigação de culturas e recreação, sendo que a usina hidrelétrica atualmente está operando também para a regulação da vazão na bacia do rio Piracicaba em épocas de cheia e períodos de estiagem (LEITE, 2002).

Por estar localizado em uma região com elevada densidade demográfica, altamente industrializada e com intensa atividade agrícola, o reservatório possui uma alta concentração de nutrientes, o que provoca o crescimento excessivo de plantas aquáticas. Devido a esse tipo de desequilíbrio, diversos usos foram minimizados, incluindo a produção de energia e a recreação de contato primário, implicando na desvalorização econômica da infra-estrutura construída na década de 70 (LEITE e ESPÍNDOLA, 2002¹⁰ apud LEITE, 2002).

Nesse contexto, considera-se que uma abordagem que viabilize a identificação de áreas infestadas e a caracterização da dispersão espaço-temporal de plantas aquáticas, realizados a partir dados de Sensoriamento Remoto, constitua

¹⁰ LEITE, M. A.; ESPÍNDOLA, E.L.G. Análise do processo de eutrofização entre os Reservatórios de Salto Grande (22° 44'S e 47° 15'W) e do Lobo (22° 10'S e 47° 57'W). Recursos hidroenergéticos: usos, impactos e planejamento integrado – Série: Ciências da Engenharia Ambiental – PPG SEA – CRHEA – SHS – EESC – USP. Rima, vol.1, p.107-116, 2002.

uma contribuição útil para o manejo destas no reservatório de Salto Grande em particular, assim como para outros reservatórios afetados por problemas dessa natureza.

5.2 IMAGENS MULTIESPECTRAIS E MULTITEMPORAIS UTILIZADAS

Na Tabela 3 estão relacionadas as datas de aquisição das imagens multiespectrais e seus respectivos sensor e satélite. Ressalta-se que as imagens Landsat e Ikonos foram disponibilizadas pela Companhia de Força e Luz do Estado de São Paulo (CPFL) e as imagens CBERS são disponibilizadas gratuitamente pelo Instituto Nacional de Pesquisas Espaciais (INPE), via internet, através do site: www.dgi.inpe.br/CDSR.

A imagem multiespectral Ikonos de Junho de 2004 foi utilizada como referência espacial no decorrer do experimento, por possuir uma maior resolução espacial original e, principalmente, por ser objeto de estudo em trabalho recente desenvolvido por Cruz (2005), disponibilizando informações adicionais sobre a área e o fenômeno, naquele momento do tempo, inclusive com dados de levantamento de campo.

Tabela 3 – Imagens disponíveis.

Imagem	Data	Sensor/Satélite	Resolução Espacial (m)
a	24 / Jun / 2000	ETM+/Landsat-7	30
b	23 / Mar / 2001	ETM+/Landsat-7	30
c	02 / Nov / 2001	ETM+/Landsat-7	30
d	11 / Abr / 2002	ETM+/Landsat-7	30
e	21 / Nov / 2002	ETM+/Landsat-7	30
f	08 / Jan / 2003	ETM+/Landsat-7	30
g	16 / Mai / 2003	ETM+/Landsat-7	30
h	16 / Out / 2003	Ikonos II	04
i	29 / Dez / 2003	CCD/CBERS-2	20

j	16 / Mar / 2004	CCD/CBERS-2	20
k	11 / Abr / 2004	CCD/CBERS-2	20
l	08 / Jun / 2004	Ikonos II	04
m	07 / Jul / 2004	CCD/CBERS-2	20
n	17 / Fev / 2005	CCD/CBERS-2	20
o	10 / Abr / 2005	CCD/CBERS-2	20
p	06 / Mai / 2005	CCD/CBERS-2	20
q	18 / Ago / 2005	CCD/CBERS-2	20
r	09 / Out / 2005	CCD/CBERS-2	20

5.3 MÉTODO PROPOSTO

Deve-se destacar que o principal objetivo deste trabalho é buscar um método adequado que permita estimar um modelo que represente o comportamento, no espaço e no tempo, da dispersão de plantas aquáticas. Neste sentido, o método originalmente idealizado, apresentado a seguir, sofreu algumas reformulações no decorrer do experimento, conforme houve a necessidade de adequar o propósito da pesquisa com as ferramentas de análise disponíveis.

A concepção do método baseou-se na hipótese inicial de que identificado um fenômeno passível de ser registrado em imagens multiespectrais e identificada uma variável, correlacionada no espaço e no tempo, que represente este fenômeno, então a geoestatística pode ser aplicada para se obter um modelo que represente esta variável no espaço e no tempo. Neste trabalho, o fenômeno em questão é a presença de plantas aquáticas em um reservatório e a variável que representa este fenômeno é o índice de vegetação.

A Figura 14 apresenta um fluxograma que procura sintetizar o método proposto inicialmente.

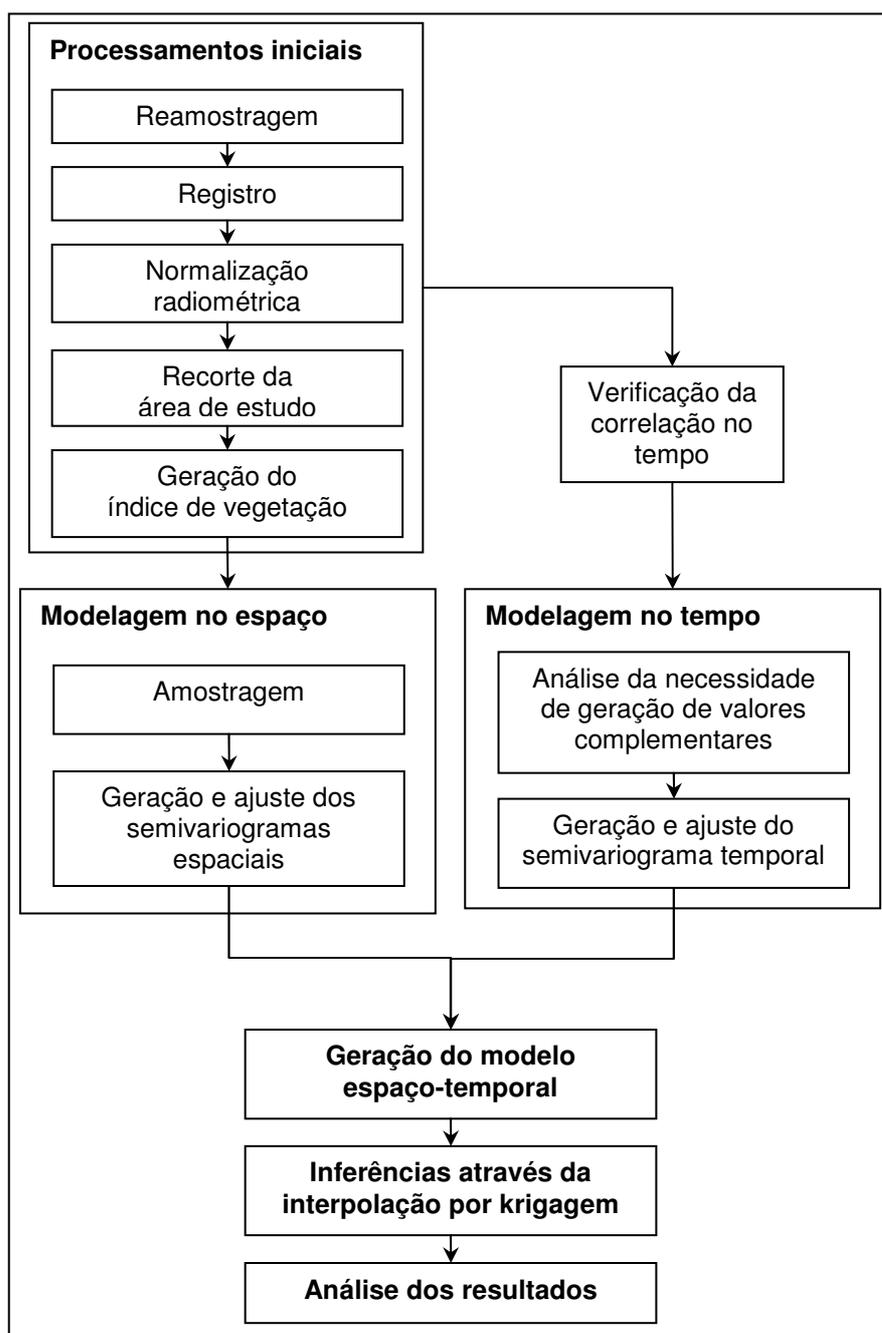


Figura 14 – Fluxograma representando o método proposto inicialmente.

Um conjunto de processamentos iniciais é imprescindível a fim de compatibilizar as imagens utilizadas radiométrica e geometricamente, principalmente por ser considerado o aspecto temporal no experimento.

Deste modo, o primeiro passo é compatibilizar, através de uma reamostragem, a resolução espacial entre as imagens, para que haja maior coerência nas análises posteriores. O registro e a normalização radiométrica são

fundamentais, pois a partir destas etapas é que se garante a consistência geométrica e radiométrica, respectivamente, do experimento. Para evitar que se confundam plantas aquáticas marginais e flutuantes com a vegetação do entorno da represa, um recorte das imagens se faz necessário. Concluindo o conjunto de processamentos iniciais, tem-se a geração de imagens índices de vegetação, com o objetivo de sintetizar a informação no domínio multiespectral, reduzindo-se a dimensionalidade dos dados.

Através do cálculo de uma matriz de correlação, pode ser verificada a existência ou não de correlação temporal entre as imagens multitemporais, uma vez que se não houver tal correlação a etapa de modelagem no tempo não teria sentido, de acordo com a hipótese inicial do trabalho.

A análise espaço-temporal é feita de acordo com o modelo proposto por De Iaco, Myers e Posa (2002), no qual a modelagem no espaço e no tempo é realizada primeiramente de modo independente. Em um segundo momento, ajusta-se um modelo espaço-temporal que integra as componentes espacial e temporal.

Uma amostragem é necessária a fim de diminuir o número de elementos na análise geoestatística. Para isto, a estratégia de amostragem sistemática não-alinhada é a mais adequada em análises geoestatísticas, garantindo tanto a distribuição geográfica dos elementos amostrais quanto a aleatoriedade. Definidos os elementos amostrais a serem utilizados, gera-se e ajusta-se, para cada imagem (ou data), os semivariogramas espaciais.

Como se dispõe de um número limitado de imagens, ou seja, de dados no tempo, pretende-se verificar a necessidade de gerar valores complementares no tempo através da média de imagens “vizinhas”, ou seja, mais próximas no tempo. Isto porque o número limitado de dados temporais pode

prejudicar o ajuste de um modelo temporal de semivariograma.

Tendo-se os semivariogramas espaciais e o semivariograma temporal, e seus respectivos patamares, determina-se graficamente o valor de k (apresentado na Equação 34) através da representação gráfica da superfície do semivariograma espaço-temporal. Assim, pode-se ajustar um semivariograma espaço-temporal de acordo com a Equação 33 (modelo produto-soma generalizado).

Este modelo (semivariograma) espaço-temporal representaria a variabilidade espaço-temporal da variável planta aquática, através do valor do índice de vegetação, e poderia ser utilizado, por exemplo, para realizar inferências em datas nas quais não se dispõe de dados e até mesmo para realizar alguma previsão.

5.4 EXPERIMENTO REALIZADO

5.4.1 Processamentos iniciais

Inicialmente, a fim de compatibilizar as imagens utilizadas radiométrica e geometricamente, passo imprescindível em uma análise que envolva o aspecto temporal, foram realizados alguns processamentos iniciais.

5.4.1.1 Reamostragem

O conjunto de imagens utilizadas no experimento é composto por imagens de diferentes sensores e satélites, cada qual com uma determinada resolução espacial – 30 m para as imagens ETM+/Landsat, 20 m para as CCD/CBERS e 4 m para as Ikonos – conforme apresentado anteriormente na Tabela 3. A fim de obter-se uma maior consistência nas análises posteriores, as imagens

correspondentes às bandas espectrais do vermelho e infravermelho próximo de cada uma das 18 cenas, ou seja, 36 imagens ao todo, foram reamostradas para que ficassem com a mesma resolução espacial de 10 m. Este valor foi adotado para que não se perdesse muita informação das imagens de alta resolução e também levando-se em conta que o fenômeno de interesse não fica descaracterizado com um menor elemento de resolução, conforme mostra Cruz (2005). Também foi observada a facilidade de implementação da operação, no caso, a replicação para as imagens Landsat e CBERS. Para reamostrar as imagens Ikonos foi utilizado o programa ENVI 3.5 e para as demais o programa IrfanView 3.95.

5.4.1.2 Registro

Para garantir a consistência geométrica do experimento todas as 36 imagens foram registradas, tomando-se como referência a imagem Ikonos de Junho de 2004. Para isso, foram utilizados seis pontos de controle, cuja distribuição pode ser vista na Figura 15, medidos inicialmente no sistema de coordenadas da imagem e posteriormente transformados para um sistema plano local.

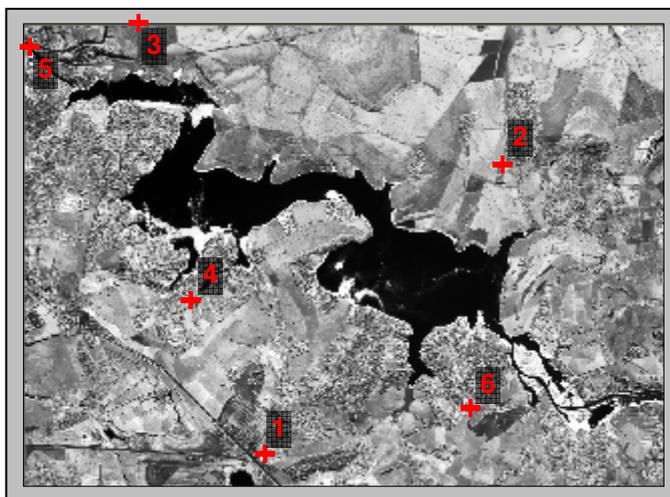


Figura 15 – Distribuição dos pontos de controle.

Medidos os pontos de controle em todas as imagens, foram montados os arquivos de correspondência e realizado o processo de registro através do programa Idrisi 3.2, utilizando a função de mapeamento linear e o método de reamostragem por vizinho mais próximo. O erro médio quadrático (EMQ) do registro de cada uma das imagens é apresentado na Tabela 4:

Tabela 4 – Erros Médios Quadráticos (EMQ's) da etapa de registro.

Imagem	EMQ (m)
a	4,5
b	2,2
c	13,9
d	2,9
e	2,0
f	5,0
g	5,9
h	0,7
i	2,2
j	3,5
k	4,0
l*	---
m	9,9
n	1,8
o	1,1
p	2,2
q	5,4
r	3,3

(*) *Referência geométrica.*

5.4.1.3 Normalização radiométrica

Uma vez que imagens de diferentes sensores e satélites foram utilizadas no experimento, a normalização foi realizada com o objetivo de compatibilizar radiometricamente as imagens. Embora as imagens Ikonos possuísem um maior contraste, estas não representavam bem as bandas utilizadas, uma vez já foram submetidas a uma operação de aumento de contraste

quando convertidas de 11 para 8 bits. Desse modo, foi utilizada como referência radiométrica a imagem ETM+/Landsat de Novembro de 2001, imagem (c), por possuir um maior contraste originalmente. Para a realização desta etapa foram utilizados os programas Idrisi 3.2 e Microsoft Excel 2003. Inicialmente, foram adquiridos, no Idrisi, os valores de média e desvio-padrão dos valores de brilho (ND's) para todas as imagens. No Excel, foram calculadas as expressões para a normalização, as quais foram processadas no Idrisi. As Figuras 16 e 17 apresentam os valores de média e desvio-padrão dos ND's das imagens antes e depois da normalização, para as bandas espectrais do vermelho (banda 3) e infravermelho próximo (banda 4), respectivamente. As barras verticais indicam os desvios-padrão associados às médias.

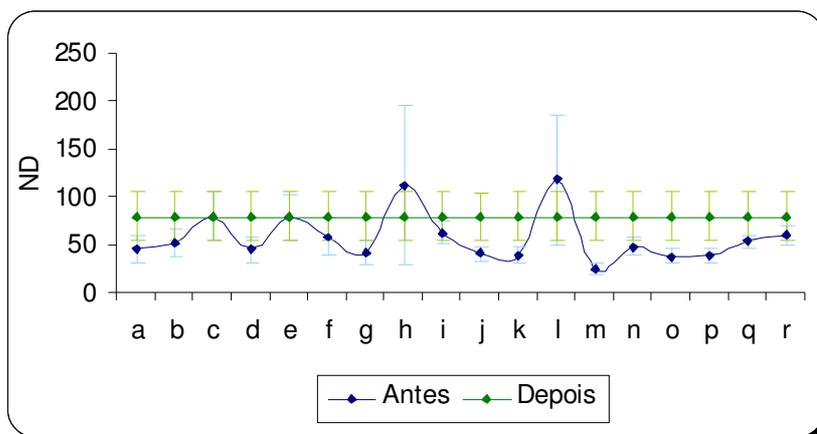


Figura 16 – Média e desvio-padrão (d.p.) dos ND's antes e depois da normalização (banda 3).

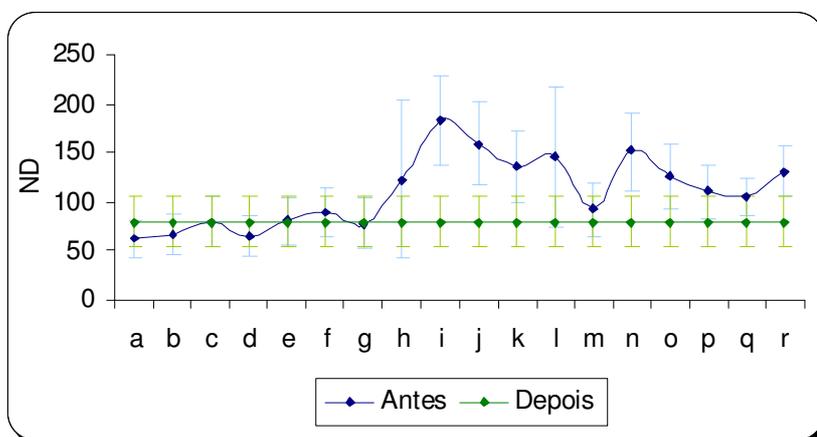


Figura 17 – Média e desvio-padrão (d.p.) dos ND's antes e depois da normalização (banda 4).

5.4.1.4 Geração dos NDVI's e recorte da área de estudo

Conforme já mencionado, a implementação de modelos de distribuição espaço-temporal de fenômenos dinâmicos não é trivial, principalmente quando a variável em questão deve ser analisada em diferentes domínios: multiespectral (7D para as imagens Landsat e 4D para as imagens Ikonos e CBERS), espacial (2D) e temporal (1D). Neste sentido, a fim de diminuir a dimensionalidade dos dados multiespectrais, foram elaboradas imagens índices de vegetação. Deste modo, a variável planta aquática passa a ser representada pelo respectivo índice de vegetação estimado para cada cena multitemporal e o espaço do domínio multiespectral passa a ser unidimensional.

As imagens índices de vegetação foram geradas utilizando o Idrisi, sendo que o índice de vegetação adotado no experimento foi o NDVI, pelo fato de que todas as imagens estariam representadas no mesmo intervalo, de -1 a 1.

Por fim, foram recortadas as 18 imagens NDVI's, removendo-se o entorno na Represa de Salto Grande. Para isso, foi gerada uma imagem binária tendo como atributos 1 para a região pertencente à represa e 0 para o entorno. Utilizando-se o Idrisi, multiplicou-se esta imagem binária com cada um dos NDVI's, resultando em imagens NDVI's nas quais se destacam somente a área de estudo. A Figura 18 apresenta as imagens NDVI's para cada data, resultantes da etapa de processamentos iniciais. Ressalta-se que a escala radiométrica para as imagens mostradas na Figura 18 não é global, ou seja, cada imagem possui uma escala individual, mas que não ultrapassa o intervalo $[-1,1]$, sendo que os valores negativos (em tons escuros nas imagens) estão associados à água e os valores positivos (próximos ao branco) estão associados à presença de plantas aquáticas.

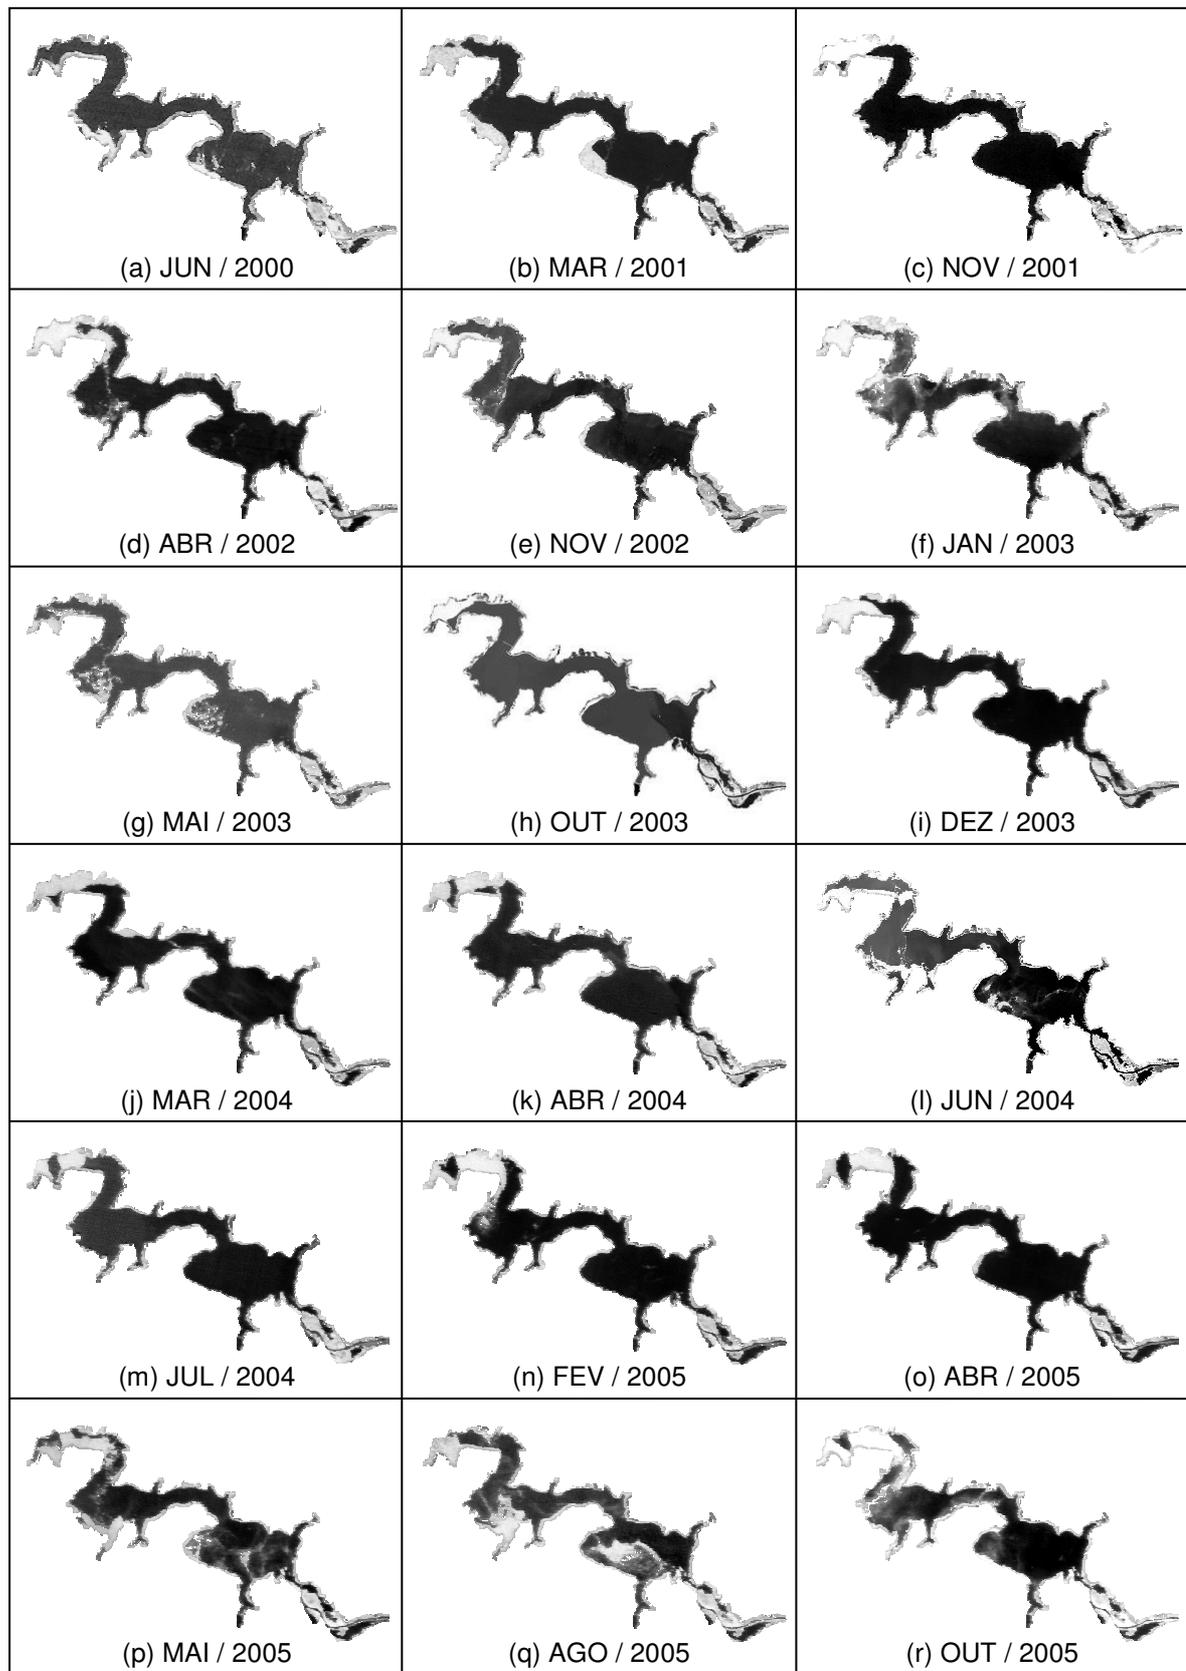


Figura 18 – Imagens resultantes dos processamentos iniciais: NDVI's.

5.4.2 Análise da correlação no tempo

Para evitar que a correlação entre as áreas descartadas das imagens multitemporais mascarasse os resultados desta análise, foi antecipada a etapa de amostragem no espaço, ou seja, foram determinados os elementos amostrais a serem utilizados no decorrer do experimento.

A amostragem foi elaborada em dois passos: inicialmente foi feita amostragem automática, no Idrisi, do tipo sistemático não-alinhado com 800 elementos amostrais, dos quais foram removidos os que estavam fora da área de interesse; em seguida, foi elaborada uma imagem de máximos na qual estão representados os maiores valores de todas as imagens multitemporais em cada posição. A partir desta imagem de máximos, foi feito, manualmente, um adensamento de elementos amostrais nas regiões em que, em algum momento do tempo, houve infestação por plantas aquáticas. Obteve-se, então, uma amostra com 543 elementos amostrais irregularmente distribuídos no espaço. A Figura 19 apresenta a imagem de máximos, na qual foi sobreposta a amostra adquirida no espaço.

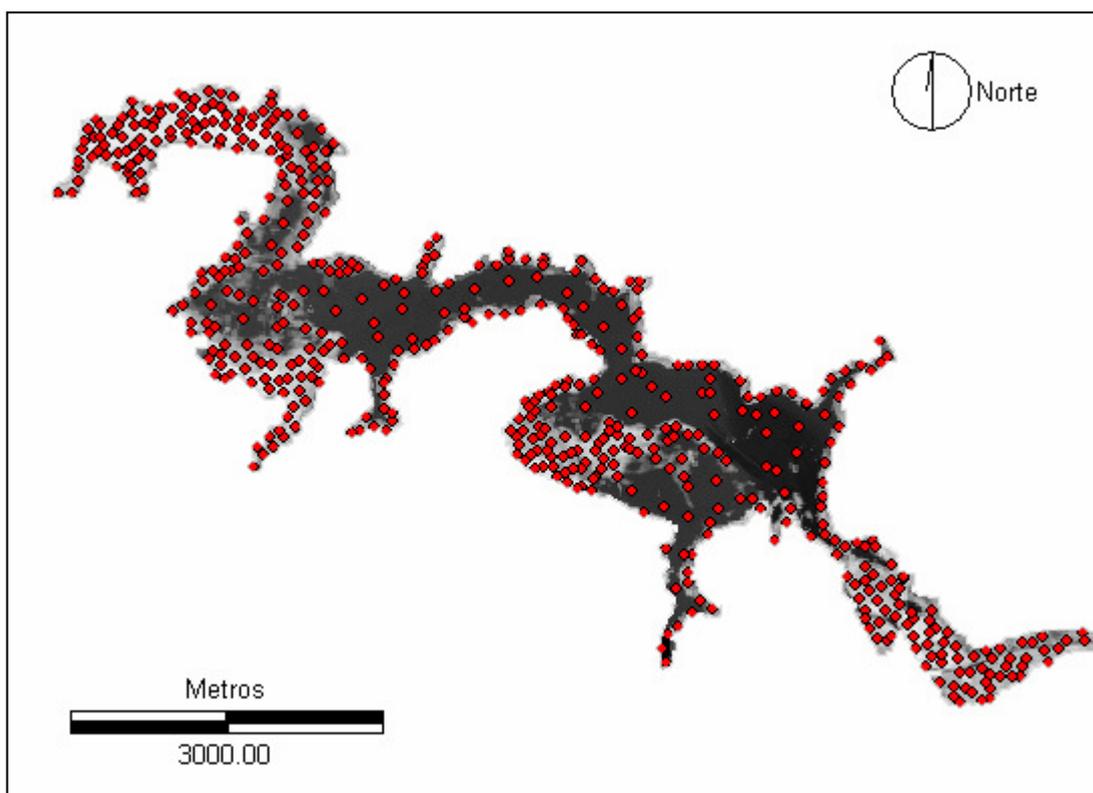


Figura 19 – Imagens de máximos e distribuição dos elementos amostrais.

A partir dos elementos desta amostra, foi calculada uma matriz de correlação a fim de verificar a existência de correlação no tempo entre as imagens, ou seja, entre as datas de aquisição das imagens. A Tabela 5 apresenta a matriz de correlação no tempo. Os elementos em vermelho indicam uma correlação menor do que 0,5, os elementos em azul indicam uma correlação maior ou igual a 0,5 e os elementos em negrito indicam valores maior ou igual a 0,7.

Tabela 5 – Matriz de correlação.

	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o	p	q
b	0,61																
c	0,37	0,52															
d	0,37	0,58	0,72														
e	0,48	0,69	0,68	0,76													
f	0,24	0,50	0,65	0,76	0,73												
g	0,57	0,65	0,48	0,54	0,62	0,49											
h	0,22	0,42	0,60	0,62	0,51	0,58	0,39										
i	0,42	0,64	0,77	0,80	0,79	0,68	0,51	0,60									
j	0,37	0,54	0,81	0,75	0,67	0,72	0,55	0,62	0,78								
k	0,39	0,52	0,78	0,74	0,67	0,72	0,53	0,68	0,75	0,88							
l	0,32	0,47	0,40	0,53	0,56	0,48	0,45	0,39	0,56	0,45	0,48						
m	0,40	0,52	0,76	0,73	0,68	0,63	0,52	0,54	0,77	0,80	0,79	0,50					
n	0,34	0,44	0,67	0,79	0,64	0,72	0,46	0,53	0,69	0,75	0,81	0,46	0,75				
o	0,38	0,50	0,67	0,70	0,63	0,61	0,51	0,51	0,71	0,78	0,81	0,43	0,81	0,84			
p	0,52	0,59	0,46	0,64	0,59	0,46	0,51	0,38	0,64	0,53	0,56	0,52	0,57	0,64	0,69		
q	0,43	0,43	0,34	0,44	0,43	0,29	0,51	0,35	0,42	0,40	0,35	0,39	0,36	0,29	0,33	0,45	
r	0,43	0,49	0,60	0,74	0,64	0,64	0,45	0,46	0,68	0,64	0,67	0,51	0,70	0,82	0,76	0,70	0,34

Analisando-se os valores encontrados, tem-se que 66,67% dos valores são maiores ou iguais a 0,5, sendo que 23,53% são maiores ou iguais a 0,7, resultados que indicam uma correlação significativa no tempo. Pelos valores apresentados, também pode-se verificar que as imagens menos correlacionadas com as demais são a (a) e a (q), de junho de 2000 e agosto de 2005, respectivamente. Observando-se as Figuras 18.(a) e 18.(q), pode-se realmente perceber que o padrão de dispersão das plantas aquáticas nestas datas difere das demais, na primeira pelo baixo nível de infestação e na última pelo alto nível de infestação em uma região onde geralmente não se tinha essa ocorrência.

Uma outra forma de visualizar esta correlação é apresentado na Figura 20, na qual verifica-se a correlação ao longo do tempo. Nota-se que, apesar da alta variabilidade, que a correlação diminui ao longo do tempo, como é de se esperar.

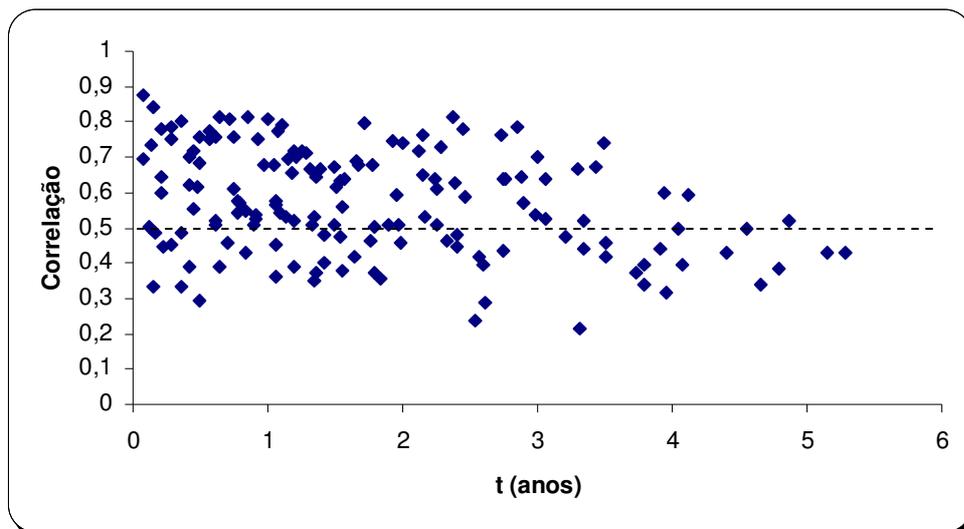


Figura 20 – Correlação temporal.

5.4.3 Modelagem no espaço

Como dito anteriormente, a etapa de amostragem foi antecipada para realizar a análise de correlação no tempo. Sendo assim, a etapa da modelagem no espaço iniciou-se com a geração dos semivariogramas e ajuste dos modelos para cada data e para os valores da imagem de máximos. Para realizar esta etapa foi utilizado o programa SPRING 4.1.

A Figura 21 apresenta os semivariogramas experimentais gerados para cada data e para os elementos da imagem de máximos.

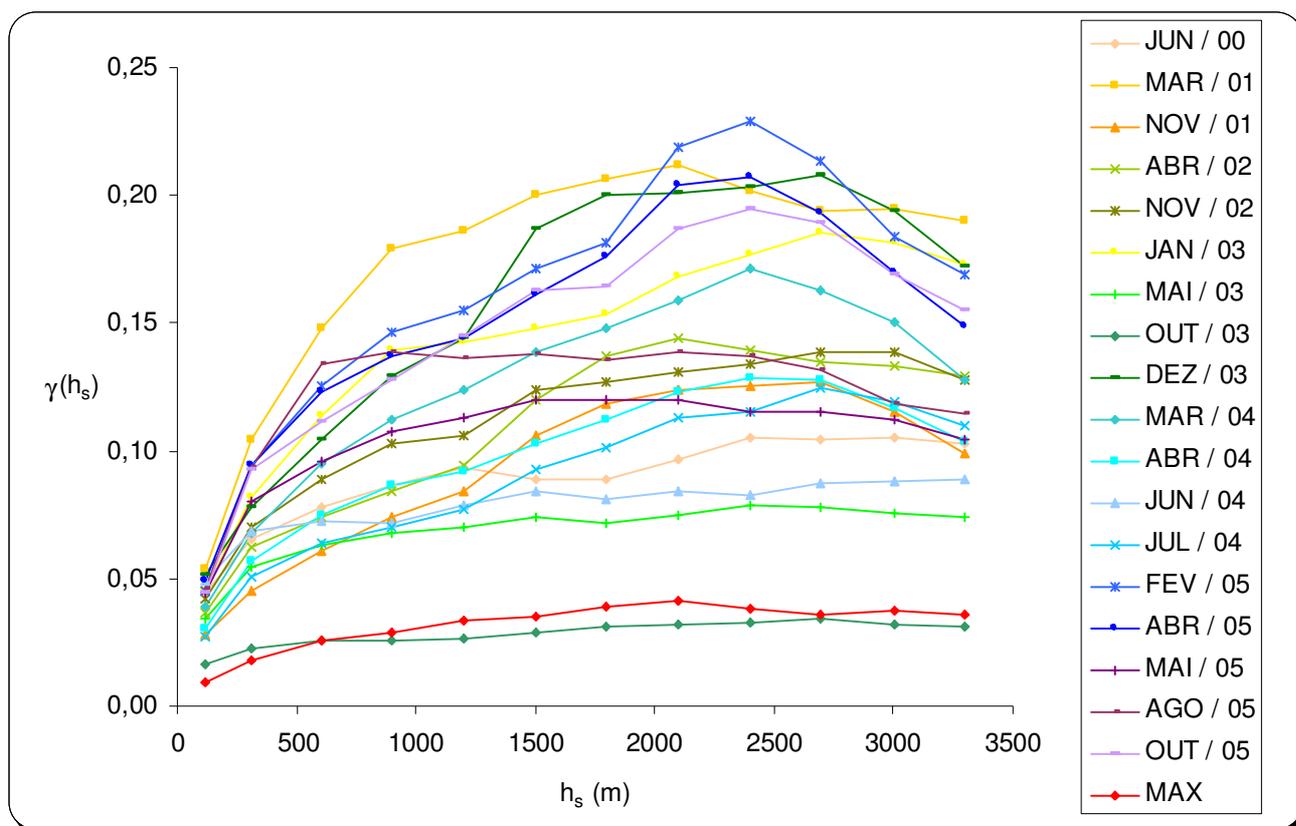


Figura 21 – Semivariogramas experimentais.

A Tabela 6 apresenta os valores obtidos para os parâmetros (efeito pepita, contribuição e alcance, respectivamente) dos modelos ajustados. Para todas as datas, o modelo foi ajustado a partir de um semivariograma experimental omnidirecional, com 10 *lags* de 300 m e tolerância de 150 m, sendo que o modelo adotado foi o esférico, com exceção do modelo gerado para os valores da imagem de máximos (MAX), sendo adotado o modelo exponencial.

Tabela 6 – Parâmetros dos modelos ajustados.

Imagem	Data	C₀	C₁	A
a	JUN / 00	0,04	0,058	1365,282
b	MAR / 01	0,033	0,165	1188,84
c	NOV / 01	0,022	0,095	2237,164
d	ABR / 02	0,032	0,104	2347,555
e	NOV / 02	0,039	0,093	1888,764
f	JAN / 03	0,037	0,133	1720,419

g	MAI / 03	0,03	0,045	1079,864
h	OUT / 03	0,018	0,015	2299,315
i	DEZ / 03	0,04	0,156	2142,44
j	MAR / 04	0,032	0,119	1872,87
k	ABR / 04	0,028	0,09	2045,99
l	JUN / 04	0,052	0,033	1721,588
m	JUL / 04	0,026	0,091	2721,927
n	FEV / 05	0,038	0,156	1860,946
o	ABR / 05	0,043	0,135	1807,936
p	MAI / 05	0,032	0,082	955,913
q	AGO / 05	0,014	0,118	632,828
r	OUT / 05	0,038	0,136	1808,363
MAX	---	0,003	0,035	1768,086

Tendo-se os modelos ajustados, concluiu-se a etapa de modelagem no espaço.

5.4.4 Modelagem no tempo

Como o número de dados no tempo é reduzido (tem-se apenas 18 datas de aquisição das imagens, o que dificulta a modelagem no tempo) foi levantada, inicialmente, a possibilidade de gerar valores complementares através do cálculo da média entre imagens de datas “vizinhas”. No entanto, esta solução não seria muito confiável, principalmente pelo fato de que as imagens estão irregularmente distribuídas no tempo, ou seja, não possuem qualquer periodicidade, conforme pode ser observado na Figura 22. Além disso, este procedimento não solucionaria muito bem o problema, uma vez que o número de imagens a ser gerado também é limitado.

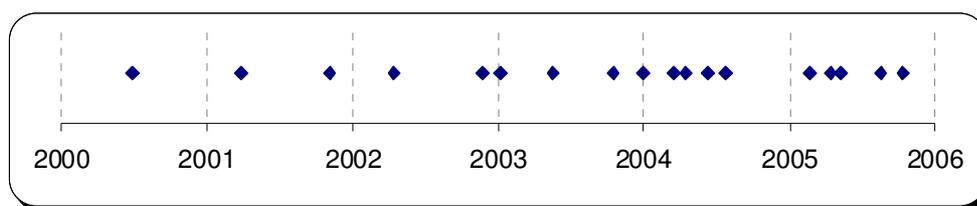


Figura 22 – Distribuição das imagens ao longo do tempo.

Uma alternativa encontrada para contornar este problema foi gerar o semivariograma experimental a partir do semivariograma empírico. Como o semivariograma empírico fornece valores de semivariância para todos os pares de pontos no tempo, o número reduzido de datas não dificulta a modelagem, uma vez que a partir das 18 datas é possível gerar 153 valores de semivariância. Deste modo, o semivariograma experimental pode ser obtido através da suavização do semivariograma empírico.

No entanto, nesta etapa, uma importante questão teve que ser solucionada: como representar toda a informação espacial através de um único valor por data?

Neste sentido, foi adotado no desenvolvimento do experimento um procedimento sugerido pela banca na ocasião do Exame de Qualificação: trabalhar com pequenos segmentos, ou regiões, de imagem da área de estudo, uma vez que esta abordagem permite um melhor entendimento do fenômeno. Assim, foram selecionadas 6 regiões nas quais foram medidos os valores de média, máximo e desvio-padrão do NDVI nas áreas infestadas por plantas. Destas regiões, uma foi selecionada para etapa de modelagem no tempo. Trata-se da região mais dinâmica do reservatório e talvez a mais problemática por ser a região onde se encontra a usina hidrelétrica.

A Figura 23 apresenta a região ou segmento da imagem selecionado

para a modelagem no tempo, em cada data, e a Figura 24 apresenta os respectivos histogramas. Do mesmo modo que na Figura 18, a escala radiométrica das imagens que compõem a Figura 23 não é global, mas sim individual, como pode ser notado na Figura 24.

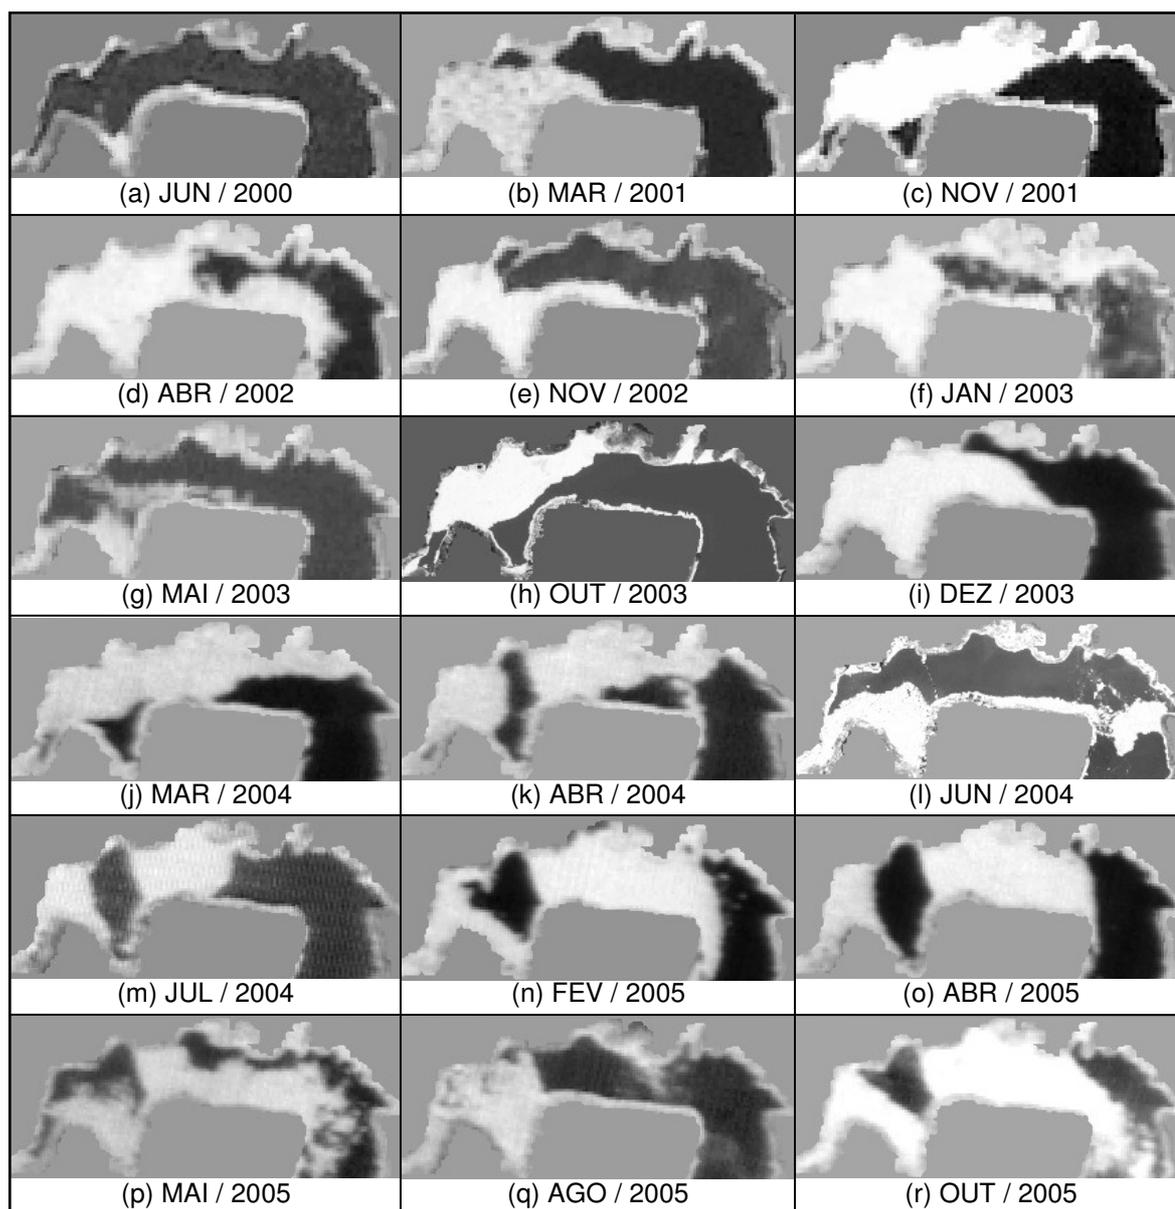


Figura 23 – Segmento da imagem, em cada data, para modelagem no tempo.

Pela Figura 23, nota-se a presença de uma barreira flutuante a partir da imagem (k), de Abril de 2004.

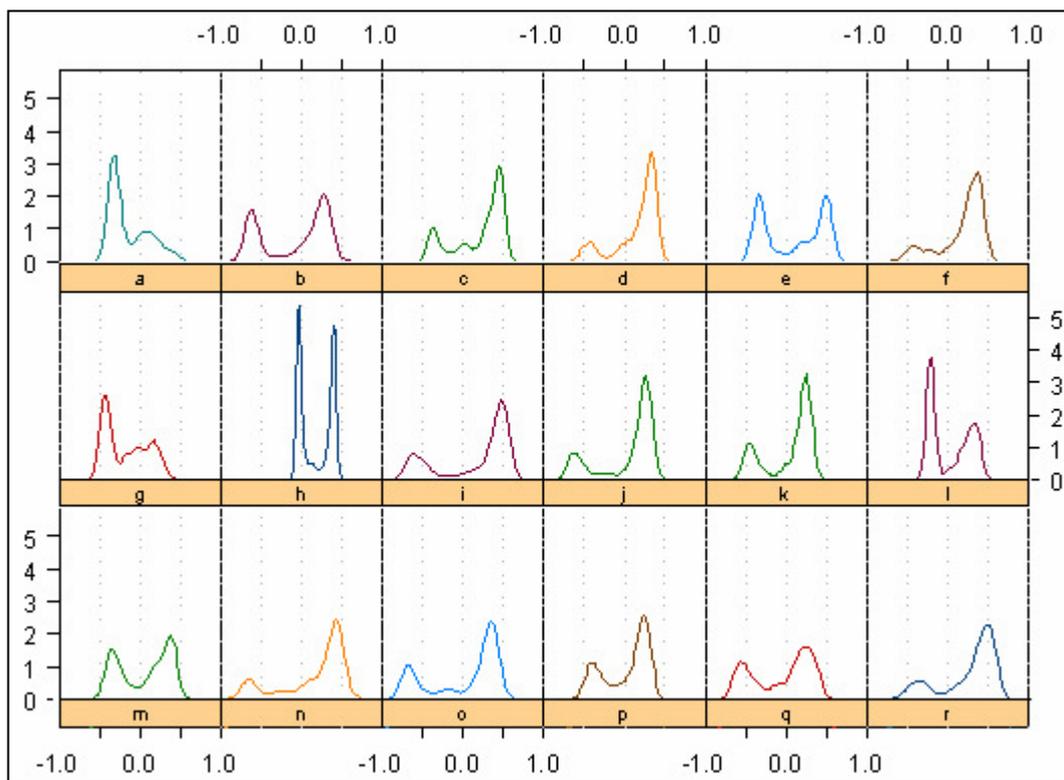


Figura 24 – Histograma do segmento de imagem para cada data.

A Figura 25 apresenta os valores de máximo e média do NDVI ao longo do tempo para o segmento selecionado e a Figura 26 os respectivos valores de desvio-padrão.

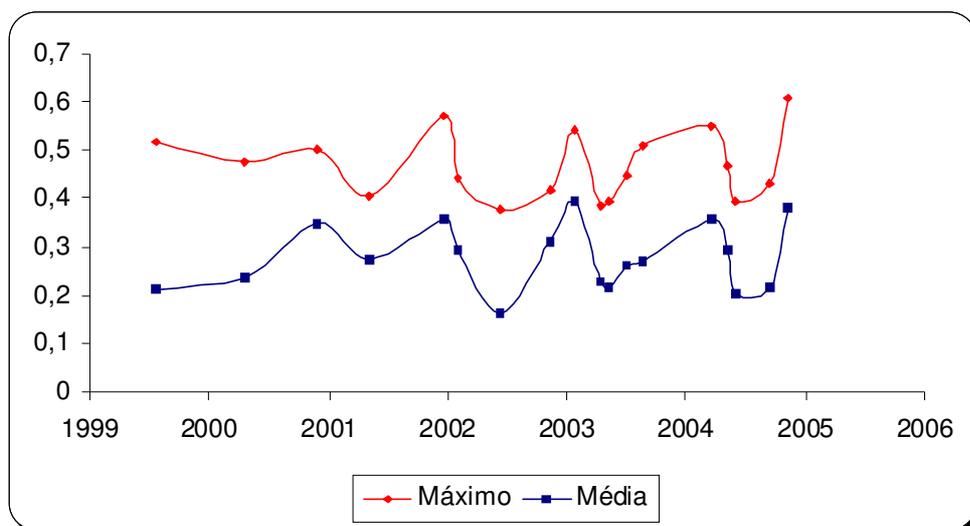


Figura 25 – Máximos e médias dos NDVI's ao longo do tempo para o segmento selecionado.

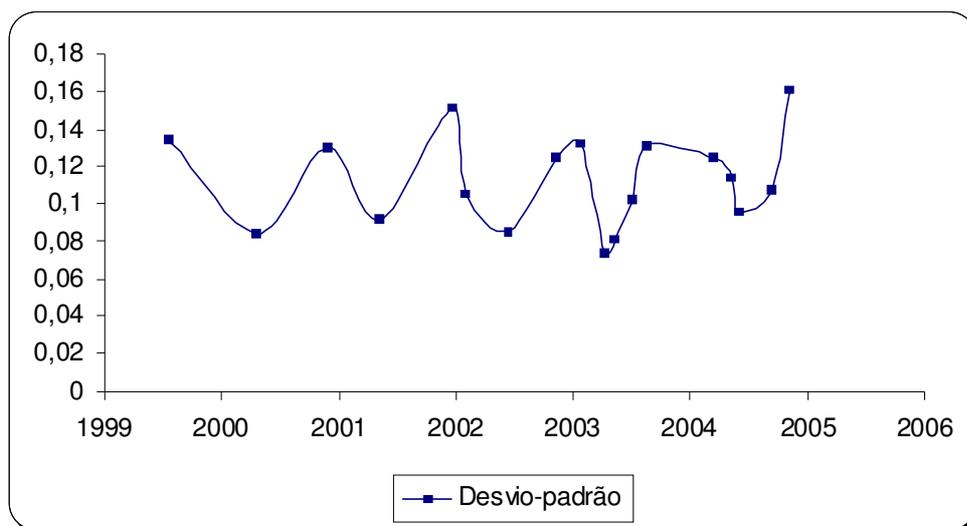


Figura 26 – Desvios-padrão dos NDVI's ao longo do tempo para o segmento selecionado.

Pelas Figuras 25 e 26 é possível perceber um padrão periódico no tempo para os valores de máximos, médias e desvios-padrão dos NDVI's, bem como uma alta correlação entre eles. Aparentemente, os valores são maiores no verão e menores no inverno, apresentando um ciclo de aproximadamente um ano.

A partir da análise do comportamento dos valores de máximo, média e desvio-padrão, ao longo do tempo, foi adotada como variável na modelagem temporal a média do NDVI. Deste modo, cada data passa a ser representada por um único valor: a média do NDVI da região infestada por plantas no segmento selecionado da área de estudo.

Definidos os valores a ser utilizados na modelagem temporal, foi gerado, utilizando o programa S-Plus 2000, o semivariograma empírico, mostrado na Figura 27:

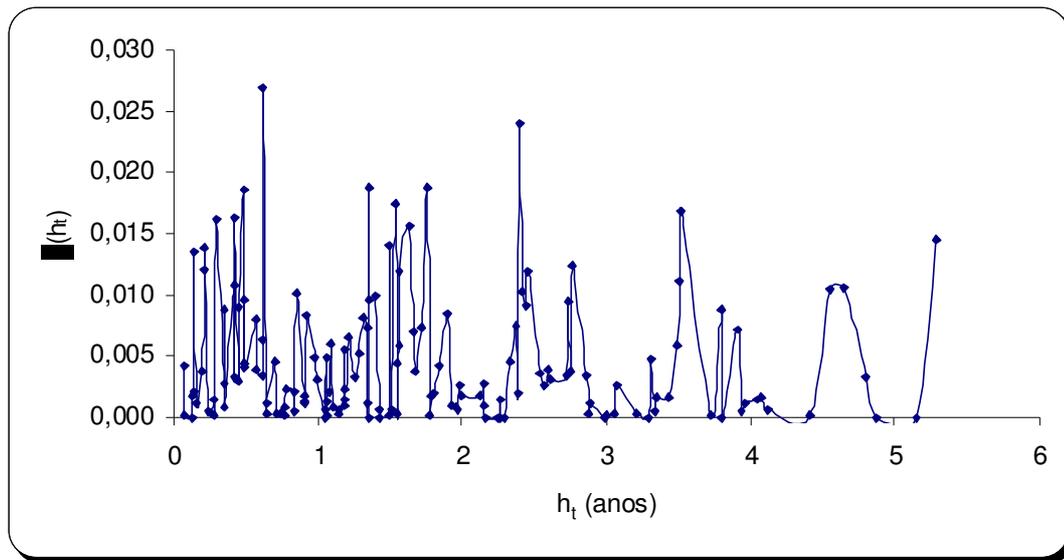


Figura 27 – Semivariograma empírico (no tempo).

A partir dos valores deste semivariograma empírico foi ajustado o modelo temporal, utilizando o S-Plus, através de uma regressão não-linear. No entanto, foram utilizados somente os valores de h_t (*lag* temporal) de 0 a 2 anos, uma vez que a alta variabilidade dos dados observados a partir 2 anos comprometem a qualidade de estimação dos parâmetros do modelo, como pode ser observado na Figura 28, na qual também se nota que o modelo ajustado com *lags* temporais de até 2 anos se aproxima mais da suavização – realizada através de uma média ponderada considerando uma vizinhança de 0,5 ano – do semivariograma empírico. A expressão analítica para o modelo temporal ajustado, dado pela Equação 36, é uma combinação de dois modelos: um exponencial, para modelar o início do semivariograma, e um periódico, com a função cosseno, capaz de representar as variações sazonais.

$$\gamma(h_t) = 0,00212336(1-\exp(-h_t/0,0223417))+ 0,00272745(1-\cos(2\pi h_t/1,01854)) \quad (36)$$

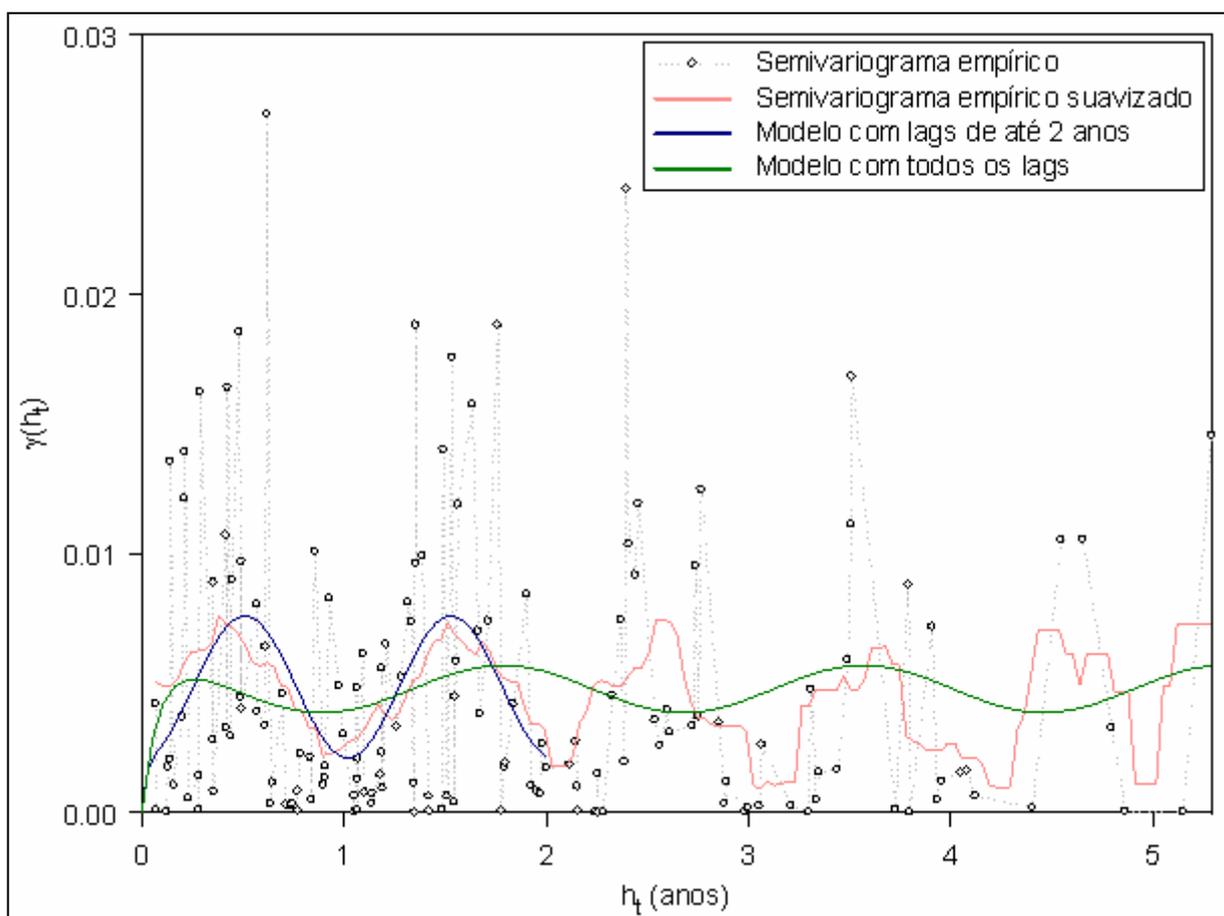


Figura 28 – Modelagem temporal.

5.4.5 Modelo espaço-temporal

Definidos os modelos espaciais, deve-se escolher apenas um para representar a variabilidade espacial, e o integrar com o modelo temporal, gerando-se o modelo espaço-temporal. Deste modo, foi adotado o modelo espacial ajustado a partir da imagem de máximos, no sentido de que esta imagem representa todos os locais onde houve infestação por plantas, ao longo do tempo.

Para integrar as componentes espacial e temporal, de acordo com o modelo produto-soma generalizado apresentado no Capítulo 4, precisa-se do valor de k , que “pondera” o produto dos modelos espacial e temporal. Para isto, é

necessário determinar graficamente, através da representação da superfície do semivariograma espaço-temporal, um patamar global $C\gamma_{st}(h_s, h_t)$. Além disto, o valor do patamar global deve escolhido de forma a atender ao critério apresentado na Equação 34.

Pelos modelos espacial e temporal, foram obtidos os valores de seus respectivos patamares: $C\gamma_{st}(h_s, 0) = 0,035$ e $C\gamma_{st}(0, h_t) = 0,0075$. Deste modo, para atender o critério de valores admissíveis para k , tem-se que:

$$0 < k \leq 1/\max\{0,035; 0,0075\} \rightarrow 0 < k \leq 1/0,035$$

$$0 < k \leq 28,57143 \quad (37)$$

Deste modo, pode-se obter o intervalo de valores admissíveis para o patamar global $C\gamma_{st}(h_s, h_t)$:

$$0 < \frac{C\gamma_{st}(h_s, 0) + C\gamma_{st}(0, h_t) - C\gamma_{st}(h_s, h_t)}{C\gamma_{st}(h_s, 0) \cdot C\gamma_{st}(0, h_t)} \leq 28,57143$$

$$0 < \frac{0,035 + 0,0075 - C\gamma_{st}(h_s, h_t)}{0,035 \cdot 0,0075} \leq 28,57143$$

$$0,035 \leq C\gamma_{st}(h_s, h_t) < 0,0425 \quad (38)$$

A Figura 29 apresenta a superfície do semivariograma espaço-temporal do qual foi estimado, visualmente, o valor do patamar global:

$$C\gamma_{st}(h_s, h_t) = 0,04 \quad (39)$$

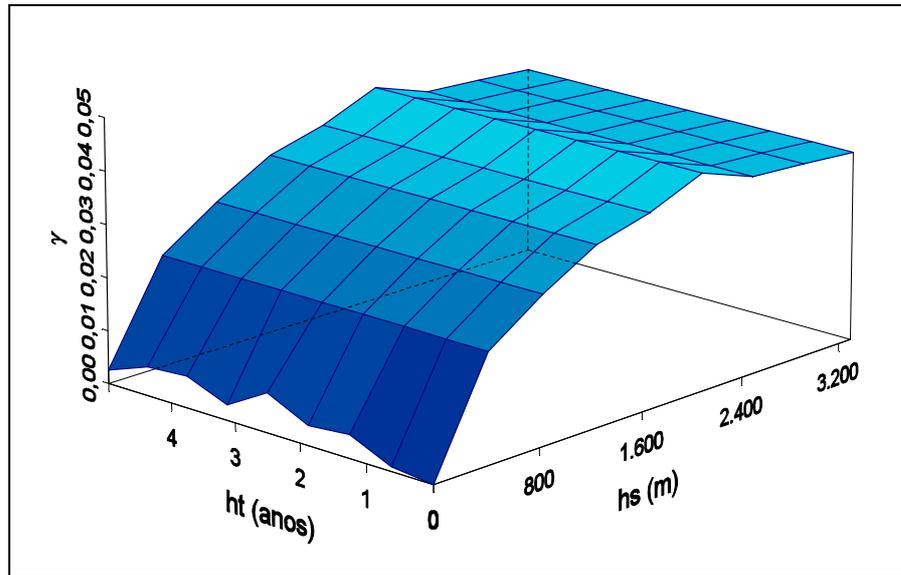


Figura 29 – Superfície do semivariograma espaço-temporal.

Definido o valor do patamar global, pela Equação 39, tem-se que:

$$k = \frac{0,035 + 0,0075 - 0,04}{0,035 \cdot 0,0075}$$

$$k = 9,52381 \quad (40)$$

Assim, o modelo espaço-temporal é definido por:

$$\gamma_{st}(h_s, h_t) = \gamma_{st}(h_s, 0) + \gamma_{st}(0, h_t) - 9,52381 \gamma_{st}(h_s, 0) \gamma_{st}(0, h_t) \quad (41)$$

com modelo espacial:

$$\gamma_{st}(h_s, 0) = 0,03 + 0,035(1 - \exp(-h_s/1768,086)) \quad (42)$$

e modelo temporal conforme definido na Equação 36.

A Figura 30 apresenta o modelo espaço-temporal na sua forma gráfica:

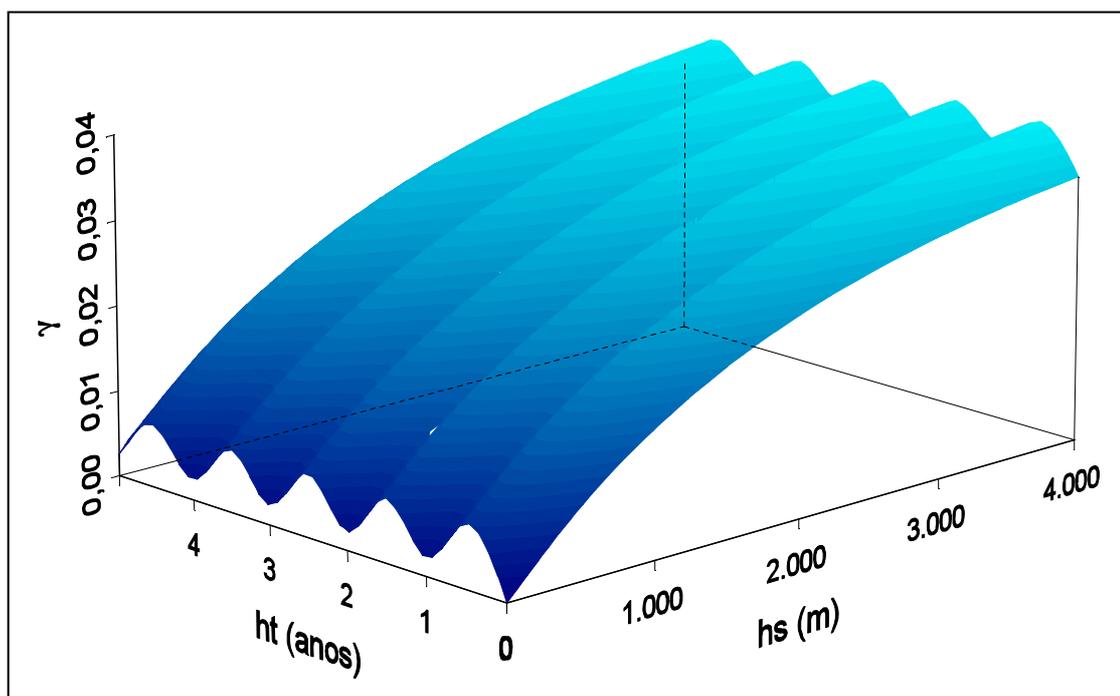


Figura 30 – Modelo espaço-temporal.

Com este modelo, tem-se caracterizado a estrutura da dispersão espaço-temporal do fenômeno, no caso, da presença de plantas aquáticas invasoras, representada pelos valores de NDVI.

Obtido o modelo espaço-temporal, tem-se a possibilidade da utilização deste modelo para realizar inferências sobre o comportamento do fenômeno, em um determinado instante do tempo para o qual não se dispõe de dados espectrais e espaciais. Contudo, os programas que disponibilizam ferramentas para realizar análises geoestatísticas não estão preparados para trabalhar com abordagens espaço-temporais, pois consideram apenas a dimensão espacial. Isto impossibilitou a verificação do modelo para a realização de inferências

por krigagem, etapa inicialmente prevista na proposta.

Entretanto, buscou-se uma alternativa para realizar uma previsão num futuro próximo usando o modelo espaço-temporal. Para isto, os programas que trabalham com geoestatística no espaço são suficientes, pois, adotando-se apenas os elementos amostrais de uma imagem “vizinha”, tem-se apenas um valor de *lag* temporal, ou seja, a componente temporal do modelo torna-se uma constante. Assim, o modelo espaço-temporal passa a ser função somente do *lag* espacial, isto é, leva em conta somente a componente espacial, com parâmetros modificados.

Deste modo, uma previsão num futuro próximo pôde ser realizada por uma inferência no espaço através de uma interpolação por krigagem.

5.4.6 Previsão

Com a disponibilidade de mais uma imagem CCD/CBERS-2, de 26 de dezembro de 2005, não utilizada na modelagem do experimento, decidiu-se testar o modelo espaço-temporal para realização de uma previsão, tomando esta imagem como referência.

Para isto, esta imagem também foi submetida aos mesmos processamentos iniciais aplicados às demais imagens: reamostragem, registro, normalização radiométrica, geração do NDVI, recorte da área de estudo e do segmento de interesse. A imagem resultante destes processamentos pode ser vista na Figura 31:

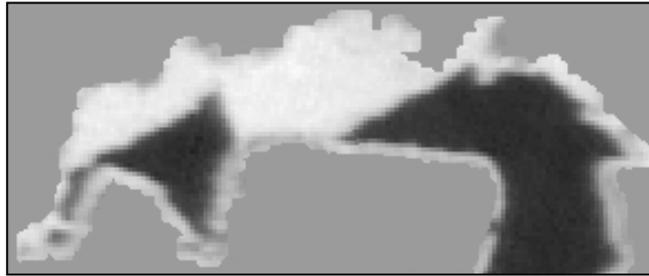


Figura 31 – Imagem de DEZ / 2005.

Pela diferença entre as datas das imagens de JUN / 2000 (origem temporal) e de DEZ / 2005, tem-se o *lag* temporal:

$$h_t = 5,5027 \quad (43)$$

Aplicando-se este valor de h_t na componente temporal do modelo, tem-se que:

$$\gamma_{st}(0;5,5027) = 0,007083 \quad (44)$$

Substituindo-se a componente temporal por esta constante (44) no modelo espaço-temporal (41), tem-se que:

$$\gamma_{st}(h_s;5,5027) = \gamma_{st}(h_s,0) + 0,007083 - 9,52381 \cdot \gamma_{st}(h_s,0) \cdot 0,007083$$

$$\gamma_{st}(h_s;5,5027) = 0,932543 \cdot \gamma_{st}(h_s,0) + 0,007083$$

$$\gamma_{st}(h_s;5,5027) = 0,035 + 0,033 \cdot (1 - \exp(-h_s / 1768,086)) \quad (45)$$

Definido o modelo, foram utilizados os elementos amostrais da imagem mais próxima no tempo – a de Outubro de 2005 – para realizar a previsão através de uma interpolação por krigagem ordinária, utilizando o programa SPRING, obtendo-se como resultado um MNT (Modelo Numérico do Terreno) que representa a previsão dos valores de NDVI para imagem de referência.

A fim de comparar a previsão realizada com a imagem de referência, ambas foram classificadas da seguinte maneira: os valores menores ou iguais a zero foram considerados água e os valores maiores que zero foram associados a plantas aquáticas. Para isso, fez-se uma tabulação cruzada, na qual se verificou **53,82%** de concordância entre a previsão e a imagem de referência para a classe planta aquática, ou seja, 53,82% dos valores previstos como planta realmente são plantas na imagem de referência. Além disso, a concordância para a categoria planta aquática foi de **85,02%**, o que indica que, de toda área infestada por plantas na imagem de referência, 85,02% foi prevista como planta aquática pelo modelo. A Figura 32 apresenta a imagem resultante da classificação cruzada, mostrando a concordância espacial entre a imagem de referência e a previsão.

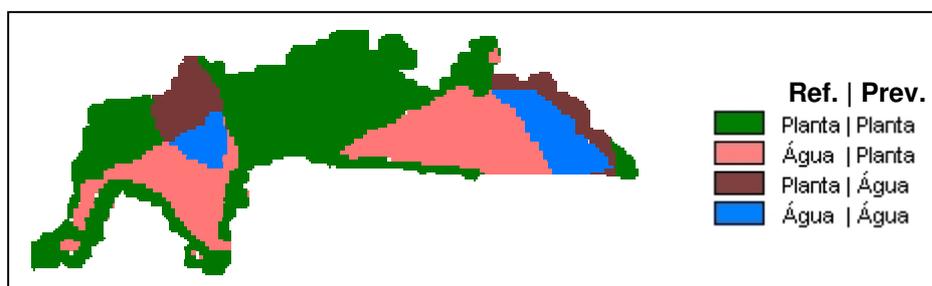


Figura 32 – Classificação cruzada.

6 CONCLUSÕES E RECOMENDAÇÕES

Considerando a hipótese inicial e os resultados apresentados, verifica-se que o objetivo do trabalho foi alcançado, isto é, através do método desenvolvido e dos dados multitemporais utilizados, foi obtido um modelo que caracteriza o comportamento da variável – plantas aquáticas – representado pelos valores de NDVI, no espaço e no tempo.

Para alcançar o objetivo proposto, vários procedimentos tiveram que ser desenvolvidos e os resultados parciais cuidadosamente avaliados. Inicialmente, a fim de garantir a consistência radiométrica e geométrica, de diminuir a dimensionalidade espectral dos dados e separar a informação de interesse, todas as imagens multiespectrais/multitemporais foram submetidas a um conjunto de processamentos iniciais: reamostragem, registro, normalização radiométrica, geração do NDVI e recorte da área de estudo.

Paralelamente, para verificar o grau de correlação no tempo – fator importante para que a modelagem no tempo tivesse sentido – foram calculadas as correlações entre as imagens a partir de elementos amostrais obtidos por um processo de amostragem sistemática não-alinhada (e posteriormente adensado em locais críticos). Os resultados mostraram que existe uma correlação temporal significativa, oferecendo subsídios para a realização da modelagem temporal.

Em seguida, foi feita a modelagem espacial, através das ferramentas da geoestatística, na qual foram obtidos modelos para cada data e escolhido um único modelo espacial, obtido pelos valores máximos de NDVI de todas as datas, e que sintetiza a informação espacial, para ser utilizado como componente do modelo integrado (espaço-temporal).

Para a modelagem temporal, dois problemas tiveram de ser solucionados: 1) como sintetizar a informação espacial em um valor único e; 2) como gerar o modelo temporal com um número reduzido de valores no tempo (18 datas). Para contornar o primeiro problema, optou-se por trabalhar em uma região específica da área de estudo e considerar a média do NDVI em cada data como a variável a ser modelada no tempo. Já a falta de dados no tempo foi contornada com a utilização do semivariograma empírico ao invés do semivariograma experimental. Deste modo, através de um ajustamento não-linear, foram ajustados os parâmetros do modelo temporal. Pelo modelo temporal ajustado, pôde-se perceber claramente um comportamento periódico da variável ao longo do tempo, em ciclos de aproximadamente um ano.

Por fim, foi gerado o modelo espaço-temporal, de acordo com o modelo produto-soma generalizado, o qual integra as componentes espacial e temporal, caracterizando assim, a estrutura da variabilidade do fenômeno no espaço e no tempo.

Como não se dispunha de aplicativos adequados, não foi possível utilizar o modelo para realizar inferências, como estava previsto. No entanto, os aplicativos disponíveis foram suficientes para realizar uma previsão para uma data futura. Apesar dos resultados parecerem bem satisfatórios para a previsão da presença de plantas aquáticas, este tipo de previsão é, de certa forma, pouco confiável, pois trata-se de um fenômeno ambiental, sujeito a uma série de perturbações naturais e/ou antrópicas, do tipo:

- Diversos tipos de manejo, como por exemplo a remoção mecânica de plantas do reservatório são realizadas de tempos em tempos, em períodos não regulares, para controlar o grau de infestação por plantas aquáticas invasoras. Além disto, a

implantação de uma barreira flutuante, próximo a usina hidrelétrica, modifica totalmente o regime distribuição das plantas na região adotada no experimento;

- Ocorrência de fatores que influenciam direta ou indiretamente no comportamento do fenômeno analisado e que não foram considerados no modelo, como por exemplo, os componentes químicos da água. Um fator externo que, aparentemente, modificou o comportamento esperado para o fenômeno foi a direção dos ventos: apenas nos últimos meses do ano e às vezes também nos primeiros meses (no verão) percebeu-se que a dispersão das plantas na região considerada no experimento seguiu um padrão, agrupando-se na direção noroeste.

Como recomendação para trabalhos futuros que tratem do assunto em questão, pode-se sugerir:

- Procurar utilizar co-variáveis, ou seja, incorporar ao modelo espaço-temporal variáveis correlacionadas com a presença de plantas aquáticas invasoras, como por exemplo, dados meteorológicos, dados de qualidade da água do reservatório, entre outros;
- Utilizar o método proposto neste trabalho para investigar outros fenômenos, que não estejam sujeitos a interferências antrópicas muito drásticas;
- Por fim, utilizar outras abordagens espaço-temporais, como por exemplo, a geoestatística aliada à abordagem bayesiana.

REFERÊNCIAS

BAILEY, T. C.; GATRELL, A. C. Interactive spatial data analysis. Essex: Longman, 1995. 413p.

CAMARGO, E. C. G. Desenvolvimento, implementação e teste de procedimentos geoestatísticos (krigagem) no Sistema de Processamento de Informações Georreferenciadas (SPRING). São José dos Campos, 1997. Disponível em: <http://www.dpi.inpe.br/teses/eduardo>. Acesso em: 20 set. 2003.

CENTENO, J. A. S. Sensoriamento remoto e processamento digital de imagens. Departamento de Geomática. Curitiba: UFPR, 2003, 210p.

CRESSIE, N., HUANG, H., Classes of nonseparable spatio-temporal stationary covariance functions. *Journal of the American Statistical Association*, 94, n. 448, p.1330-1340, 1999.

CRUZ, N. C. Uma análise da infestação por plantas aquáticas utilizando imagens multiescala e redes neurais artificiais. 2005. 101 f. Dissertação (Mestrado em Ciências Cartográficas). Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente.

DE CESARE, L.; MYERS, D. E. ; POSA, D. Estimating and modeling space-time correlation structures. (2000). Statistics e Probability Letters, 51, p.9-14, 2001. Disponível em: <<http://www.donatoposa.it.htm>>. Acesso em: 25 set. 2003.

DE IACO, S.; MYERS, D. E.; POSA, D. Space-time analysis using a general product-sum model. Statistics e Probability Letters, 52, p.21-28, 2001. Disponível em: <<http://www.donatoposa.it/sandra.htm>>. Acesso em: 25 set. 2003.

_____. Space-time variograms and a functional form for total air pollution measures. Computational Statistics and Data Analysis, 41, p.311-328, 2002. Disponível em: <<http://www.donatoposa.it/sandra.htm>>. Acesso em: 25 set. 2003.

DEUTSCH, C. V.; JOURNEL, A. G. GSLIB: Geostatistical Software Library and user's guide. New York: Oxford University Press, 1992. 339p.

DRUCK, S.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. M. V. (Ed.) Análise espacial de dados geográficos. Planaltina: Embrapa Cerrados, 2004. 209p.

ESPINHOSA, M. C. Utilização do Sensoriamento Remoto orbital e redes neurais artificiais no mapeamento de macrófitas aquáticas emersas em grandes reservatórios. 2004. Dissertação (Mestrado em Ciências Cartográficas). Faculdade de Ciências e Tecnologia, Universidade Estadual Paulista, Presidente Prudente.

FLORENZANO, T. G. Imagens de satélite para estudos ambientais. São Paulo: Oficina de Textos, 2002. 97p.

GALO, M.L.B.T.; NOVO, E. M.L.M. Normalização radiométrica de imagens: um meio de integrar dados multitemporais de Sensoriamento Remoto para monitoramento ambiental. Revista do Instituto Florestal, São Paulo, v.1, n.12, p.67-75, 2000.

GALO, M. L. B. T.; VELINI, E. D.; TRINDADE, M. L. B.; SANTOS, S. C. A. Uso de Sensoriamento Remoto orbital no monitoramento da dispersão de macrófitas nos reservatórios do Complexo Tietê. Planta Daninha, Edição Especial de Plantas Aquáticas, v.20, p.7-20, 2002.

GNEITING, T.; GENTON, M. G.; GUTTORP, P. Geostatistical space-time models, stationarity, separability and full symmetry. Technical report, n. 475. Seattle: Department of Statistics, University of Washington, 2005. Disponível em: www.stat.washington.edu/www/research/reports/2005/tr475.pdf. Acesso em: 10 abr. 2005.

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

LANDIM, P. M. B. Análise estatística de dados geológicos. São Paulo: UNESP, 1998. 226p.

LEITE, M. A. Análise do aporte, da taxa de sedimentação e da concentração de metais na água, plâncton e sedimento do Reservatório de Salto Grande, Americana-SP. 2002. Tese (Doutorado em Ciências da Eng. Ambiental). Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos.

LIMA, D. L.; GALO, M. L. B. T.; IMAI, N. N. Aplicação do modelo de cores IHS na detecção de plantas aquáticas imersas. In: Simpósio Brasileiro de Sensoriamento Remoto, 12. (SBSR), 16-21 abr. 2005, Goiânia. Anais... São José dos Campos: INPE, 2005. Artigos. CD-ROM.

MINGOTI, S. A; NEVES, O. F. A metodologia de geoestatística como alternativa na análise de séries temporais. Revista Escola de Minas (REM), Ouro Preto, v.52, n.3, 182-187, 1999. Disponível em: http://www.est.ufmg.br/prevgeo/artigo_1.pdf. Acesso em: 08 fev. 2005.

MONTEIRO, R. C. Estimativa espaço-temporal da superfície potenciométrica do sistema Aquífero Guarani na cidade de Ribeirão Preto (SP), Brasil. 2003. 212 f. Tese (Doutorado em Geociências). Instituto de Geociências e Ciências Exatas, Universidade Estadual Paulista, Rio Claro.

MOREIRA, M. A. Fundamentos do Sensoriamento Remoto e metodologias de aplicação. São José dos Campos: INPE, 2001. 250p.

MYERS, D. E.; DIBAKOR, R. B. Valid models for space-time variograms. 2003. 5f. Research paper. Undergraduate Research Assistantship Program, University of Arizona, Tucson. Disponível em: <http://math.arizona.edu/~ura/034/Dibakor.RoyBapy/ResearchPaper.htm>. Acessado em: 05 ago. 2005.

NOVO, E. M. L. M. Sensoriamento remoto: princípios e aplicações. São Paulo, Edgard Blucher, 1989.

NOVO, E. M. L. M.; BRAGA, C.Z.F.; TUNDISI, J. G. Use of TM/Landsat data to retrieve the optically active water constituents from an eutrophic tropical reservoir. Proceedings of ISPRS Commission VII Symposium: Resource and Environmental Monitoring, Rio de Janeiro, sept-26-30, 1994, INPE, Vol.30, Part 76, 1994, p.258-62.

NOVO, E. M. L. M.; HAMSOM, J. D.; CURRAN, P. J. The effect of sediment type on the relationship between reflectance and suspended sediment concentration. International Journal of Remote Sensing, v.10, n.7, p.1283-1289, 1989.

RICHARDS, J. A. Remote sensing digital image analysis: an introduction. New York: Springer-Verlag, 1986. 300p.

ROBIN, M. La télédétection. Coll. Fac Géographie. Paris: Nathan, 1995. 318p.

SHIMABUKURO, Y. E.; SMITH, J. A. The least-squares mixing models to generate fraction images derived from remote sensing multispectral data. IEEE Transactions on Geoscience and Remote Sensing, v.29, n.1, p.16-20, 1991.

VIVAR-ROJAS, J. C. Uma nova classe de modelos espaço-temporais para dados de área. 2004. 114 f. Dissertação (Mestrado em Estatística). Instituto de Matemática, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)