

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
FACULDADE DE CIÊNCIAS AGRONÔMICAS  
CÂMPUS DE BOTUCATU

**GEOESTÍMICA E SENSORIAMENTO REMOTO NA  
CLASSIFICAÇÃO DE IMAGENS EM ÁREAS CULTIVADAS COM  
CITROS**

ALESSANDRA FAGIOLI DA SILVA

Dissertação apresentada à Faculdade de  
Ciências Agronômicas da Unesp – Campus de  
Botucatu, para obtenção do título de Mestre em  
Agronomia (Energia na Agricultura)

BOTUCATU - SP

Fevereiro – 2011

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
FACULDADE DE CIÊNCIAS AGRONÔMICAS  
CÂMPUS DE BOTUCATU

**GEOESTÍSTICA E SENSORIAMENTO REMOTO NA  
CLASSIFICAÇÃO DE IMAGENS EM ÁREAS CULTIVADAS COM  
CITROS**

ALESSANDRA FAGIOLI DA SILVA

Orientadora: Prof. Dr. Célia Regina Lopes Zimback

Co-orientador: Prof. Dr. Paulo Milton Barbosa Landim

Dissertação apresentada à Faculdade de  
Ciências Agronômicas da Unesp – Campus de  
Botucatu, para obtenção do título de Mestre em  
Agronomia (Energia na Agricultura)

BOTUCATU - SP

Fevereiro – 2011

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉCNICA DE AQUISIÇÃO E TRATAMENTO DA INFORMAÇÃO - SERVIÇO TÉCNICO DE BIBLIOTECA E DOCUMENTAÇÃO - UNESP - FCA - LAGEADO - BOTUCATU (SP)

S586g Silva, Alessandra Fagioli da, 1983-  
Geoestatística e sensoriamento remoto na classificação de imagens em áreas cultivadas com citros / Alessandra Fagioli da Silva. - Botucatu : [s.n.], 2011

xi, 83 f. : ils., tabs.

Dissertação (Mestrado) - Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas, Botucatu, 2011

Orientador: Célia Regina Lopes Zimback

Co-orientador: Paulo Milton Barbosa Landim

Inclui bibliografia

1. Krigagem indicativa. 2. Satélite CBERS-2B. 3. Classificadores de imagens. I. Zimback, Célia Regina Lopes. II. Landim, Paulo Milton Barbosa. III. Universidade Estadual Paulista "Júlio de Mesquita Filho" (Campus de Botucatu). Faculdade de Ciências Agrônômicas. IV. Título.

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

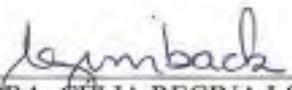
CERTIFICADO DE APROVAÇÃO

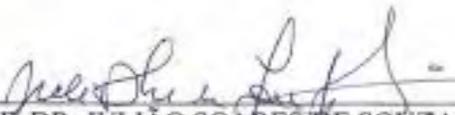
TÍTULO: "GEOESTATÍSTICA E SENSORIAMENTO REMOTO NA CLASSIFICAÇÃO  
DE IMAGENS EM ÁREAS CULTIVADAS COM CITRUS"

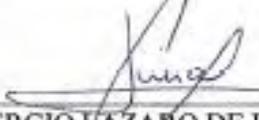
ALUNA: ALESSANDRA FAGIOLI DA SILVA

ORIENTADOR: PROFA. DRA. CÉLIA REGINA LOPES ZIMBACK

Aprovado pela Comissão Examinadora

  
\_\_\_\_\_  
PROFA. DRA. CÉLIA REGINA LOPES ZIMBACK

  
\_\_\_\_\_  
PROF. DR. JÚLIO SOARES DE SOUZA LIMA

  
\_\_\_\_\_  
PROF. DR. SÉRGIO LAZARO DE LIMA

Data da Realização: 28 de fevereiro de 2011.

**Á DEUS**

Autor da vida.

Aos meus pais Adão e Balbina,  
meus exemplos de vida...

Aos meus irmãos Sandro e Fagno e aos amigos,  
que muito me ajudaram nesta fase da minha vida.

Ao meu namorado Rone,  
meu conselheiro particular e exemplo de pesquisador.

Dedico

“Grandes medos só podem ser vencidos mediante o cultivo de pequenas coragens”.

(Fábio de Melo e Gabriel Chalita, 2010)

## AGRADECIMENTO ESPECIAL

À minha orientadora, *Prof. Dra. CÉLIA REGINA LOPES ZIMBACK*, agradeço pelos ensinamentos, solidariedade, por ser atenciosa, correta, pela confiança em mim depositada e pela grande amizade que construímos... e pelas orientações artesanais. Suas palavras de incentivo e o grande empenho nas etapas da dissertação foram essenciais para a qualidade deste trabalho.

Ao *Prof. Dr. PAULO MILTON BARBOSA LANDIM*, pela co-orientação, amizade, ajuda nos ensinamentos, dedicação e disposição em ajudar.

**Minha eterna gratidão.**

## AGRADECIMENTOS

A Deus, que iluminou o meu caminho rumo aos planos a mim determinados.

Aos meus pais Adão e Balbina, pelo apoio, compreensão, simplicidade, sabedoria e ensinamentos concebidos ao longo da vida.

Aos meus irmãos Sandro e Fagno, pelo incentivo, apoio e carinho.

À minha cunhada Rosilei, pelo entusiasmo, constante incentivo, apoio e, principalmente, pelos conselhos.

Ao Prof. Dr. Julião, pela grande amizade, ensinamentos, solidariedade, por ser atencioso, amigo e conselheiro.

À comadre Célia Cristina Costa de Souza Lima, pelo apoio, amizade e consideração.

Ao meu noivo Rone, pela compreensão, e companherismo nesta fase da minha vida, pelos ensinamentos científicos e por ter me apresentado a geoestatística.

Aos meus tios Jaime e Maria Fagioli, pelo apoio e conselhos.

Aos colegas e amigos conquistados durante a pós-graduação, especialmente a Ana Paula, Anderson, André, Clovis, Diego, Ednéia, Eliel, Estelita, Fábio, Francienne, Indiamara, Juliano, Junia, Karina, Leslie, Lucivane, Lessa, Marystella, Patrícia, Ramon, Renato, Ricardo, Rodrigo, Talita, Waylson, pelo apoio recebido, auxílio nos trabalhos, sugestões, críticas, pelos momentos de descontração, carinho, amizade e pela agradável convivência.

À Ana, minha amiga que sempre ajudou a tornar as coisas menos difíceis, tirando minhas dúvidas, dando dicas para o trabalho e me ensinando os processamentos de imagem de sensoriamento remoto.

Ao Lessa, pela dicas de utilização do SIG-SPRING.

Aos integrantes do Grupo de Estudos e Pesquisas Agrárias Georreferenciadas - GEPAG, pelos ensinamentos recebidos, pela saudável e cordial amizade.

À Faculdade de Ciências Agronômicas/UNESP, Campus de Botucatu-SP, pelo curso de pós-graduação, conceituado corpo docente, estrutura física e por me abrir os caminhos do conhecimento científico e pelo crescimento pessoal e profissional.

Ao Departamento de Recursos Naturais/Ciência do Solo, por conceder-me a oportunidade de desenvolver o trabalho no Laboratório de Geoprocessamento.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro, sem o qual a realização da dissertação seria comprometida.

Aos Professores e funcionários do Departamentos de Recursos Naturais/Ciência do Solo, pela atenção dedicada, pela amizade e por toda ajuda prestada.

Aos funcionários da biblioteca e às secretárias da Seção de Pós Graduação, pela atenção e dedicação.

E a todos que de maneira direta ou indireta contribuíram para a realização deste trabalho.

**MUITO OBRIGADA!**

## SUMÁRIO

	Páginas
OFERECIMENTO .....	II
AGRADECIMENTO ESPECIAL .....	III
AGRADECIMENTO .....	IV
SUMÁRIO .....	VI
LISTA DE TABELAS .....	IX
LISTA DE FIGURAS .....	X
LISTA DE FÓRMULAS.....	XI
1 RESUMO .....	1
2 SUMMARY .....	3
3 INTRODUÇÃO.....	5
4 REVISÃO DE LITERATURA .....	7
4.1 Citros .....	7
4.2 Geoprocessamento.....	8
4.2.1 Sistema de Informação Geográfica - SIG.....	9
4.2.1.1 Características do sistema.....	11
4.2.1.2 Programa - SPRING.....	12
4.2.2 Sensoriamento Remoto.....	14
4.2.2.1 Conceitos e características de imagens orbitais .....	16
4.2.2.2 Processamento de dados digitais.....	17
4.2.2.3 Sistema CBERS .....	19
4.2.2.4 Interação culturas perenes e imagem de satélite .....	20
4.3 Classificadores Digitais de Imagens.....	22
4.3.1 Classificação Supervisionada .....	23
4.3.1.1 Krigagem Indicativa - KI.....	23
4.3.1.1.1 Metodologia geoestatística.....	23
4.3.1.1.1.1 Variograma.....	25
4.3.1.1.1.2 Krigagem .....	29
4.3.1.1.1.2.1 Krigagem ordinária .....	30
4.3.1.1.1.2.2 Krigagem Indicativa - KI.....	32

4.3.1.1.1.3 Validação da Krigagem.....	34
4.3.1.2 Máxima Verossimilhança - MAXVER.....	35
4.3.2 Classificação Não Supervisionada .....	36
4.3.2.1 <i>CLUSTER</i> .....	36
4.3.3 Validação das classificações.....	37
4.3.4 Aplicações .....	39
5 MATERIAL E MÉTODOS.....	41
5.1 Descrição da Área de Estudo.....	41
5.2 Material.....	43
5.2.1 Equipamentos .....	43
5.2.2 Software SPRING .....	43
5.2.3 Base de dados .....	44
5.2.3.1 Imagens de Satélite .....	44
5.3 Metodologia.....	44
5.3.1 Criação do Banco de Dados Geográficos .....	44
5.3.2 Processamento Digital das Imagens .....	45
5.3.2.1 Pré Processamento .....	45
5.3.2.1.1 Importação e Transformação de Imagens pelo o SIG-SPRING ....	45
5.3.2.1.2 Registro das imagens de satélite .....	46
5.3.2.1.3 Mosaico das imagens de satélite .....	46
5.3.2.2 Interpretação visual das imagens .....	47
5.3.2.3 Classificação das Imagens .....	48
5.3.2.3.1 Classificação Supervisionada.....	48
5.3.2.3.1.1 Krigagem Indicativa - KI.....	48
5.3.2.3.1.2 Máxima Verossimilhança - MAXVER .....	49
5.3.2.3.2 Classificação Não Supervisionada .....	50
5.3.2.3.2.1 Segmentação de Imagens.....	51
5.3.2.4 Validação das Classificações .....	52
5.3.2.5 Correlação dos classificadores.....	53
6 RESULTADOS E DISCUSSÃO .....	54
6.1 Interpretação visual das imagens.....	55

6.2 Krigagem Indicativa - KI.....	56
6.3 Máxima Verossimilhança - MAXVER .....	60
6.4 CLUSTER .....	61
6.5 Comparação de métodos de classificação de imagens .....	63
6.5.1 Índice Kappa.....	63
6.5.2 Quantificação de áreas de citros .....	64
6.5.3 Correlação dos classificadores.....	64
6.5.4 Considerações Finais .....	65
7 CONCLUSÕES .....	66
8 REFERÊNCIAS .....	68

**LISTA DE TABELAS**

	Páginas
1. Características da câmara CCD .....	20
2. Nível de exatidão de uma classificação, conforme o valor de índice .....	53
3. Modelo e parâmetros do ajuste do variograma da Banda 4 (infravermelha) da câmara CCD do CBERS-2B .....	58
4. Comparação dos classificadores pelo Índice Kappa.....	63
5. Quantificação de área de citros pelos classificadores e diferença de área.....	64

**LISTA DE FIGURAS**

	Páginas
1. Estrutura de Sistemas de Informação Geográfica.....	11
2. Configuração do ambiente SPRING.....	13
3. Imagens de cultura de citros com diferentes alturas de tomada de imagens: (a) a 1000 m e (b) a 100 m.....	21
4. Variograma típico e seus componentes. ....	27
5. Localização da área de estudo. ....	42
6. Máscara de da drenagem e mata ciliar da área de estudo. ....	47
7. Mapa resultante do mosaico da composição das bandas 4, 3 e 2 da câmara CCD do CBERS-2B, de parte da mesoregião de Bauru e Araraquara. ....	55
8. Áreas cultivadas com citros resultantes da interpretação visual. ....	56
9. Pontos amostrais da Banda 4 (infravermelha) da câmara CCD do CBERS-2B.....	57
10. Variograma da Banda 4 (infravermelha) da câmara CCD do CBERS-2B.....	58
11. Mapa de probabilidade da Banda 4 (infravermelha) da câmara CCD do CBERS-2B. ....	59
12. Classificação por KI da Banda 4 (infravermelha) da câmara CCD do CBERS-2B. ....	60
13. Classificação MAXVER para CITROS e NÃO CITROS.....	61
14. Classificação <i>CLUSTER</i> para CITROS e NÃO CITROS. ....	62

**LISTA DE FÓRMULAS**

	Páginas
1 Equação do variograma .....	26
2 Equação do Índice de Dependência Espacial .....	28
3 Equação da Krigagem Ordinária .....	30
4 Equação dos pesos utilizados na Krigagem .....	31
5 Equação da função de distribuição de probabilidades acumuladas .....	33
6 Equação do intervalo probabilístico da variável .....	34
7 Equação do variograma do número digital .....	49
8 Equação da estatística Kappa .....	52
9 Equação da a exatidão geral .....	52
10 Equação da proporção de unidades que concordam por casualidade .....	52

## **1 RESUMO**

A citricultura é importante para a economia brasileira devido aos recordes de exportações e pela geração de empregos direto e indireto. O sensoriamento remoto é a fonte primária de informações sobre a cobertura do solo em decorrência dos avanços tecnológicos nos sistemas sensores. A incorporação de procedimentos geoestatísticos em estudos ambientais baseado em técnicas de Krigagem tem sido utilizada por profissionais da área de sensoriamento remoto. O objetivo deste trabalho foi comparar a precisão de métodos de classificação de imagens orbitais na determinação de áreas cultivadas com citros, na Mesoregião de Bauru e Araraquara, através de métodos de sensoriamento remoto e geoestatísticos, para a discriminação e quantificação da área plantada. A área de estudo utilizada nesta pesquisa esta localizada na região central do Estado de São Paulo, com uma área de 56.146,78 ha. Foi utilizado o SIG-SPRING para o processamento dos dados. Foram utilizadas as bandas 2, 3 e 4 da imagem digital proveniente do satélite CBERS 2B, câmera CCD (Câmera Imageadora de Alta Resolução) que fornece imagens com uma resolução espacial de 20 metros. A imagem foi de 16/04/2009, nas órbitas/ponto 157/124 e 157/125. No processo de classificação das imagens foram estudados três métodos de classificação, sendo o

*CLUSTER* não-supervisionado, o MAXVER (Máxima Verossimilhança) e a KI (Krigagem Indicativa) supervisionados, além da classificação em tela tida como verdade terrestre. As fidedignidades das classificações foram avaliadas pelo índice Kappa. Pelos resultados obtidos nas classificações de imagem para a discriminação e quantificação de áreas cultivadas com citros pode-se concluir: os classificadores obtiveram melhor qualidade de classificação para as áreas maiores com CITROS; a Krigagem Indicativa unificou as áreas pequenas de CITROS em uma única área; a Krigagem Indicativa foi o classificador que menos classificou área de mata ciliar como CITROS, já os demais confundiram consideravelmente mata ciliar com CITROS; pela validação, a Krigagem Indicativa foi o classificador que obteve a menor qualidade de classificação em comparação com o MAXVER e o *CLUSTER* e o maior tempo de processamento; o MAXVER foi o que apresentou área total de CITROS mais próxima da verdade terrestre, enquanto que a Krigagem Indicativa foi o classificador que mais superestimou a área total de CITROS em 27,94 %; a Krigagem Indicativa obteve uma correlação de 66% com a interpretação visual enquanto o MAXVER e o *CLUSTER* obtiveram uma correlação de 76% e 73%, respectivamente.

---

**Palavras-chaves:** Krigagem Indicativa, Satélite CBERS-2B, Classificadores de Imagens.

**GEOSTATISTICS AND REMOTE SENSING IN THE IMAGE CLASSIFICATION IN CITRUS CROP. Botucatu, 2011. 83p. Dissertação (Mestrado em Agronomia/Energia na Agricultura) - Faculdade de Ciências Agronômicas, Universidade Estadual Paulista.**

Author: ALESSANDRA FAGIOLI DA SILVA

Adviser: Ph. D. CÉLIA REGINA LOPES ZIMBACK

Ph. D. PAULO MILTON BARBOSA LANDIM

## **2 SUMMARY**

The citrus industry is important for the Brazilian economy due to record exports and generating direct and indirect jobs. Remote sensing is the primary source of information on land cover as a result of technological advances in sensor systems. The incorporation of geostatistics procedures in environmental studies based on Kriging techniques has been used by professionals in areas of remote sensing. The aim of this study was to compare the accuracy of classification methods in the determination of satellite images of areas cultivated with citrus, Mesoregião in Araraquara, Bauru, and, through methods of remote sensing and geostatistics to discrimination and quantification of the area planted. The study area used in this research is located in the central region of São Paulo, with an area of 56,146.78 ha. It was used the GIS-SPRING for data processing. We used bands 2, 3 and 4 of the digital image from the satellite CBERS 2B, CCD camera (Camera high resolution image) that provides images with a spatial resolution of 20 meters. The image dated of 04/16/2009, the path/row 157/124 and 157/125. In the process of image classification were studied three methods of classification, and unsupervised clustering, the MLC (Maximum Likelihood) and KI (kriging) supervised classification beyond the screen taken as ground truth. The validation of classifications were evaluated by Kappa index. The results obtained of image classification onto discrimination and quantification of citrus areas were: the classifiers had improved quality of classification for wide citrus areas, the Indicative Kriging unified the small citrus areas in a single area, the Indicative Kriging was the classifier that less classified riparian vegetation area such as citrus, the others changed riparian vegetation by citrus. The validation

showed that Indicative Kriging was the classifier which had the lower quality rating than the MLC and CLUSTER and the longest processing time. The MLC showed the total citrus area was the closest to ground truth, while the Indicative Kriging was the classifier that superestimated the total area 27.94% of citrus. The correlation between the Indicative Kriging and visual interpretation was 66% whereas the MLC and CLUSTER obtained a correlation of 76% and 73% respectively.

---

**Keywords:** Indicative kriging, CBERS-2B satellite, Images classifiers.

### **3 INTRODUÇÃO**

A citricultura brasileira é uma das mais eficientes e dinâmicas do mundo, respondendo rapidamente às alterações do ambiente internacional. Poucos países têm condições de competir com o Brasil sem que haja condições artificiais de proteção a seus citricultores devido aos custos de produção agrícola e industrial brasileiros serem de difícil competição. A cultura é de fundamental importância para a economia brasileira devido aos recordes de exportações e pela geração de grande quantidade de empregos diretos e indiretos.

Os problemas do processamento de dados em sensoriamento remoto geralmente envolvem a identificação específica da cobertura da terra, a estimativa de parâmetros biogeofísicos e a extração de feições. Essa variedade de problemas tem aumentado a sua complexidade dependendo dos cenários analisados. Dentre as aplicações mais difundidas do sensoriamento remoto destaca-se o mapeamento da cobertura do solo. Nas últimas décadas, o sensoriamento remoto orbital tornou-se a fonte primária de informações sobre a cobertura do solo em decorrência dos avanços tecnológicos nos sistemas sensores. Estas tecnologias têm permitido a aquisição de informações sobre grandes áreas geográficas em diferentes resoluções espaciais, temporais, espectrais e radiométricas.

No Brasil, a partir da década de 80, vários trabalhos foram desenvolvidos no sentido de avaliar a aplicação de imagens de sensoriamento remoto orbital para estimar a área cultivada. A maior parte dos estudos baseou-se em imagens Landsat,

provavelmente pela maior facilidade de acesso e menor custo que as imagens de outros satélites. Atualmente as imagens da família CBERS têm sido bastante utilizadas nos trabalhos de pesquisa e de planejamento, devido à facilidade de aquisição e por ser de distribuição gratuita.

Devido ao seu caráter multiespectral, o custo da repetição no tempo e espaço é relativamente baixo, em comparação com fotografias aéreas. Imagens de sensoriamento remoto por satélite é um método potencial para obter informações sobre áreas cultivadas com citros.

Os dados de sensores remotos necessitam ser analisado para que sejam extraídas informações necessárias ao planejamento, manejo e monitoramento dos recursos. Nesse sentido, muitas técnicas de classificação foram desenvolvidas, visando, sobretudo, o mapeamento do uso e ocupação do solo de forma automática, através de algoritmos especializados.

A incorporação de procedimentos geoestatísticos em estudos ambientais baseados em técnicas de Krigagem tem sido utilizada por um grande número de profissionais das mais diversas áreas da ciência. E, muito recentemente os profissionais da área de sensoriamento remoto vem aplicando esses procedimentos, principalmente quando se trata de mapeamentos de uso do solo e classificação de imagens digital. Assim, incorporado aos SIGs, deu-se início a uma nova fase nos métodos conceituais de representação cartográfica. Esta incorporação se deve ao fato de que, essa associação melhora os procedimentos tradicionais de tais sistemas devido à qualidade do estimador.

O objetivo deste trabalho foi comparar a precisão de métodos de classificação de imagens orbitais na determinação de áreas cultivadas com citros, na Mesoregião de Bauru e Araraquara, por meio de métodos de sensoriamento remoto e geoestatísticos, para a discriminação e quantificação da área plantada.

## **4 REVISÃO DE LITERATURA**

### **4.1 Citros**

Os citros são originários principalmente das regiões subtropicais e tropicais do sul e sudeste da Ásia, incluindo áreas da Austrália e África (países vizinhos de clima subtropical úmido). Foram levados para a Europa na época das Cruzadas, e introduzidos no Brasil pela Bahia, através das primeiras expedições colonizadoras por volta de 1540. Por encontrar boas condições para vegetar e produzir, a cultura se expandiu por todo o país (MOREIRA; MOREIRA, 1980).

O cultivo da laranjeira está disseminado por mais de 60 países e, os pomares mais produtivos, resultantes de uma citricultura estruturada, estão nas regiões de clima tropical e subtropical, destacando-se o Brasil, Estados Unidos, México, China e África do Sul (ABECITRUS, 2001 citado por ALVES; MELO, 2010).

O Brasil é o maior produtor de citros e lidera o mercado mundial de suco de laranja. A produção de citros ocorre, principalmente, no Estado de São Paulo, com cerca de 80% da produção brasileira de laranjas. Outros estados como Bahia, Minas Gerais, Sergipe, Para, Rio de Janeiro, Paraná e Rio Grande do Sul contribuem para o agronegócio dos citros. O cinturão citrícola paulista é responsável por 53% da produção mundial de suco e 80% do comércio internacional desse produto (ANUÁRIOS, 2010).

As plantas cítricas mais cultivadas são: a laranja, o limão e a tangerina. A produção nacional de laranja em 2009 foi de 18,479 milhões de toneladas e as exportações de fruta *in natura* em 2009, segundo indicativos, finalizaram em 26,185t e US\$ 11,3 milhões, (IBGE, 2010). Contudo, verifica-se no Brasil a carência de ferramentas para um monitoramento constante das áreas cítrica, de forma a favorecer a manutenção desta exploração em níveis internacionalmente competitivos.

O clima exerce grande influência sobre o vigor e longevidade das plantas cítricas. Os citros cultivados em regiões de clima ameno produzem maior quantidade de frutos e com melhor qualidade. A laranjeira, e os outros citros preferem climas com temperatura entre 23 e 32 °C e umidade relativa do ar alta (80%). O ideal anual de chuvas está em 1.200 mm bem distribuídos ao longo do ano (MATTOS JUNIOR et al., 2009).

As plantas cítricas, apesar de terem determinadas exigências em relação aos solos, adaptam-se tanto a solos arenosos como argilosos. Solos profundos e permeáveis, com boa fertilidade (pouco ácidos, pH entre 5 e 6, e com ampla reserva de nutrientes) permitem maior desenvolvimento das árvores e maior produção de frutos. As principais classes de solos, onde predomina a citricultura brasileira, compreendem os Latossolos, os Argissolos e os Neossolos (MATTOS JUNIOR et al., 2009).

O espaçamento utilizado no cultivo de citros no Brasil é de cerca de 6 a 7 m entre linhas por 3 a 5 m na linha (MATTOS JUNIOR et al., 2009).

## **4.2 Geoprocessamento**

A evolução do geoprocessamento, com conseqüente aumento de suas funções, é agente fundamental nos diagnósticos das informações espaciais proporcionando, quando utilizados corretamente, dados com altíssima precisão, confiabilidade e rapidez. As ferramentas do geoprocessamento são de grande aplicabilidade para a espacialização, caracterização e representação dos dados e também para viabilizar a utilização dos mesmos na elaboração de planos de informação com a finalidade de utilização posterior em planejamentos ambientais (PERES, 2006).

O termo geoprocessamento denota a disciplina do conhecimento que utiliza técnicas matemáticas e computacionais para o tratamento da informação geográfica e

que vem influenciando de maneira crescente as áreas de Cartografia, Análise de Recursos Naturais, Transportes, Comunicações, Energia e Planejamento Urbano e Regional. As ferramentas computacionais para geoprocessamento permitem realizar análises complexas, ao integrar dados de diversas fontes e ao criar bancos de dados georreferenciados (CÂMARA et al., 2006).

O geoprocessamento constitui um importante conjunto de tecnologias de apoio ao desenvolvimento da agricultura. Ele permite analisar grandes quantidades de dados georreferenciados, independentemente de serem estatísticos, dinâmicos, atuando de maneira isolada ou em conjunto e, ainda, permite o tratamento destes dados, gerando informações que possibilitam soluções por meio de modelagem e simulações de cenários (BUCENE, 2002).

O Geoprocessamento procura abstrair o mundo real, transferindo ordenadamente as suas informações para o sistema computacional. Esta transferência é feita sobre bases cartográficas, através de um sistema de referência apropriado (DAINESE, 2001).

Segundo Moreira (2004), a ferramenta utilizada para realizar o geoprocessamento compõe um conjunto denominado de Sistema de Informação Geográfica (SIG).

#### **4.2.1 Sistema de Informação Geográfica - SIG**

*“Quase tudo que acontece, acontece em algum lugar. Portanto, saber onde as coisas acontecem é de fundamental importância”* (LONGLEY, 2001). Esta afirmativa manifesta a relevância da análise espacial, numa época, hoje, considerada a era do gerenciamento disciplinado de informações. Para a realização deste tipo de tarefa, foram desenvolvidos os sistemas de informação geográfica (SIG), uma tecnologia capaz de analisar dados espaciais e oferecer alternativas ao entendimento da ocupação e utilização do meio físico. As definições para os SIG são várias, geralmente baseadas no tipo de usuário e no domínio da aplicação. A diversidade de aplicações desta tecnologia permitiu sua inclusão à rotina de várias áreas do conhecimento, o que implica no seu uso pelos mais diversos profissionais, os quais foram incorporando sua própria concepção do sistema, resultando em diversos conceitos (BERNARDES, 2006).

Teixeira et al. (1992) consideraram como informação geográfica o conjunto de dados cujo significado contém associações ou relações de natureza espacial. Esses dados podem ser representados em forma gráfica (pontos, linhas, polígonos), numérica (caracteres numéricos) ou alfanumérica (combinação de letras e números).

Os SIGs têm sido aplicados no gerenciamento em diversas áreas, tais como: urbana, regional, floresta, de infra-estrutura, de utilidade pública, de utilidade privada, além de serem utilizados também no monitoramento agrícola etc. Mesmo com a diversidade de aplicações de um SIG, sua forma de utilização se resume em três funções: 1) ferramenta para produção de mapas; 2) suporte para análise espacial e de fenômenos; 3) banco de dados geográficos com funções de armazenamento e recuperação de informações espaciais (CÂMARA, 1995).

As ferramentas computacionais utilizadas em geoprocessamento, chamadas de Sistemas de Informações Geográficas (SIGs), são programas especializados para aquisição, edição, armazenamento, integração, análise e saída de dados espacialmente distribuídos (BAILEY; GATRELL, 1995). Os SIGs possuem a capacidade de analisar, de forma espacial, uma grande variedade de dados em amplas regiões geográficas, para a extração de novas informações pertinentes à tomada de decisões, permitindo que a ação de cada fator isolado e, em conjunto, seja avaliada rapidamente (CÂMARA; MEDEIROS, 1998).

Um SIG pode ser definido como a ligação técnica e conceitual das ferramentas desenvolvidas pela informática para capturar, armazenar e processar dados e apresentar informações espaciais georreferenciadas. Para a formação de um banco de dados para um SIG, os mesmos são coletados em mapas cartográficos, dados de campo como tipo de solo, precipitação, imagens de satélite, fotografias aéreas, que são armazenados e manipulados segundo a informação que se deseja obter (LOPES; FERREIRA, 2005).

#### 4.2.1.1 Características do sistema

Numa visão abrangente, pode-se dizer que um SIG é composto de cinco componentes independentes, porém interligados uns aos outros por meio de funções específicas. Os componentes do SIG são: interface, entrada e integração de dados, funções de consulta e análise espacial, visualização e plotagem e banco de dados geográficos, como disposto na Figura 1 (MOREIRA, 2004).

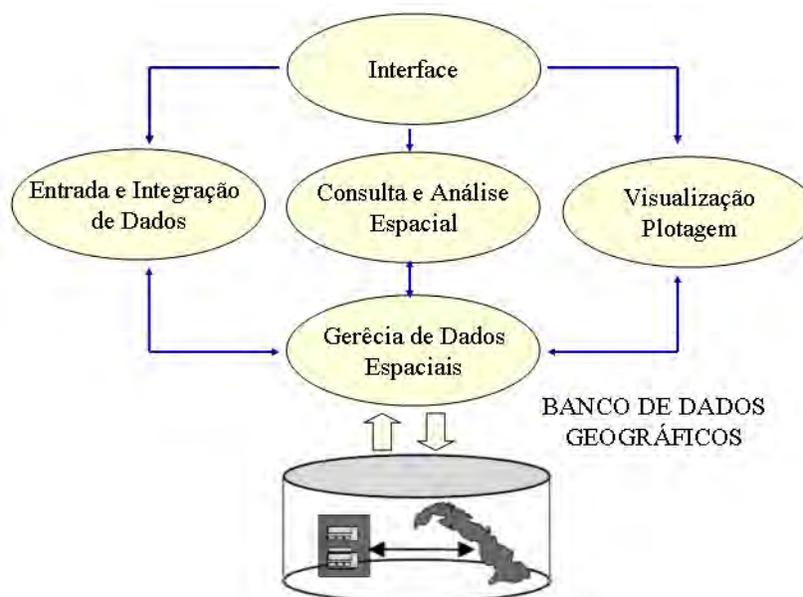


Figura 1. Estrutura de Sistemas de Informação Geográfica.

Fonte: adaptada de Câmara e Medeiros (1996).

Atualmente, existe um grande número de SIGs com características as mais variadas possíveis em termos de tipos de estruturas de dados, modelos de banco de dados, sistemas de análise e outras. Apesar de possuírem habilidades diferentes, existem alguns módulos presentes na maioria destes programas. Estes módulos são: Sistema de Aquisição e Conversão dos Dados; Banco de Dados Geográficos; e Representações de Dados Espaciais (DAINESE, 2001).

O formato de representação digital dos dados é uma característica distintiva do SIG. Basicamente um SIG dispõe de dois tipos de dados da superfície terrestre: as definições topológicas de uma estrutura do terreno e os atributos e qualidades que esta estrutura possui. Essa representação geralmente é feita por dois tipos de formato digital: raster

ou vetor. O SIG-vetor possui uma representação gráfica mais elaborada, permitindo uma visualização mais eficiente das localidades tendo, além disso, uma maior eficiência na utilização conjunta com uma base de dados relacionais (banco de dados). A informação topológica é mais eficiente, permitindo a utilização de redes para acesso e análise a locais específicos. O SIG-raster é um modelo indicado para análises ambientais, pois possui uma estrutura de dados mais simples, permitindo operações de análises diretamente sobre os dados, cuja variabilidade espacial é mais bem representada, uma vez que os fenômenos ambientais não têm limites fixos, considerando-se difusa a transição entre eles. A unidade espacial é representada pelo *pixel*, o qual possui a mesma forma e tamanho, possibilitando uma análise mais eficiente em ambientes contínuos (SILVEIRA, 2004).

O sistema raster tem mais poder analítico que o vetor na análise do espaço contínuo. Sua estrutura assemelha-se à dos computadores digitais e, deste modo, tende a ser muito rápida na resolução de problemas que envolvem várias combinações matemáticas e modelos ambientais. As imagens de satélites usam uma estrutura raster o que torna mais fácil a incorporação desses dados. O sistema vector é eficiente no armazenamento de dados de mapas, armazenando somente os limites e não o que está contido neles. Suas representações gráficas estão diretamente ligadas ao banco de dados de atributos, permitindo o cálculo de distância entre pontos de atributos ou ao longo de linhas, cálculos de áreas de regiões definidas na tela, entre outras operações. Dentro de um SIG é importante que seja possível uma rotina de conversão raster-vector e vice-versa para permitir uma integração dos diferentes tipos de dados (EASTMAN, 1999).

#### **4.2.1.2 Programa - SPRING**

O programa SPRING (Sistema de Procesamento de Informações Georreferenciadas) foi desenvolvido pelo INPE (Instituto Nacional de Pesquisas Espaciais), pela EMBRAPA (Empresa Brasileira de Pesquisas Agropecuárias) e pela IBM (*International Business Machines*) que se iniciou em 1991, e tiveram seu primeiro resultado concreto em 1993, com o lançamento da versão 1.0 do SIG-PRING (CÂMARA et al., 1996a). A evolução do sistema SPRING durante os anos levou ao lançamento de outras versões sendo atualmente a versão 5.1.6

O SIG-SPRING é baseado num modelo de dados orientado a objetos, do qual são derivadas sua interface de menus e a linguagem espacial LEGAL. Algoritmos inovadores, como os utilizados para indexação espacial, segmentação de imagens e geração de grades triangulares, garantem o desempenho adequado para as mais variadas aplicações.

Dentro de um mesmo ambiente o SIG-SPRING é composto por três módulos: o IMPIMA, o SPRING e o SCARTA, conforme é ilustrado na Figura 2. Os módulos IMPIMA e SCARTA são interligados ao módulo central SPRING, porém operam independentemente do SPRING.

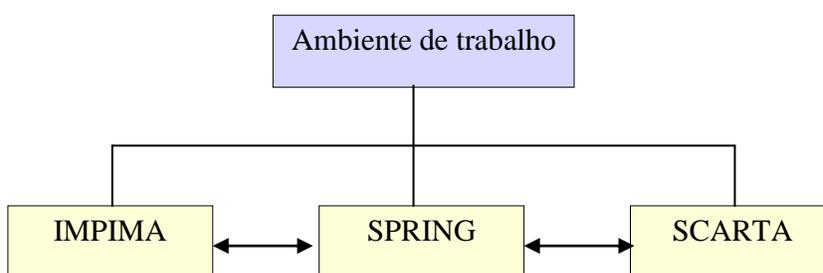


Figura 2. Configuração do ambiente SPRING.

Fonte: Moreira (2000).

O módulo IMPIMA tem a função de ler os dados de satélites no formato digital. No IMPIMA o analista lê e seleciona bandas espectrais e/ou a área de interesse para ser exportada para o banco de dados SPRING.

O SPRING é o módulo principal de entrada, manipulação e transformação de dados geográficos, executando as funções relacionadas à criação, manipulação de consulta ao banco de dados, funções de entrada de dados, processamento digital de imagens, modelagem numérica de terreno e análise geográfica de dados (CÂMARA et al., 1996a).

O módulo SCARTA destina-se a gerar cartas. A interligação do SCARTA ao SPRING é feita pelo gerenciador de banco de dados (SGBD), assim, o SCARTA não tem nenhuma função para processar e alterar os dados. O SCARTA foi projetado como um módulo independente do módulo SPRING para permitir ao usuário optar por exportar seus dados para outros geradores de cartas.

O SIG-SPRING mostrou-se eficiente para a manipulação de dados em diferentes formatos (vetorial e matricial), em uma base georreferenciada, permitindo a conversão das informações vetoriais para o formato matricial (ARAGÃO, 2004).

O SIG-SPRING mostrou-se uma poderosa ferramenta para a elaboração do diagnóstico ambiental (CASTRO, 2008).

Segundo Jim (2006), ao elaborar o diagnóstico físico ambiental do Ribeirão Descalvado em Botucatu, SP através de técnicas de geoprocessamento, concluiu que a aplicação de tais técnicas foi de grande utilidade para o diagnóstico e o SIG-SPRING apresentou-se adequado para a realização do estudo dispondo de todas as ferramentas necessárias para as análises propostas.

#### **4.2.2 Sensoriamento Remoto**

A necessidade do ser humano de ler o seu entorno, coletando cada vez mais informações com maior precisão sobre a relação de suas atividades socioeconômicas com a natureza tem motivado o desenvolvimento contínuo do sensoriamento remoto e de suas ferramentas para mapear e monitorar os recursos naturais (SHIMABUKURO, 1996).

Jensen (2000) definiu o sensoriamento remoto como a arte e a ciência de se obter informações acerca de objetos presentes na superfície terrestre sem contato físico com os mesmos. Um sensor remoto é um sistema capaz de detectar, medir e registrar a Radiação Eletromagnética (REM) refletida, absorvida, transmitida e/ou emitida pelos alvos da superfície terrestre. Imagens de satélite são ferramentas que podem ser utilizados para gerar informações que são obtidas pelo comportamento espectral da vegetação (VIEIRA et al., 2006).

A energia refletida ou emitida por um determinado objeto na superfície é registrada pelos sensores que operam em certas faixas espectrais do espectro eletromagnético, como a região do visível, do infravermelho próximo, médio e distante, etc (DAINESE, 2001).

Os satélites de observação da Terra têm uma grande diversidade de sensores que permitem obter imagens com diferentes características, as quais se adaptam às mais diversas aplicações do sensoriamento remoto. A análise combinada de imagens

adquiridas por diferentes sensores/satélites em aplicativos de processamento de imagens e em SIG é uma alternativa viável para aumentar a frequência de observação dos alvos (MOREIRA et al., 2005).

Estes sensores podem registrar estas informações em condições de campo, aerotransportados ou colocados em plataformas orbitais. Quando colocado em plataformas orbitais, como é o caso do satélite CBERS, os dados coletados apresentam algumas vantagens em relação àqueles coletados no campo ou aerotransportados. Os sensores orbitais permitem realizar um imageamento sinóptico (visão ampla da área imageada) e periódico. Além disso, a energia refletida ou emitida pelo alvo pode ser gravada em diferentes faixas espectrais, permitindo assim, fazer uma análise do comportamento espectral em diferentes bandas do espectro eletromagnético (MOREIRA et al., 2005).

Os sensores remotos são específicos para atender distintas aplicações, que requerem características próprias quanto ao número, posicionamento e largura espectral das bandas. Assim, os sensores ópticos orbitais geralmente possuem três bandas na porção do visível, uma banda na porção do infravermelho próximo e uma ou duas bandas na porção do infravermelho médio do espectro eletromagnético. Alguns sensores remotos possuem ainda uma banda centrada em comprimentos de onda maiores, correspondentes ao infravermelho termal, para medir a radiância emitida pelos alvos da superfície terrestre. Outros sensores possuem uma banda denominada pancromática, cuja faixa espectral é larga e se estende desde o visível ao infravermelho próximo (RIZZI, 2005).

Koffler (1992) destacou que a utilização de sensores orbitais em estudos agroambientais apresenta vantagens, por permitir a análise de grandes áreas em apenas uma imagem da superfície terrestre continuamente e em intervalos regulares, dispensando a realização de levantamentos aerofotogramétricos e permite a obtenção de dados multiespectrais, multitemporais e em diferentes resoluções espaciais.

A utilização do sensoriamento remoto na identificação das formas de uso da terra mostrou-se eficiente, particularmente quanto ao emprego combinado das classificações digitais e do geoprocessamento. As imagens do sensor digital dos satélites possibilitaram a classificação digital do uso da terra de forma rápida, confiável e atual, tendo em vista a deficiência de informações sobre este tema na carta topográfica (BECKER; BRAUN, 1999).

#### 4.2.2.1 Conceitos e características de imagens orbitais

A imagem digital gerada pelos sistemas de sensores é discreta e constituída por um arranjo de elementos (dígito) sobre a forma de malha ou grade regular denominada *pixel*, o qual é atribuído um valor numérico de acordo com a intensidade da REM em níveis de cinza (NC) que variam do preto ao branco, nível mínimo e máximo, respectivamente (BENVENUTI, 2005). O nível de cinza é conhecido por número digital (ND). O ND de um *pixel* representa a intensidade da REM (refletida ou emitida) medida pelo sensor, para a área da superfície da Terra, correspondente ao tamanho do *pixel*.

A imagem de satélite é uma ferramenta que pode ser utilizada para gerar informações, que são obtidas pelo comportamento espectral da cultura. As diferenças espectrais são registradas na imagem na forma de variações tonais, de cores ou de densidade. Os sensores remotos buscam detectar e mostrar as diferenças em tonalidades ou cor entre um objeto e o ambiente em que se encontram (VALÉRIO FILHO, 1996).

Imagens orbitais surgiram como uma boa opção na coleta de dados sobre a superfície terrestre, reduzindo custos e tempo necessários a sua realização. O uso de imagens de satélite representa uma ferramenta de grande utilidade para fins de mapeamento, devido a sua grande abrangência, em termos de área, periodicidade de imageamento em intervalos curtos, possibilidade de análise visual e espectral e baixo custo de aquisição (MACHADO, 2002). Nesse sentido, as técnicas de sensoriamento remoto e processamento digital de imagens constituem uma fonte de geração de dados que podem ser manipulados e analisados em SIGs auxiliados por dados provenientes de outras fontes, proporcionando a obtenção de informações importantes sobre a superfície terrestre na região que se deseja estudar (BERNARDES, 2006).

Do ponto de vista do processamento dos dados digitais, as características importantes são: Resolução espectral, Resolução espacial, Resolução radiométrica e Resolução temporal.

A resolução temporal ideal para o monitoramento agrícola depende principalmente do tipo de estudo que se pretende realizar. Em estudos envolvendo a identificação de culturas agrícolas, a obtenção de uma ou duas imagens em períodos bem definidos dentro do ciclo da cultura se mostra suficiente, embora pesquisas apontem para uma

melhora na identificação de culturas agrícolas utilizando imagens multitemporais (IPPOLITI-RAMILO et al., 2003; OETTER et al., 2000; RIZZI; RUDORFF, 2003).

A época de aquisição das imagens de satélite influencia muito no sucesso ou não do analista em obter resultados sobre os alvos na superfície terrestre. Para saber a melhor data para adquirir uma imagem de satélite é necessário que se façam algumas considerações a respeito da prática agrícola da cultura e das restrições impostas por parte dos dados nas imagens do satélite (MOREIRA, 2004).

Em algumas culturas, principalmente aquelas de ciclo perene ou semiperene, como café, citros e cana-de-açúcar, a época de seleção de imagens de satélite não é um problema sério, porque podem ser utilizadas imagens de épocas com menor índice de precipitação pluviométrica, aumentando, deste modo, a probabilidade de adquirir imagens livres de cobertura de nuvens (MOREIRA, 2004).

#### **4.2.2.2 Processamento de dados digitais**

A idéia de se criar procedimentos computacionais para a análise de dados coletados por sistemas sensores, surgiu basicamente por duas razões: agilizar as tarefas manuais realizadas durante a interpretação visual (delimitação de áreas, confecção de mapas, cálculo de área, etc) e possibilitar que o analista pudesse introduzir outros tipos de informações e cruzá-las com os padrões espectrais, contidos nas imagens, de tal modo a tornar a interpretação mais fácil de ser realizada (MOREIRA, 2000).

O tratamento de imagens digitais é o processo pelo qual o analista obtém informações temáticas dos alvos contidos na área imageada.

As imagens digitais possuem uma grande vantagem em comparação às imagens analógicas, que é a de poderem ser processadas visando o realce ou a extração de informações específicas. Assim sendo, através das imagens digitais, podem ser geradas composições coloridas a partir da utilização de diferentes combinações de bandas espectrais, combinações de imagens de uma mesma banda em diferentes datas, ou imagens de diferentes sensores (NOVO, 2008).

Entende-se por processamento digital de imagens a análise e a manipulação de imagens por computador, cuja finalidade, segundo Mascarenhas e Velasco

(1989), é identificar e extrair informações da imagem, e transformar a imagem de tal modo que a informação seja mais facilmente discernível por um analista humano.

O sucesso na obtenção de resultados através da análise digital também está sujeito aos dois fatores básicos citados por Duarte (1989), ou seja, época de obtenção dos dados e experiência do pesquisador em associar os padrões espectrais de algumas áreas de treinamento para o computador, exceto no caso de classificação não supervisionada, que depende apenas do primeiro fator.

O processamento de dados digitais é basicamente dividido em três etapas: pré-processamento, classificação e pós-processamento (MOREIRA, 2004).

Podemos definir pré-processamento, portanto, como o conjunto de técnicas e métodos que permitem a correção dos erros inerentes ao processo de aquisição dos dados (NOVO, 2008). Esta etapa tem como objetivo melhorar a qualidade da imagem, realçando detalhes importantes e eliminando possíveis defeitos de gravação dos dados, para facilitar a análise do intérprete. As técnicas empregadas visando melhorar a qualidade dos dados são: georreferenciamento, realce e segmentação (MOREIRA, 2004).

Para propósitos de mapeamento é essencial que as imagens de sensoriamento remoto sejam georreferenciadas com exatidão ao mapa proposto como base (EASTMAN, 1998). Isso é necessário para que as informações extraídas das imagens possam ser integradas juntamente com outros dados georreferenciados relativos à área em estudo (RICHARDS; JIA, 1999).

A manipulação de contraste (realce) é um dos processamentos mais simples a que se pode submeter uma imagem. A manipulação de contraste permite que seja alterado o histograma original, de modo a gerar uma nova imagem com o realce dos objetos de interesse (NOVO, 2008).

A segmentação de uma imagem é o processo de particionamento do espaço de atributos espectrais em regiões homogêneas, ou seja, a localização de regiões na imagem que possuem *pixels* com características similares, como forma, textura e parâmetros espectrais (MOREIRA, 2004; SCHOWENGERDT, 1997). A partir da segmentação de uma imagem pode-se iniciar a definição de padrões ou de classes a serem discretizadas. Além disto, a segmentação tem como objetivo evitar a subjetividade do analista, como pode ocorrer nas classificações supervisionadas (MOREIRA, 2004).

O segmentador por crescimento de regiões baseia-se em dois limiares, os quais são introduzidos pelo analista: o de similaridade e o de área. O limiar de similaridade é um parâmetro que indica a diferença máxima de NC que um dado *pixel* da imagem pode assumir em relação ao NC médio da classe em consideração. Em outras palavras, se a diferença do valor do NC do *pixel* for menor ou igual ao valor do limiar, o *pixel* é agrupado a essa região, caso contrário, o *pixel* é agrupado a outra região. Em síntese, pode-se dizer que a similaridade serve como regra de decisão para associar ou não um *pixels* da imagem a uma dada região. O limiar de área é utilizado para limitar o tamanho mínimo da área na imagem que deve ser individualizada (INPE, 2001).

#### 4.2.2.3 Sistema CBERS

As tecnologias de sensoriamento remoto assumem uma importância cada vez maior, dada a sua aplicação em áreas diversas, desde a meteorologia, passando pelo monitoramento ambiental e indo até a geração de subsídios para a construção de políticas públicas de desenvolvimento humano e ambiental. Nesse sentido, dada a importância estratégica do domínio da tecnologia de sensoriamento remoto, o Brasil e a China estabeleceram uma parceria científica e tecnológica em 1988 para o desenvolvimento de satélites, que resultou no programa CBERS (*China-Brazil Earth Resources Satellite*). Essa parceria resultou em 3 satélites, CBERS 1, CBERS 2 e CBERS 2B, que integram o Sistema Brasileiro de Coleta de Dados Ambientais, sendo previsto para os próximos anos o lançamento de mais dois satélites (EPIPHANIO, 2009).

O primeiro satélite da série CBERS foi lançado em 1999, e esteve operacional por 45 meses, até julho de 2003. O CBERS-2 foi lançado em outubro de 2003 e ficou em operação até julho de 2008. O CBERS-2B, fruto de acordo bilateral de 2004, foi lançado em setembro de 2007 e ficou em operação até março de 2010. A decisão de construir o CBERS-2B foi motivada pela possibilidade de ocorrer uma interrupção no fornecimento de dados entre o final das operações do CBERS-2 e o início das operações do CBERS-3, cujo lançamento estava programado para 2010 (EPIPHANIO, 2009).

O sistema CBERS possui um conjunto de sensores ou instrumentos. Cada um desses sensores tem características próprias que os tornam mais adequados a certas

categorias de aplicações. O satélite CBERS-2B possui sistemas ópticos CCD - Câmera Imageadora de Alta Resolução, WFI - Câmera de Amplo Campo de Visada e HRC - Câmera Pancromática de Alta Resolução (CBERS, 2010).

A câmara CCD permite o imageamento instantâneo de uma faixa de 113 km de largura, com uma resolução espacial de 20 m. Ela tem também a capacidade de apontamento de  $\pm 32$  graus, perpendicularmente à órbita, permitindo a obtenção de pares estereoscópicos para áreas selecionadas. Além disso, qualquer fenômeno detectado pelo sensor WFI pode ser focalizado pela Câmera CCD, para estudos mais detalhados, através de seu apontamento num período de três dias. A Tabela 1 descreve as principais características da câmara CCD (NOVO, 2008).

Tabela 1. Características da câmara CCD

Bandas espectrais	0,51-0,73 $\mu\text{m}$ (pan) 0,45-0,52 $\mu\text{m}$ (azul) 0,52-0,59 $\mu\text{m}$ (verde) 0,63-0,69 $\mu\text{m}$ (vermelho) 0,77-0,89 $\mu\text{m}$ (infravermelho próximo)
Resolução espacial	20 x 20 m
Resolução temporal	26 dias

(Fonte: HTTP: /www.cbbers.inpe.br/PT/programas/cbbers1-2\_cameras.htm)

As imagens CBERS apresentam um desempenho similar às imagens Landsat para a estimativa de área de soja, com a metodologia de classificação utilizada na região estudada, resultando em valores cerca de 4,7% superiores. Elas podem ser usadas para este propósito em substituição às imagens Landsat ou para complementar períodos em que estas não podem ser obtidas em função da cobertura de nuvens (WEBER et al., 2005). Além disso, as imagens de satélite CBERS-2 mostraram-se adequadas para a avaliação da ocupação do solo, tendo como vantagem a fácil disponibilidade (JIM, 2006).

#### 4.2.2.4 Interação culturas perenes e imagem de satélite

Em culturas perenes, a reflectância registrada num dado *pixel* resulta não só a partir da planta, mas também de fatores relacionados ao solo, à arquitetura de planta e

geometria do sombreamento. O desenvolvimento destas plantas é geralmente lento e outros fatores, tais como: o uso constante de máquinas agrícolas no solo, o sombreamento dentro e entre as fileiras de plantas e as características sazonais da cultura tornam-se importantes (VIEIRA et al., 2006).

Culturas plantadas em fileiras (Figura 4) representam uma cena complexa consistindo de vegetação e solo exposto, com proporções captadas pelo sensor variando sazonalmente como o crescimento da cultura. Neste caso, a presença de sombras provocadas pelas plantas em fileiras sobre a superfície do solo ou sobre outras fileiras torna-se um fator importante na radiação do dossel (RANSON et al., 1984).

Covre (1989) estudou a relação entre alguns parâmetros culturais de citros (cobertura do terreno por árvores de citros, tipo de solo, orientação das fileiras de plantio, declividade, altura das árvores de citros, substrato e uniformidade do talhão) e a reflectância espectral obtida a partir da transformação dos níveis de cinza da imagem TM/Landsat – 5. O autor explica que o relacionamento não coerente entre porcentagem de cobertura do terreno com árvores de citros e reflectância na banda TM 4 se deve, sobretudo ao aumento de sombras que acompanha o aumento de cobertura do talhão pelas árvores de citros, em função dos espaçamentos empregados e distribuição dos pomares. Segundo o autor, o aumento de sombras anula o efeito do aumento da fitomassa na reflectância para esta banda.



Figura 3. Imagens de cultura de citros com diferentes alturas de tomada de imagens: (a) a 1000 m e (b) a 100 m.

Fonte: CASTRO, 2003.

### 4.3 Classificadores Digitais de Imagens

A classificação digital de imagens consiste no estabelecimento de um processo de decisão, no qual um grupo de *pixels* é definido como pertencente a uma determinada classe (VENTURIERI; SANTOS, 1998). O resultado de uma classificação é uma imagem temática, na qual os *pixels* classificados são representados por símbolos gráficos ou cores, associados a uma classe definida pelo usuário.

Para aplicar a classificação digital, primeiramente, devem ser escolhidas as feições de interesse, seguido da determinação do método "Padrão de Comparação", ou seja, a classificação propriamente dita e, finalmente, a avaliação da exatidão do mapa gerado (MATHER, 1999).

Na interpretação digital, a maioria das técnicas-padrão de classificação disponível apresenta algoritmos de classificação baseados somente no uso da informação espectral, ou seja, na intensidade de cinza ou características tonais, deixando de lado as outras características consideradas na interpretação visual (LOCH; KIRCHNER, 2000).

A classificação automática de imagens multiespectrais visa à categorização de todos os *pixels* da imagem, de acordo com o uso e cobertura da Terra distinguindo as composições de diferentes materiais superficiais. Os valores de nível de cinza de cada *pixel* são agrupados e associados a um tipo de cobertura da superfície terrestre imageada. A distinção entre os padrões de uso da terra é possível graças ao comportamento espectral específico dos objetos ao longo do espectro eletromagnético (BERNARDES, 2006).

Para a classificação utilizam-se programas apropriados, também denominados algoritmos de classificação ou simplesmente classificadores. A categorização (rotulação) dos valores dos níveis de cinza é feita utilizando algoritmos estatísticos (programas computacionais) de reconhecimento de padrões espectrais (MOREIRA, 2004).

Tradicionalmente, a classificação de uma imagem segue os seguintes passos: a) extração das feições - transformar as imagens multiespectrais em uma imagem temática, onde características espectrais ou características espaciais idênticas são agrupadas; b) treinamento - extração de valores, associados ao *pixel*, utilizados na função de discriminação (este processo pode ser automático ou não); c) categorização - consiste em associar cada *pixel* da imagem a uma categoria temática (SCHOWENGERDT, 1997).

Na opinião de Mather (1999), Richads (1986) e Schowengerdt (1997), o princípio do reconhecimento de feições consiste em estabelecer a relação entre o objeto e as características espectrais apresentadas nas imagens. Esses autores agruparam os métodos de classificação digital em função da presença ou não de uma fase de treinamento, no qual o analista interage com o computador. De acordo com esse ponto de vista, os métodos de classificação são agrupados em: classificação supervisionada e não-supervisionada.

### **4.3.1 Classificação Supervisionada**

Os métodos de classificação supervisionada baseiam-se na disponibilidade prévia de amostras representativas, identificadas na imagem, para cada classe de interesse (MATHER, 1999). O algoritmo classificador utiliza, então, a informação estatística referente a essas amostras na classificação dos demais *pixels* da imagem. Em função disso, para que a classificação seja bem sucedida, é fundamental que as amostras de treinamento sejam homogêneas e representativas das classes de interesse. Entre os métodos de classificação supervisionada, destacam-se a do paralelepípedo e a da máxima verossimilhança, ou MAXVER, como sendo os mais utilizados (LILLESAND; KIEFER, 1999), outro classificador que tem sido utilizado é a KI (krigagem indicativa), que é baseada nas técnicas geoestatísticas (ROSSI et al., 1994).

#### **4.3.1.1 Krigagem Indicativa - KI**

##### **4.3.1.1.1 Metodologia geoestatística**

A base da geoestatística vem da teoria das variáveis regionalizadas de Matheron. Segundo esta teoria, a diferença entre os valores do atributo tomados em dois pontos mais próximos no espaço deve ser menor do que a diferença entre os valores tomados em dois pontos mais distantes. Portanto, cada valor carrega consigo uma forte interferência dos valores de sua vizinhança, ilustrando uma continuidade espacial (ISAACS; SRIVASTAVA, 1989).

A presença de dependência espacial requer o uso de um tipo de estatística chamada Geoestatística, a qual surgiu na África do Sul, quando Krige (1951), trabalhando com dados de concentração de ouro, concluiu que não conseguia encontrar sentido nas variâncias, se não levasse em conta a distância entre as amostras. Matheron (1963, 1971), baseado nestas observações, desenvolveu uma teoria, a qual ele chamou de Teoria das Variáveis Regionalizadas que contém os fundamentos da Geoestatística (VIEIRA, 2000).

A análise espacial de dados, utilizando a geoestatística, ganhou impulso em áreas distintas a partir de 1980. Uma justificativa para tal fato é a facilidade computacional que viabilizou alguns cálculos relativamente trabalhosos nesta metodologia (GUIMARÃES, 2001).

Geoestatística teve as suas primeiras aplicações em mineração (BLAIS; CARLIER, 1968; OLEA, 1977) depois em hidrologia, (DELHOMME, 1976), vários estudos em ciência do solo (HAJRASULIHA et al., 1980; VIEIRA et al., 1992) e em estudos de sensoriamento remoto (VAUCLIN et al., 1982; VIEIRA; HATFIELD, 1984).

As técnicas de geoestatística que utilizam a informação espacial na classificação de imagens podem ser divididas em dois grupos distintos. Primeiro, a informação espacial é utilizada para fornecer dados sobre a textura. Está implícito em tais abordagens que a textura varia espacialmente na imagem e, em especial entre as classes de interesse, de modo que os dados sobre a textura podem ser usados para informar a classificação. No segundo grupo, a informação espacial é utilizada para suavizar a imagem classificada. A justificativa para a suavização é que imprecisões que surgem a partir de classificação espectral simples aplicada sobre um *pixel-por-pixel* pode ser reduzido utilizando a dependência espacial entre os *pixels* vizinhos. *Pixels* próximos são susceptíveis de serem semelhantes (em que a resolução espacial é boa em relação à escala de variação) e esta dependência pode ser formalizada, em um modelo de variograma, e utilizada para aumentar a precisão da classificação (ATKINSON; LEWIS, 2000).

No contexto estatístico, a textura pode ser associada aos números digitais (ND) de maneira conceitual como: variabilidade global ou local e, correlação espacial. A primeira componente é frequentemente analisada a nível local através do cálculo da média e variância, no qual a medida de dispersão do ND é considerada por meio de “janelas móveis”. A segunda característica assume que os ND não são distribuídos aleatoriamente em uma imagem e consequentemente, existe uma variabilidade ou dependência espacial associada à estrutura de

cada cobertura do solo. Lark (1996) escreveu que a taxa de variabilidade entre os ND's, podem ser medidas entre um par de *pixels* dependendo de seu relacionamento espacial, o qual pode descrever a textura de cada tipo de cobertura do solo.

O ND é interpretado como uma variável regionalizada, espacialmente caracterizado por aspectos estruturais e aleatórias por meio da função variograma (ATKINSON; CURRAN, 1995; CHICA-OLMO; ABARCA-HERNANDEZ, 1998).

Matheron (1963) definiu Variável Regionalizada como uma função espacial numérica, que varia de um local para outro, com uma continuidade aparente e cuja variação não pode ser representada por uma função matemática simples. Essa continuidade ou dependência espacial pode ser estimada através do variograma.

De acordo com Landim (2006), a análise geoestatística compreende os seguintes passos: levantamento do variograma experimental; ajuste a uma família de modelos de variogramas e validação do modelo a ser utilizado nos procedimentos da Krigagem e por fim, a aplicação da Krigagem, propriamente dita.

O primeiro passo em qualquer estudo espacial é a definição do delineamento experimental, que envolve, entre outros procedimentos, a escolha da técnica de coleta de amostras e também da malha de amostragem. A malha de amostragem pode ser do tipo aleatória quando a distribuição dos pontos de coleta é casual; agregada ou agrupada quando ocorrem grupos (*CLUSTER*) de pontos mais próximos entre si; e regular quando os pontos estão regularmente espaçados (LANDIM et al., 2002).

#### **4.3.1.1.1 Variograma**

O método mais indicado na estimativa da dependência entre amostras é o variograma, quando a amostragem envolve duas direções ( $x_i, y_i$ ) (SILVA, 1988), ou ainda, quando a interpolação entre locais medidos for necessária para a construção de mapas de isolinhas (VIEIRA et al., 1983).

O variograma analisa o grau de dependência espacial entre amostras dentro de um campo experimental, além de definir parâmetros necessários para a estimativa de valores para locais não amostrados, através da técnica de Krigagem (SALVIANO, 1996).

Ele é definido a partir da variância das medidas feitas em amostras espaçadas no campo de determinada distância  $h$ , ou seja, “lag” (WEBSTER, 1985), sendo a soma dos quadrados da diferença entre valores amostrados, separados por uma distância ( $h$ ), divididos por duas vezes o número de pares possíveis e é estimado pela seguinte equação:

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

onde:

$N(h)$  = número de pares de valores medidos  $Z(x_i)$ ,  $Z(x_i+h)$  separados por um vetor  $h$ .

Esta ferramenta pode ser empregada em estudo de sensoriamento remoto (CURRAN, 1988; WOODCOCK, 1988; CURRAN; ATKINSON, 1998). Considerando os NDs de uma imagem digital como uma variável regionalizada, com características como aleatoriedade e correlação espacial.

O uso desta função no processamento de imagem tem sido amplamente aceito porque é considerada uma poderosa ferramenta para a análise da autocorrelação espacial de dados radiométricos e, mais especificamente, da estrutura de variabilidade espacial (RAMSTEIN; RAFFY, 1989). Sua aplicação é baseada na análise variográfica, compreendendo as seguintes etapas clássicas: cálculo, modelagem e interpretação do variograma experimental. Computar a função variograma não apresenta qualquer dificuldade, dada a estrutura matricial de uma imagem de satélite, só que o tempo de processamento pode ser demorado, dependendo do tamanho da imagem (ATKINSON et al., 1994; DUNGAN et al., 1994).

Isaaks e Srivastava (1989) relataram sobre os componentes principais do variograma ilustrado na Figura 4. De acordo com os autores à medida que  $h$  aumenta a variância  $\gamma(h)$  também aumenta até um valor máximo no qual ele se estabiliza. Este valor no qual  $\gamma(h)$  se estabiliza chama-se patamar ( $C_0+C$ ). O valor de efeito pepita ( $C_0$ ) revela a descontinuidade do variograma para distâncias menores do que a menor distância entre as amostras. À distância na qual  $\gamma(h)$  atinge o patamar é chamada de alcance ( $a$ ), que define a distância a partir da qual as amostras são independentes.

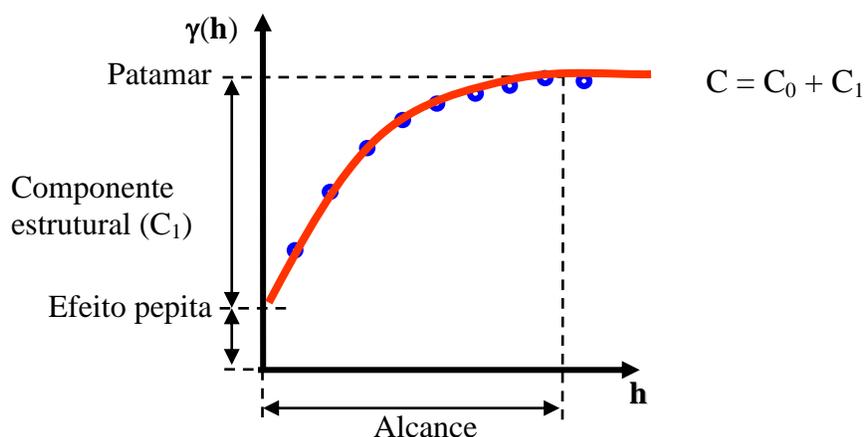


Figura 4. Variograma típico e seus componentes.

Souza (1992) afirmou que amostras separadas por distâncias menores que o alcance ( $a$ ) são espacialmente dependentes, e que o mesmo é também utilizado para definir o raio de ação máximo de interpolação por Krigagem, onde os pesos utilizados na ponderação podem afetar os valores estimados. Segundo Silva (1988), o raio de ação é um dos parâmetros principais no estudo da variabilidade espacial, pois é a distância limite na escolha do tipo de estatística a ser aplicada, ou seja, geoestatística ou a estatística clássica.

O alcance indica a distância em *pixels* em que são correlacionados e, portanto, fornece uma medida do tamanho dos elementos dentro da imagem e, é frequentemente relacionada com o tamanho ou a escala dos elementos maiores e mais dominantes na cena (CURRAN, 1988; JUPP et al., 1989). O patamar é atingido quando a variância dos dados se torna constante com a distância entre as amostras. O valor de  $\gamma(h)$  nesse ponto é aproximadamente igual à variância total dos dados (SILVA, 1988).

O patamar fornece uma medida da variabilidade dos valores de reflectância para o transecto em todo o *stand* (eucalipto) e indica uma defasagem na distância além da qual não há dependência espacial entre os valores de reflectância. O patamar foi associado com a complexidade dos dados de imagem e, portanto, a complexidade da superfície do alvo (ou seja, dossel). Porque o patamar do variograma é dependente da espécie e pode fornecer informações úteis da estrutura da vegetação (TRIETZ; HOWARTH, 2000).

O efeito pepita, que é um parâmetro importante do variograma, reflete o erro analítico, indicando uma variabilidade não explicada (ao acaso) de um ponto para o outro, que pode ser devida tanto a erros de medidas ou microvariação não detectada em função

da distância de amostragem utilizada (CAMBARDELLA et al., 1994; VIEIRA, 1997), sendo impossível quantificar a contribuição individual dos erros de medições ou da variabilidade. Alta porcentagem obtida para o efeito pepita reflete que grande parte da variação encontrada é devida a variações a distâncias menores que à distância amostrada (JOURNEL; HUIJBREGTS, 1978; LAMPARELLI et al., 2001).

De acordo com Trangmar et al. (1985), um efeito pepita de 0% indica que o erro experimental é praticamente nulo e que não existe variação significativa a distâncias menores que a amostrada. Quanto menor a proporção do efeito pepita para o patamar, maior será a semelhança entre os valores vizinhos e a continuidade do fenômeno e menor a variância da estimativa e, portanto, maior a confiança que se pode ter nas estimativas (VIEIRA, 1997; VIEIRA, 1998).

A determinação do variograma é descrita como o primeiro passo no procedimento de estimativa geoestatística. É o passo mais importante porque o modelo escolhido será utilizado através de todo o processo de interpolação e influenciará todos os resultados e conclusões. Nesse estágio, o avaliador deverá decidir se usa ou não a geoestatística para inferências (GUERRA, 1988).

O variograma expressa o comportamento espacial da variável regionalizada ou de seus resíduos e mostra o tamanho da zona de influência em torno de uma amostra, a variação nas diferentes direções do terreno e mostrando também continuidade da característica estudada no terreno (LANDIM, 1998).

Zimback (2001) sugeriu o uso da % da variância estrutural para mensurar a dependência espacial, sendo os seguintes intervalos para avaliar a % da variância estrutural:  $\leq 25\%$  - fraca dependência espacial; entre 25% e 75% - moderada dependência espacial e  $\geq 75\%$  - forte dependência espacial, denominado de IDE (Índice de Dependência Espacial):

$$IDE = \frac{C}{C + C_0} \times 100 \quad (2)$$

O ajuste de um modelo teórico ao variograma experimental é um dos aspectos mais importantes das aplicações da teoria das variáveis regionalizadas e pode ser uma das maiores fontes de ambiguidade e polêmica nestas aplicações. Todos os cálculos de

geoestatística dependem do valor do modelo do variograma para cada distância especificada (VIEIRA et al., 1981). Por isto, se o modelo ajustado estiver errado, todos os cálculos seguintes também o estarão. Como regra, quanto mais simples puder ser o modelo ajustado, melhor, e não se deve dar importância excessiva a pequenas flutuações que podem ser artifícios referentes a um pequeno número de dados (VIEIRA, 2000).

Para os modelos teóricos são encontradas, basicamente, quatro funções teóricas que se ajustam aos modelos de variograma: a) linear; b) esférico; c) exponencial; d) gaussiano (VIEIRA et al., 1983; STURARO, 1988).

#### **4.3.1.1.1.2 Krigagem**

O termo Krigagem é derivado do nome Daniel G. Krige, que foi o pioneiro a introduzir o uso de médias móveis para evitar a superestimação sistemática de reservas de mineração (DELFINER; DELHOMME, 1975). Inicialmente, o método de Krigagem foi desenvolvido para solucionar problemas de mapeamentos geológicos, mas seu uso expandiu-se com sucesso no mapeamento de solos (BURGESS; WEBSTER, 1980), mapeamento hidrológico (KITANIDIS; VOMVORIS, 1983), mapeamento atmosférico (LAJAUNIE, 1984) e outros campos correlatos.

A Krigagem é o método de interpolação da geoestatística, o qual usa a dependência espacial expressa no variograma entre amostras vizinhas para estimar valores em qualquer posição dentro do campo, sem tendência e com variância mínima. Estas duas características fazem da Krigagem um interpolador ótimo (BURGESS; WEBSTER, 1980).

Na maioria das vezes, o interesse da análise geoestatística não se limita à obtenção de um modelo de dependência espacial, desejando também prever valores em pontos não amostrados, obtendo uma malha de pontos interpolados que permitam visualizar o comportamento da variável na região através de um mapa de isolinhas ou de superfície (SILVA JUNIOR, 2001).

A Krigagem leva em consideração o número de amostras utilizadas, as posições das amostras na área a ser avaliada, as distâncias entre as amostras e a zona a ser estimada e a continuidade espacial da variável em estudo.

Segundo Oliver e Webster (1990), a Krigagem linear engloba um conjunto de métodos de estimação: Krigagem Simples, Krigagem Ordinária, Krigagem Universal, Cokrigagem, Krigagem Disjuntiva, etc. Existem também krigagem não linear, das quais se destaca a Krigagem indicativa (KI).

#### 4.3.1.1.1.2.1 Krigagem Ordinária

A Krigagem Ordinária é uma técnica de estimativa linear para uma variável regionalizada que satisfaz a hipótese intrínseca. Em contraste com a Krigagem Simples que, sob hipótese da estacionaridade de segunda ordem, exige que a média seja conhecida, neste caso a média é desconhecida. Na Krigagem Ordinária é assumida a hipótese de quase estacionaridade, também conhecida como estacionaridade regional.

O modelo de dependência espacial fornece os parâmetros necessários para estimar os valores de variáveis em locais não amostrados (GOOVAERTS, 1997).

A Krigagem Ordinária utiliza um estimador linear não-viciado com mínima variância (*BLUE-Best Linear Unbiased Estimator*) para interpolação do atributo medido em posições não-amostradas (ISAAKS; SRIVASTAVA, 1989). Linear significa que as estimativas são feitas por combinações lineares; *Unbiased* (sem viés) determina que o erro de estimativa esperado é nulo; e *best* porque seu objetivo é minimizar a variância destes erros de estimativa (INOUE et al., 1999).

A Krigagem Ordinária, que é a variação mais utilizada da Krigagem Simples, descrita por Tranngmar et al. (1985), em que o valor interpolado de uma variável regionalizada  $Z(x_0)$ , num local  $x_0$ , pode ser determinada por:

$$\hat{Z}_{(x_0)} = \sum_{i=1}^n [\lambda_i \times Z_{(x_i)}] \quad (3)$$

onde:

$n$  = número de pontos;

$\hat{Z}(x_0)$  = valor estimado para local  $x_0$  não amostrado;

$Z(x_i)$  = valor obtido por amostragem no campo; e

$\lambda_i$  = peso associado ao valor medido na posição  $x_i$ .

A construção do estimador  $\hat{Z}$ , na Krigagem Ordinária, não requer o conhecimento inicial da média estacionária da amostragem (LANDIM, 1998), mas requer que a soma dos pesos seja igual a 1 (UZUMAKI, 1994).

De acordo com Uzunaki (1994), o sistema de Krigagem Ordinária tem solução única se o modelo de variograma for válido. A Krigagem, além de ser um estimador não tendencioso, é um interpolador exato, isto é, se o ponto a ser estimado coincidir com um dos pontos amostrados, o valor estimado deverá ser igual ao valor amostrado.

No método da Krigagem, os pesos são variáveis de acordo com a variabilidade espacial expressa no variograma. O que torna a Krigagem um interpolador ótimo é a maneira como os pesos são distribuídos (VIEIRA, 2000). Pontos próximos da posição a ser interpolada levam maiores pesos que os mais distantes, e ainda, as distâncias consideradas não são somente entre o ponto a ser predito e os vizinhos, mas também entre os vizinhos (SILVA JUNIOR, 2001). Com isso podemos enfatizar que, para uma mesma distância, dados agrupados, terão menores pesos, quando comparados individualmente com pontos isolados, pois estes dados trazem informações quase redundantes de uma mesma região.

A minimização da variância de estimação, respeitada a condição de não-enviesamento, é um problema que exige, para a sua solução, a utilização da técnica de Multiplicadores de Lagrange. Considerações teóricas mostram que os pesos ótimos são encontrados pela solução de um conjunto de equações lineares, cujos coeficientes são função do variograma e da localização das amostras em relação ao bloco a ser estimado (ANDRIOTTI, 2005).

Os pesos utilizados na Krigagem são calculados pela equação:

$$\lambda = A^{-1} \times b \quad (4)$$

onde:

- $[A]^{-1}$  é a matriz inversa de variância entre as localidades da vizinhança de um ponto, determinada pelo modelo de variograma com base nas distâncias euclidianas entre os locais;

- $b$  é a matriz de variância entre as localidades vizinhas (com a variável estimada) e o ponto para o qual a variável será interpolada, também determinado pelo modelo de variograma, com base nas distâncias entre as localidades vizinhas e o ponto a ser interpolado;
- $[\lambda]$  a matriz de pesos de Krigagem.

É indicado que se adotem como vizinhança de Krigagem (raio dentro do qual serão tomados pontos para utilizar na avaliação de um determinado painel), distâncias menores ou iguais ao alcance obtido por meio da variografia; se a quantidade de dados for suficiente, pode-se ampliar esse raio, mas considerando um sistema de Krigagem não-estacionário (ANDRIOTTI, 2005).

#### 4.3.1.1.1.2.2 Krigagem Indicativa - KI

A modelagem da incerteza de atributos espaciais pode ser feita por KI que constitui uma forma de Krigagem não-paramétrica, na qual a distribuição de probabilidade associada ao atributo é estimada experimentalmente, sem uma suposição de normalidade da distribuição (GOOVAERTS, 1997). O procedimento de modelagem por KI tem vantagens sobre a modelagem estocástica linear (ou krigagem tradicional): (a) a modelagem é não-paramétrica; (b) a modelagem da incerteza é independente de um estimador; (c) é possível modelar dados de natureza categórica, além de dados de natureza numérica (FELGUEIRAS, 1999). Ela tem a vantagem de não sofrer efeitos de valores discrepantes (*outliers*) e, segundo Smith et al. (1993), é útil para conjuntos de dados assimétricos (MOTOMIYA, et al., 2006). Essa técnica também possibilita a modelagem de dados com grande variabilidade espacial.

A KI consiste basicamente na aplicação da Krigagem Ordinária para a variável transformada, ou seja, a variável resultante da aplicação da função não linear  $f(z) = 0$  ou 1. O conceito inicial foi apresentado por Journel (1983) como uma proposta para construir uma função de distribuição de probabilidades acumuladas para a estimativa de distribuições espaciais. O conceito da transformação indicativa é dos mais simples e amigável, visto que os variogramas indicativos são os mais fáceis de modelar (LANDIM; STURARO, 2002).

No processo básico da Krigagem, a estimativa é feita para determinar um valor médio em um local não amostrado. Pode-se, porém, também fazer estimativas

baseadas em valores que se situam abaixo ou acima de um determinado nível de corte (LANDIM; STURARO, 2002).

O método é baseado em uma transformação binária dos dados, sendo cada dado transformado em um indicador antes de ser submetido às análises geoestatísticas e a Krigagem. Por convenção, os dados são codificados em 0 ou 1, se estiverem acima ou abaixo de determinado valor de corte, respectivamente. O valor de corte é arbitrário e depende do objetivo do estudo. O resultado da transformação é um novo conjunto de dados, composto de 0 e 1, o qual é então submetido às análises geoestatísticas, obtendo-se, assim, o variograma indicativo, que reflete o modelo de continuidade espacial para o valor de corte preestabelecido (MOTOMIYA et al., 2006).

A melhor variografia é obtida para o valor de corte igual ao valor da mediana obtido a partir do conjunto amostral (ISAAKS; SRIVASTAVA, 1989). Assim, é possível usar um único valor de corte, igual ou muito próximo do valor da mediana das amostras, para se gerar uma codificação por indicação única, conhecida como codificação por indicação pela mediana. O uso de um único valor de corte é vantajoso no sentido de eficiência computacional, mas apresenta restrições quanto ao seu uso quando o modelo de variografia, próximo à mediana, é muito diferente dos obtidos para outros valores de corte (ISAAKS; SRIVASTAVA, 1989).

O variograma indicativo, calculado a partir do conjunto dos dados transformados, pode ser usado para estimar valores, pela Krigagem, em outros locais não amostrados, porém dentro da área onde ele foi ajustado, os quais terão valores entre 0 e 1. Estes números correspondem à probabilidade de que os valores estimados estejam acima ou abaixo de determinado valor de corte, isto é, o valor esperado em um local não amostrado é equivalente à distribuição cumulativa da variável em estudo (MOTOMIYA, et al., 2006).

Efetuando-se a krigagem ordinária pontual nos valores transformados, obtém-se a probabilidade de  $v_i < v_c$ . À medida que se incrementa  $v_c$ , obter-se-á valores estimados da função de distribuição de probabilidades acumuladas, assim expresso (LANDIM; STURARO, 2002):

$$F\left(v \frac{v_c}{n}\right) = E\left[\frac{i(v, v_c)}{n}\right] \quad (5)$$

com  $(v_i; v_c) = 1$ , se  $v_i \leq v_c$ .

Definidas as funções da distribuição acumulada, pode-se, portanto, obter qualquer intervalo probabilístico da variável, ou seja:

$$F(v_j) = F(v_i) \quad (6)$$

onde:  $v_j > v_i$ .

Por fim, de posse dessas proporções para os vários níveis, estabelece-se à função de distribuição acumulada condicionada para os diversos locais de ocorrência da variável sob análise.

Para Verhagen e Bouma (1997), a KI tem sido usada com sucesso porque permite expressar o modelo espacial em termos de probabilidade de excesso. Em vez de apresentar os resultados de interpolações em termos de classes de valores fixos, pode-se apresentá-los em termos de probabilidade de que determinado valor seja excedido.

#### 4.3.1.1.1.3 Validação da Krigagem

No ajuste de variogramas experimentais, sempre existe certo grau de incerteza sobre as hipóteses de estacionaridade assumidas, modelos selecionados, parâmetros ajustados e qualidade da Krigagem. Esta incerteza representa o erro da estimativa que pode ser avaliado pelo procedimento denominado de validação cruzada (VIEIRA et al., 1981; CRESSIE, 1991).

O processo de validação cruzada, de acordo com Myers (1997), é bastante simples: remove-se um dado do conjunto de dados amostrais e, usando-se um estimador e função ponderada relacionada com a distância, estima-se o valor retirado, utilizando-se as amostras remanescentes. Têm-se, agora, dois valores para o mesmo ponto, o real e o estimado. O erro da estimação pode ser calculado pela diferença entre o valor real e o estimado, sendo repetido para cada local amostrado.

Se a validação cruzada apresentar os resultados sobre uma reta de regressão próxima da bissetriz e com pequena dispersão dos pontos em torno dessa reta, pode-se estar confiante de uma boa estimativa. Plotam-se, nessa reta, os valores dos dados disponíveis confrontados com os valores dos dados estimados, ou seja,  $Z_i$  e  $Z^*_i$ . A validação cruzada pode ser utilizada também para avaliar se o modelo de variograma escolhido está bem ajustado aos dados disponíveis, pois um ajuste pobre pode significar a presença de viés (ANDRIOTTI, 2005).

Um fator que afeta o cálculo de precisão do método de interpolação é o número de amostragens vizinhas usadas para a estimativa (GOOVAERTS, 1997). O raio de pesquisa onde serão avaliadas as amostras, também, é muito importante para uma boa estimativa e, conseqüentemente, uma boa validação, como o definido por Kane et al. (1982).

#### **4.3.1.2 Máxima Verossimilhança - MAXVER**

O MAXVER (Máxima Verossimilhança) é um classificador estatístico que utiliza os valores dos níveis de cinza de cada classe previamente definidas a partir das amostras de treinamento, avaliando a probabilidade que cada *pixel* da imagem tem de pertencer a cada uma das classes identificadas e o designa àquela cuja probabilidade é maior (DUTRA et al., 1981). É a técnica de classificação supervisionada mais popular para tratamento de dados satélites.

A fase de treinamento consiste em fornecer ao sistema um conjunto de *pixels*, representativos de cada alvo de ocupação do solo, na imagem a ser classificada. Esse conjunto de *pixels* é adquirido através de um cursor de área (MOREIRA, 2004).

A partir deste pacote de treinamento, o classificador define o diagrama de dispersão das classes em torno de uma média e suas distribuições de probabilidades, considerando a distribuição normal (MOREIRA, 2004).

A eficácia do MAXVER depende, principalmente, de uma precisão razoável da estimativa do vetor médio e da matriz de covariância de toda classe espectral. Isso depende da quantidade de *pixels* incluídos nas amostras de treinamento. O resultado do MAXVER é tanto melhor quanto maior o número de *pixels* numa amostra de treinamento para implementá-los na matriz de covariância (PREVIDELLI, 2004).

### 4.3.2 Classificação Não Supervisionada

Na classificação não-supervisionada os *pixels* de uma imagem são colocados em classes sem que o usuário tenha conhecimento prévio de sua existência. Este procedimento permite que o analista conheça a distribuição de *pixels* por classes espectrais. Estas distribuições são analisadas e comparadas com informações de campo ou mapas ou dados teóricos sobre o comportamento espectral de alvos. A classe do terreno à qual pertence cada *pixel* é, portanto, determinada *a posteriori* (NOVO, 2008).

#### 4.3.2.1 CLUSTER

Análise de agrupamentos é um termo usado para descrever diversas técnicas numéricas cujo propósito fundamental é classificar os valores de uma matriz de dados sob estudo em grupos discretos. A técnica classificatória da análise de agrupamentos pode ser utilizada quando se deseja explorar as similaridades entre indivíduos ou entre variáveis definindo-os em grupos (LANDIM, 2002).

Agrupar objetos consiste em reconhecer entre eles um grau de similaridade suficiente para reuni-los num mesmo conjunto. A escolha do método de agrupamento é tão crítica quanto à escolha do coeficiente de associação (VALENTIN, 2000).

Na classificação não-supervisionada os algoritmos baseiam-se na análise de agrupamentos (*CLUSTERS*) para identificar *pixels* com características espectrais similares e agrupá-los em uma mesma classe temática. Os limiares destes agrupamentos são estabelecidos pelo analista e servem como critério para o algoritmo (classificador) definir quais concentrações de *pixels* devem ser tratadas como agrupamentos distintos. Entre os algoritmos que utilizam este método, pode-se citar: o *pixel a pixel*, o por regiões, o K-médias, e o ISOSEG (MATHER, 1999; MOREIRA, 2004; SCHOWENGERDT, 1997).

Um classificador não-supervisionado muito utilizado no SPRING é o classificador ISOSEG, que não requer nenhum parâmetro inicial para começar o agrupamento dos *pixels* em regiões homogêneas. A princípio, ele aceita todos os *pixels* da cena como

pertencentes a uma única classe. Posteriormente, começa a dividir a cena em diferentes classes, segundo as diferenças espectrais observadas nos *pixels* (MOREIRA, 2004).

O ISOSEG, inicialmente particiona a imagem em regiões com diferentes atributos estatísticos (média, matriz de covariância e área) e em seguida realiza a classificação de regiões, embasado na teoria de agrupamentos (*clustering*). Esse classificador utiliza a matriz de covariância e o vetor de média dos níveis de cinza (NC) para estimar o valor central de NC de cada classe (INPE, 2001).

A classificação não supervisionada é a opção mais adequada quando a área investigada é desconhecida, ou quando suas características não estão bem definidas (JENSEN, 1996; LILLESAND; KIEFER, 1994).

### 4.3.3 Validação das classificações

Após o processo de classificação, torna-se necessária à avaliação da exatidão da classificação, ou seja, é necessário determinar quão bom é o resultado da classificação em relação à realidade. O método de avaliação da exatidão de classificação depende da disponibilidade de dados de campo (NOVO, 2008).

A confiabilidade de qualquer mapa (uso da terra, por exemplo) está diretamente vinculada a sua exatidão, a qual indica a proximidade de uma observação ou medida de seu valor real. Nesse sentido, realizada a classificação de imagens digitais, necessita-se de algum procedimento estatístico que defina a acurácia desta classificação, seja ela automatizada ou visual (BERNARDES, 2006). Para Machado (2002), precisão não pode ser confundida com acurácia. Acurácia é um conceito estatístico que expressa estados de semelhança ou probabilidade que um grupo particular de medidas tem com a realidade. No caso de um mapeamento, a acurácia avalia o posicionamento da distribuição espacial de uma classe em relação à realidade no campo. Medidas de precisão são descritas por índices, como desvio padrão e erro padrão das médias estimadas para amostragem, ou seja, quanto da área de uma classe reflete os valores verdadeiros de área no campo. Portanto, a precisão de um mapeamento pode ser alta, mas podem existir classes mapeadas erroneamente, devido a semelhanças no comportamento espectral da cobertura em questão com outra, resultando em baixa exatidão. Nesse sentido buscou-se uma medida de quão próximos os valores obtidos por

estas estimativas estão daqueles considerados verdadeiros (BERNARDES, 2006). Os métodos mais simples expressam a exatidão da classificação através da razão entre a área total de cada classe obtida na imagem e a área total da classe determinada em campo ou em fotografias aéreas, sem levar em conta a localização das classes (NOVO, 2008).

Atualmente, as técnicas usadas na exatidão do mapeamento têm como ponto de partida a construção de matrizes de erro ou de contingência. Uma matriz de contingência constitui uma maneira eficaz de representar a acurácia de um conjunto de dados simulados ou estimada em relação a um conjunto de dados de referência, proporcionando um índice global de acerto (BERNARDES, 2006).

O procedimento mais adotado na medição da exatidão das classificações por meio de matrizes de erro é o índice Kappa (CONGALTON; MEAD, 1983; MACHADO, 2002). Esta medida de acurácia ou, mais apropriadamente, exatidão está baseada na diferença entre a concordância real na matriz (concordância entre os dados simulados e os dados de referência, indicada na diagonal principal) e a concordância por chance, indicada pelo total das linhas e das colunas (marginais).

Kappa ( $k$ ) é uma estatística amplamente utilizada para estimar a acurácia da previsão de uma variável categórica. A estatística  $k$  é uma técnica multivariada discreta para determinar estatisticamente se uma matriz de erro é significativamente diferente do outro (ZHAN et al., 2002).

A análise Kappa foi originalmente adotada em ciências sociais e, após sua inserção em estudos de sensoriamento remoto, vários trabalhos têm sido publicados com a sua utilização, tornando-se componente padrão em avaliações de acurácia (CONGALTON; MEAD, 1983; CONGALTON, 1991). Sanches et al. (2008) e Dainese (2001), em seus trabalhos utilizaram o índice Kappa para realizar a validação dos classificadores, tendo como referência a verdade terrestre.

O meio mais comum de expressar a precisão de mapas ou classificações automáticas, conforme Story e Congalton (1986), é obter a porcentagem da área corretamente classificada, quando comparada com dados de referência (“verdade terrestre”).

#### 4.3.4 Aplicações

Rossi et al. (1994) demonstraram a utilidade e precisão de Krigagem para interpolar os valores de *pixels* em falta. Em seu estudo, a KI foi utilizada para interpolar os *pixels* que foram obscurecidos por nuvens e sombras de nuvens na Terra, classificados na imagem do Landsat TM de uma região ao longo da planície costeira do sul de Chiapas, México. Assumindo um nível de probabilidade de corte de 50%, o erro foi mostrado para ser 17%, sem viés espacial óbvio, mas com alguma tendência para categorizar como não pastagem e como pastagem.

Lacaze (1994) estudou a possibilidade de identificação de padrão espacial em escala regional analisando dados de sensoriamento remoto aplicando análise variográfica em diferentes direções em dados do Landsat TM 5.

Van der Meer (1996, 1999) utilizou KI aplicada a dados multivariados para obter uma classificação para todos os *pixels* de uma imagem de sensoriamento remoto. A abordagem envolveu a definição de variáveis indicadoras para cada característica (banda de frequências), em uma imagem e obtenção de variogramas para cada indicador. Esses variogramas foram então utilizados na KI por bloco para estimar o valor médio de cada indicador para um bloco ou área de *pixels* centrada no *pixel* a ser classificado. Isso equivale à suavização do classificador tradicional. No entanto, a mais importante informação espacial (função de ponderação) incorporada à classificação, através do variograma, é a forma como a variação espacial da variável ocorre.

Lark (1996), após estudo de números digitais de imagens escaneadas, considerou a aplicação do variograma como uma poderosa ferramenta de análise em textura de imagens.

Atkinson e Lewis (2000) rerepresentaram estudo de classificação textural de imagens de sensoriamento remoto *pixel-a-pixel* empregando métodos geoestatísticos com função variográfica.

Chica-Olmo e Abarca-Hernández (2000) apresentaram trabalho aplicando métodos geoestatísticos para classificação de textura na discriminação de feições litológicas na classificação de imagem de satélite do Landsat TM 5 na área da Cordilheira de Betic, sul da Espanha.

Berberoglu et al. (2000) realizaram na costa sudeste da Turquia, na região conhecida como Delta de Cukurova, o mapeamento das áreas de risco a deslizamentos com o uso de imagem de satélite do Landsat TM 5 e o emprego de métodos geoestatísticos.

Wallace et al. (2000) aplicaram técnicas geoestatísticas para avaliar as características e distribuição espacial das comunidades de vegetação no Deserto de Mojave, Califórnia, USA.

## **5 MATERIAL E MÉTODOS**

### **5.1 Descrição da Área de Estudo**

A área de estudo utilizada nesta pesquisa está localizada na região central do Estado de São Paulo, com 56146,78 ha, abrangendo parte dos municípios de Bariri, Itaju, Bocaína, Boa Esperança do Sul, Gavião Peixoto, Nova Europa, Ibitinga e Tabatinga. Situa-se entre as coordenadas geográficas 22° 2' 56" e 21° 50' 9" de latitude Sul e 48° 48' 32" e 48° 31' 3" de longitude Oeste de Greenwich (Figura 5), com altitude variando de 447 a 580 metros. Os municípios são banhados pelos rios Tietê e Jacaré Pepira, Rio Boa Esperança, Rio Jacaré-Guaçu, Rio São Lourenço e cortado por diversos córregos e ribeirões.

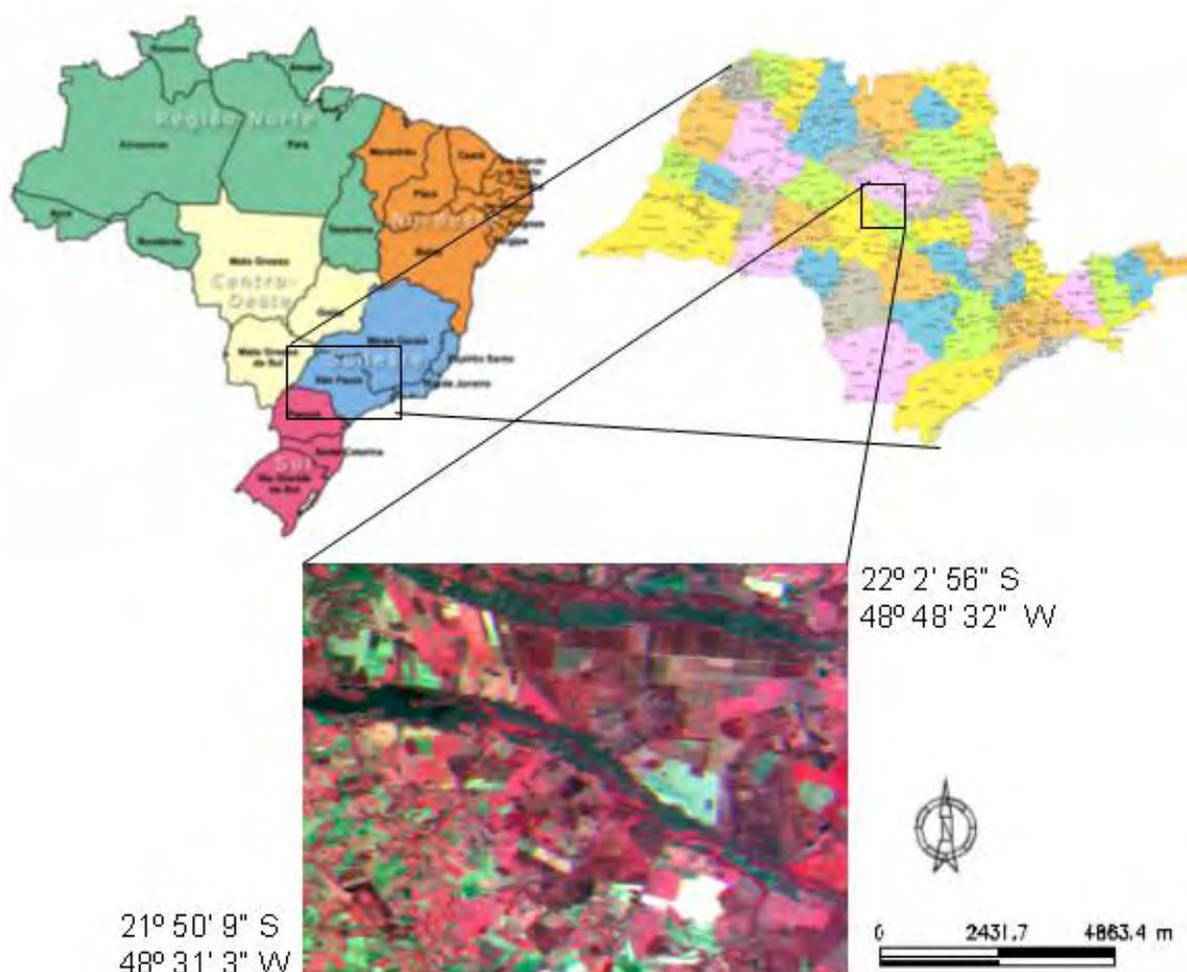


Figura 5. Localização da área de estudo.

A área foi escolhida por sua grande importância citrícola, contendo os municípios com maior área plantada com citros na Mesoregião de Bauru e Araraquara. Nessa região encontram-se as principais fazendas e indústrias de suco concentrado de laranja do Brasil.

O solo predominante na região foi classificado como Latossolo Vermelho (EMBRAPA, 2006) e as litologias, segundo o IPT (1981), são representadas por materiais de alterações de rochas areníticas do Grupo Bauru e dos basaltos da formação Serra Geral do Grupo São Bento.

O relevo é do tipo suavemente ondulado (BRASIL, 1960) e o clima predominante na região é o tropical e subtropical Cwa, segundo a classificação de Köppen, clima temperado quente, com estações de verão e inverno bem definidas, temperatura média

do ar dos 3 meses mais frios compreendidas entre  $-3^{\circ}\text{C}$  e  $18^{\circ}\text{C}$ . A precipitação média anual esta entre 1.100 e 1.700mm, ocorrendo uma precipitação média no mês mais seco de no máximo 30 mm.

## **5.2 Material**

### **5.2.1 Equipamentos**

Os processos empregados no tratamento das imagens digitais, bem como a criação do banco de dados foram realizados por um microcomputador com processador AMD Athlon (TM) XP 1900+ 1.60 GHz; 512 MB de memória RAM; HD de 80 GB.

### **5.2.2 Software SPRING**

O Sistema de Informações Geográficas (SIG) utilizado foi o SPRING (Sistema de Processamento de Informações Georreferenciadas), na versão 5.1.6., desenvolvidos no INPE – Instituto Nacional de Pesquisas Espaciais em conjunto com a EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária.

A metodologia para utilização do SPRING foi: manipulação e transformação de dados geográficos, executando as funções relacionadas à criação, manipulação de consulta ao banco de dados, funções de entrada de dados, processamento digital de imagens, modelagem numérica de terreno e análise geográfica de dados (CÂMARA et al., 1996b).

Este programa foi utilizado para a criação do banco de dados e processamento das imagens, por apresentar todas as ferramentas necessárias para as análises propostas e também por estar disponível gratuitamente no endereço [www.dpi.inpe.br/spring](http://www.dpi.inpe.br/spring).

### **5.2.3 Base de dados**

#### **5.2.3.1 Imagens de Satélite**

Foram utilizadas imagens no formato digital provenientes do satélite CBERS 2B, câmera CCD (Câmera Imageadora de Alta Resolução), provenientes do DGI-INPE (Divisão de Geração de Imagens do Instituto Nacional de Pesquisas Espaciais).

Foram utilizadas as bandas 2, 3 e 4 correspondentes ao azul, verde e vermelho, respectivamente.

Na escolha da imagem de satélite usou-se os critérios de cobertura de nuvens e visibilidade do local de estudo. Assim sendo, buscou-se uma imagem proveniente de um período seco em 16/04/2009, nas órbitas/ponto 157/124 e 157/125 do satélite CBERS 2B.

### **5.3 Metodologia**

No processo de classificação das imagens foram estudados três métodos de classificação, sendo um não-supervisionado e dois supervisionados, além da classificação em tela tida como verdade terrestre.

#### **5.3.1 Criação do Banco de Dados Geográficos**

Para a entrada dos dados no SIG-SPRING, inicialmente, foi necessário criar o Banco de Dados e definir seu Modelo de Dados. Para efetuar qualquer operação, um Banco de Dados deve estar ativo e as categorias dos dados que foram manipulados deverão ser declaradas.

Um banco de dados georreferenciado abrangendo os limites geodésicos da área de estudo foi criado, onde foram armazenados todos os dados referentes ao projeto.

Um banco de dados no SIG-SPRING corresponde fisicamente a um diretório onde foram armazenados suas definições de categorias e classes, e os projetos pertencentes ao banco. Os projetos foram armazenados em subdiretórios juntamente com seus

arquivos de dados: pontos, linhas, imagens orbitais e aéreas, imagens temáticas, textos, grades e objetos.

No SIG-SPRING foram realizadas as etapas que envolveram tratamento de imagens e geoprocessamento, dentre as quais se destacam: classificação das imagens de satélites, segmentação, consultas e cálculo da área mapeada.

### **5.3.2 Processamento Digital das Imagens**

O tratamento de imagens digitais é o processo pelo qual o analista obtém informações temáticas dos alvos contidos na área imageada. Esse procedimento é basicamente dividido em três etapas: pré-processamento, classificação e pós-processamento.

#### **5.3.2.1 Pré Processamento**

No pré-processamento, foram realizados a importação das imagens, o georreferenciamento, realce de imagens, mosaico da imagem e a segmentação de imagens.

##### **5.3.2.1.1 Importação e Transformação de Imagens pelo o SIG-SPRING**

As imagens CBERS-2B utilizadas na estimativa da área cultivada com citros foram inseridas no banco de dados pelo módulo de importação do SPRING.

A imagem no formato TIFF, para que seja importada pelo SIG-SPRING, deve ser transformada para o formato GRIB (Gridded Binary). O programa tem um módulo separado para fazer esta transformação, que é o módulo IMPIMA. Após a transformação do formato da imagem, a mesma foi salva em um banco de dados automaticamente com a extensão \*.grb. Assim, este arquivo imagem pronto foi registrado e incluído em um projeto, para realizar tratamento.

### 5.3.2.1.2 Registro das imagens de satélite

O registro das imagens corresponde ao seu georreferenciamento para que possam ser importadas para o projeto que foi criado no programa.

Todas as imagens foram retificadas em modo tela, com base em uma imagem georreferenciada para o reconhecimento dos pontos de controle (GCP - Ground Control Points).

As imagens foram georreferenciadas no SIG-SPRING, utilizando 30 pontos de controle, com um erro máximo de 0,3.

Para o georreferenciamento das imagens CBERS-2B 157/124 e 157/125 foi utilizada a imagem Landsat 221/075, de 2002, obtida em [www.landsat.org](http://www.landsat.org).

Como o processo de registro implica na produção de uma nova imagem, a interpolação dos novos valores de *pixel* foi realizada por reamostragem pelo método do bilinear. Após o georreferenciamento, todas as informações passam a ter representatividade, uma vez que se encontram dentro da mesma base geográfica, ou seja, estarão dispostas na mesma escala, e as posições geográficas para os parâmetros mensurados e as informações colhidas da região em estudo passam a representar camadas (*layers*) passíveis de sobreposição, comparação, análise e tomadas de medidas métricas.

### 5.3.2.1.3 Mosaico das imagens de satélite

O mosaico de imagens pode ser definido como a junção de diferentes imagens em uma única imagem, correspondente a uma área geográfica definida. O produto final do mosaico é uma imagem com continuidade física. Foi realizado o mosaico de duas cenas das imagens CBERS-2B. Depois de mosaicadas as imagens, esta foi recortada para ter a área útil utilizada.

A área de drenagem e mata ciliar é um caso a parte no processo de classificação, pois sua reflectância gera confusão com a reflectância dos citros diminuindo muito o desempenho final da classificação. Para resolver este problema deixa que a classificação confunda os dados de drenagem e mata ciliar e, numa próxima etapa, tais informações são removidas mosaicando um PI (Plano de Informação) “Temático” contendo a

área de drenagem e mata ciliar vetorizada manualmente sobre a imagem de satélite em falsa cor (Figura 6).

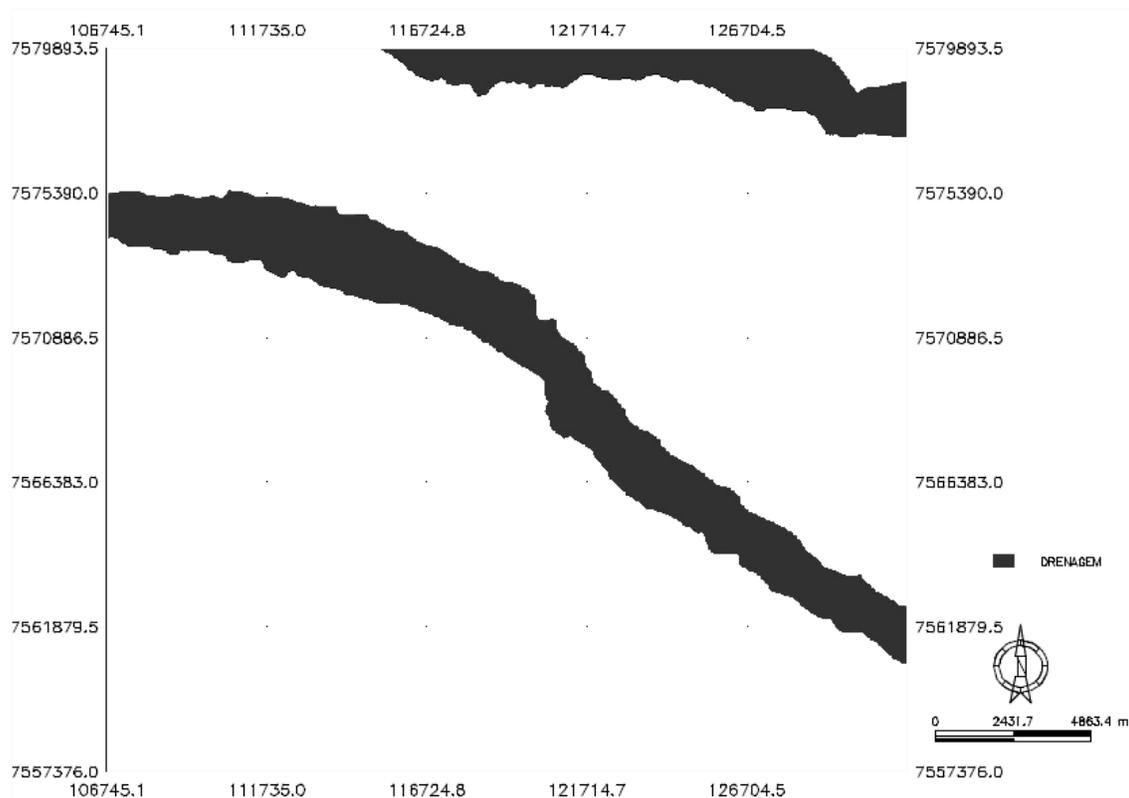


Figura 6. Máscara de da drenagem e mata ciliar da área de estudo.

### 5.3.2.2 Interpretação visual das imagens

A classificação visual foi realizada para ser utilizada como um mapa de referência na avaliação do desempenho dos classificadores digitais de imagens. O mapa de referência foi realizado pela classificação em tela da área de estudo, que como é um método de classificação trabalhoso e demorado, outras classificações devem ser estudadas para discriminação de áreas cultivadas. Como o objetivo é conhecer a área cultivada com citros, foram determinadas duas (2) classes de uso: CITROS e NÃO CITROS (composta por todas as áreas de uso que não são citros).

Neste processo, foi utilizada uma ferramenta, implementada no SPRING, denominada *edição matricial*, que permite visualizar vários PIs de forma simultânea

e interativa para realizar a classificação visual. A classificação/interpretação visual foi realizada utilizando o mosaico das imagens do satélite CBERS-2B, sensor CCD (Câmera Imageadora de Alta Resolução) de forma interativa até que o intérprete tenha certeza de que a classe rotulada num dado polígono represente a realidade no campo.

### **5.3.2.3 Classificação das Imagens**

Com o intuito de acelerar o tempo de geração de mapas de uso, bem como padronizar os procedimentos de classificação, utilizou-se um conjunto avançado de ferramentas para processamento e classificação automática de imagens.

#### **5.3.2.3.1 Classificação Supervisionada**

Os classificadores supervisionados utilizados foram: a KI (Krigagem Indicativa) e o MAXVER (Máxima Verossimilhança).

##### **5.3.2.3.1.1 Krigagem Indicativa - KI**

Para a classificação pela KI, foi realizada a amostragem no mosaico da imagem para a obtenção de pontos contendo coordenadas UTM e o valor de reflectância da banda 4 do CBERS-2B. Os pontos foram amostrados de 300 m em 300 m, com adensamento na área de citros, gerando 7074 pontos na área de 56146,78 ha.

A geoestatística foi utilizada para verificar a existência e quantificar o grau de dependência espacial da reflectância da banda 4 da imagem do CBERS-2B, definindo com auxílio do SIG-SPRING, os parâmetros necessários para o ajuste dos modelos teóricos (esférico, exponencial, gaussiano, linear com e sem patamar) aos variogramas experimentais. Também foi realizada a validação cruzada para escolha do melhor ajuste e, em seguida a interpolação por Krigagem ordinária para locais não medidos.

Para realizar a análise geoestatística, os valores da reflectância foram transformados em valores binários, ou seja, foram codificados em 0 e 1 para analisá-los

utilizando o variograma indicativo. Os valores de reflectância que representa a classe de CITROS foram codificados para o valor 1 e os demais para valor 0.

As operações seguidas para executar a classificação por KI foram: análise exploratória; geração do variograma; ajuste de um modelo teórico ao variograma; validação do modelo do ajuste e interpolação por KI.

Na geoestatística, a análise do variograma é uma etapa importante, pois o modelo de variograma escolhido é a interpretação da estrutura de correlação espacial foi utilizada nos procedimentos inferenciais da Krigagem.

O ajuste dos variogramas, com base nas pressuposições de estacionaridade da hipótese intrínseca, foi estimado, conforme descrito por Rossi et al. (1994), utilizando-se do variograma clássico de Matheron, ajustado para número digital (ND) de uma imagem digital, exposto na equação 7.

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [ND(x_i) - ND(x_i + h)]^2 \quad (7)$$

onde:  $\gamma(h)$  representa metade da esperança matemática do quadrado da diferença entre os valores dos pares de *pixel* separados pelo vetor de distância  $h$ , isto é, a variância;  $\gamma(h)$  é uma função que depende do ângulo e da distância do vetor  $h$  entre os número de pares de valores de *pixels*  $x_i + h$  e  $x_i$ .

O índice de dependência espacial (IDE) foi classificado de acordo com os intervalos propostos por Zimback (2001).

Após a geração do mapa da Krigagem, foi realizado o mapeamento das probabilidades para obter as áreas de CITROS e de NÃO CITROS.

### 5.3.2.3.1.2 Máxima Verossimilhança - MAXVER

Classificação é o processo de extração de informação em imagens para reconhecer padrões e objetos homogêneos. Os classificadores "*pixel a pixel*" utilizam apenas a informação espectral isoladamente de cada *pixel* para achar regiões homogêneas. O resultado

final de um processo de classificação é uma imagem digital que constitui um mapa de "*pixels*" classificados, representados por símbolos gráficos ou cores. As técnicas de classificação multiespectral "*pixel a pixel*" mais comuns são: máxima verossimilhança (MAXVER), distância mínima e método do paralelepípedo.

O mapa de ocupação dos solos foi obtido pela classificação das imagens CBERS-2B "*pixel a pixel*" pelo método MAXVER (Máxima Verossimilhança), considerado o método de classificação mais comum desta modalidade. Este método considera a ponderação das distâncias entre médias dos níveis digitais das classes, utilizando parâmetros estatísticos.

A classificação seguiu a sequência de operações:

- Criação do arquivo de contexto - este arquivo armazena quais bandas faz parte do processo de classificação, qual o método utilizado (*pixel*) e as amostras da classificação *pixel a pixel*;

- Execução do treinamento - foram feitas amostragens sobre uma imagem na área de desenho. Para o treinamento dos classificadores, foram definidas e amostradas tantas classes quanto necessárias para expressar a diversidade de padrões espectrais de cada tipo de cobertura;

- Análise das amostras - permitiram verificar a validade das amostras coletadas. As amostras foram analisadas procurando obter uma matriz de confusão com a diagonal principal próxima a 100%;

- Execução da classificação - de posse das amostras e das bandas escolhidas, a imagem foi classificada. Foi utilizado o classificador MAXVER e um limiar de aceitação de 100%;

- Execução do mapeamento para classes - permitiu transformar a imagem classificada (categoria Imagem) para um mapa temático raster (categoria Temática).

#### **5.3.2.3.2 Classificação Não Supervisionada**

O classificador não-supervisionado utilizado foi o *CLUSTER* (ISOSEG). Nessa classificação, o algoritmo baseia-se na análise de agrupamentos onde foram identificadas as "manchas" (*CLUSTERS*) formadas por *pixels* com características espectrais

similares. Foram definidas quais as concentrações de *pixels* que foram tratadas como grupos distintos.

Para realizar a classificação, primeiro procede-se a segmentação da imagem. No procedimento de segmentação foi necessário definir os parâmetros de similaridade de área. Para tal, foram realizados alguns testes numa área piloto com diferentes limiares a fim de escolher aqueles que particionavam a imagem de acordo com o interesse do trabalho.

#### 5.3.2.3.2.1 Segmentação de Imagens

A segmentação de imagem foi um procedimento adotado antes da fase de classificação, que tenta solucionar a subjetividade na aquisição do pacote de treinamento. Através deste procedimento, a imagem é dividida em regiões espectralmente homogêneas, onde algumas dessas áreas são utilizadas como treinamento do classificador. O processo utilizado para dividir a imagem, em regiões espectralmente homogêneas foi o de crescimento de regiões, pois para áreas agrícolas e áreas de vegetação natural, o segmentador utilizado foi o crescimento de regiões.

A segmentação por crescimento de regiões é uma técnica em que somente as regiões espacialmente adjacentes são agrupadas segundo algum critério de similaridade (MOREIRA, 2004). O procedimento de segmentação exige que o analista forneça dois tipos de limiares: o limiar de *Similaridade* e de *Área*.

Depois de realizada a segmentação dos diferentes tipos de produtos, o passo seguinte foi realizar a classificação não-supervisionada. Para tal, foi utilizado o classificador ISOSEG, com limiar de aceitação de 75%. Este algoritmo, bem como o limiar foi empregado porque, segundo algumas pesquisas, entre elas os estudos de Venturieri (1996), demonstram que o ISOSEG e o limiar 75% são os que apresentaram melhor desempenho de classificação de uso do solo.

Após o mapeamento das classes temáticas, foi realizada a edição matricial, para corrigir alguns erros de classificação decorrente de similaridade de respostas espectrais entre alvos diferentes.

### 5.3.2.4 Validação das Classificações

O processo de validação determina o grau de confiabilidade do resultado de acordo com os dados de referência, ou seja, supondo que os dados de referência representam a verdade, os processos de validação verificam sobre o resultado de uma determinada operação, o quão perto da referência o mesmo se encontra.

Os índices de acerto das classificações automáticas derivadas da imagem CBERS-2B foram obtidos considerando-se a interpretação visual de mesma data como verdade terrestre. As fidedignidades das classificações foram avaliadas pelos índices Kappa, para posterior comparação do desempenho dos diferentes índices em cada tipo de classificação.

O Índice Kappa é um coeficiente de concordância que informa o acerto da variação intra e interobservador, sendo utilizado quando dois observadores classificam separadamente uma amostra de objetos empregando a mesma escala de classes. Normalmente um dos observadores é a referência real ou verdade.

Para a determinação do valor Kappa e da sua variância emprega-se as seguintes equações:

$$K = \frac{P_o - P_c}{1 - P_c} \quad (8)$$

$$P_o = \frac{\sum_{i=1}^M n_{ij}}{N} \quad (9)$$

$$P_c = \frac{\sum_{i=1}^M n_{i+} n_{+j}}{N^2} \quad (10)$$

onde,  $P_o$  é a exatidão geral;  $P_c$  é a proporção de unidades que concordam por casualidade;  $M$  é o número de classes presentes na matriz de erro;  $n_{ij}$  representa o número de observações na

linha  $i$  e coluna  $j$ ;  $n_{i+}$   $n_{+j}$  são os totais marginais da linha  $i$  e da coluna  $j$ , respectivamente e  $N$  refere-se ao número de unidades amostrais completadas pela matriz.

O índice kappa considera que os valores próximos de 1 indicam excelente concordância do classificador com a verdade terrestre, enquanto que um valor próximo a 0 apresenta ausência de concordância. O valor da estatística Kappa, determinado pela Equação (8), é classificado de acordo com os intervalos contidos na Tabela 2. Essa tabela tem sido uma referência para classificar mapas resultantes da utilização de dados de sensoriamento remoto, dentro de certas restrições, mas que tem dado resultados satisfatórios. Os limites de concordância da Tabela 2 são os utilizados pelo SIG – SPRING.

Tabela 2. Nível de exatidão de uma classificação, conforme o valor de índice

Índice Kappa (K)	Concordância
$K < 0$	Sem concordância
$0,00 < K = 0,19$	Pobre
$0,20 < K = 0,39$	Fraca
$0,40 < K = 0,59$	Moderada
$0,60 < K = 0,79$	Forte
$0,80 < K = 1,00$	Excelente

Depois de realizar o pós-processamento, foi realizado um estudo comparativo dos resultados obtidos pela interpretação visual da imagem do CBERS-2B com várias operações de classificação digital não-supervisionada e supervisionada realizadas no SIG-SPRING.

### 5.3.2.5 Correlação dos classificadores

Para realizar a correlação entre os classificadores e a verdade terrestre (interpretação visual) foram amostrados 200 pontos, com mesma coordenada, nas imagens temáticas (interpretação visual, KI, MAXVER e CLUSTER), sendo 100 pontos em áreas cultivadas com CITROS e 100 de NÃO CITROS.

Depois que os pontos das classes temáticas foram obtidos, eles foram correlacionados no microsofot Excel<sup>®</sup>.

## **6 RESULTADOS E DISCUSSÃO**

As análises das imagens para as classificações da cultura de citros foram executadas com parte de duas cenas do satélite CBERS 2B, bandas 2, 3 e 4.

O mosaico da composição das bandas 432 (vermelho, verde e azul) da câmara CCD da imagem do satélite CBERS-2B foi reduzido para se obter apenas à área de estudo (Figura 7).



Figura 7. Mapa resultante do mosaico da composição das bandas 4, 3 e 2 da câmara CCD do CBERS-2B, de parte da mesoregião de Bauru e Araraquara.

### 6.1 Interpretação visual das imagens

Os classificadores digitais de imagens foram analisados com base nos resultados obtidos através do mapa de interpretação visual, representando a verdade terrestre (Figura 8) com áreas cultivadas com citros.

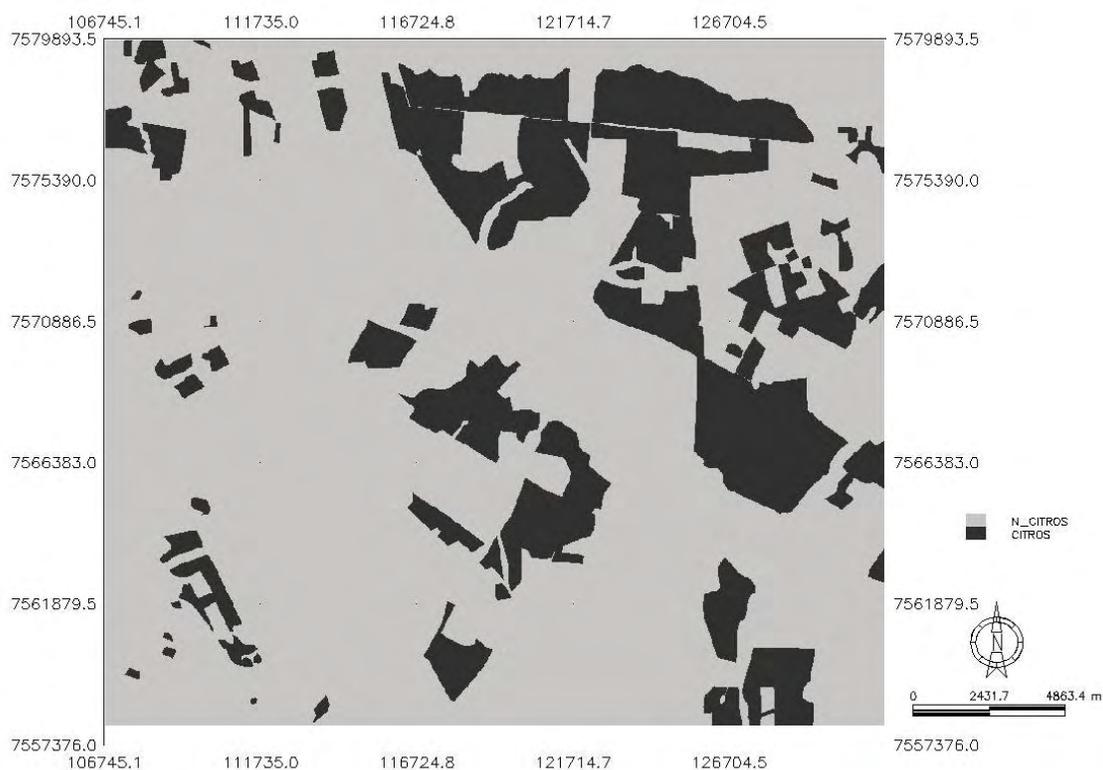


Figura 8. Áreas cultivadas com citros resultantes da interpretação visual.

## 6.2 Krigagem Indicativa - KI

A análise geoestatística parte do princípio que os dados são relacionados espacialmente, sendo que pontos próximos são mais parecidos que pontos distantes, com isso é preciso conhecer a localização no espaço do atributo que está sendo estudado. No estudo da dependência espacial da reflectância foi gerada uma malha amostral (Figura 9) com os pontos distanciados entre si por 300 metros. Nesta malha amostral foi realizado um adensamento nas áreas cultivadas com citros para verificar o valor da reflectância do citros na banda 4 (infravermelha próximo) para que este valor fosse utilizado como ponto de corte na aplicação da KI. Os valores de reflectância para a cultura do CITROS encontra-se dentro do intervalo de 73 a 96, sendo os valores menores do que 73 e os maiores a 96 representam outros tipos de cobertura do solo, aqui denominados como NÃO CITROS.

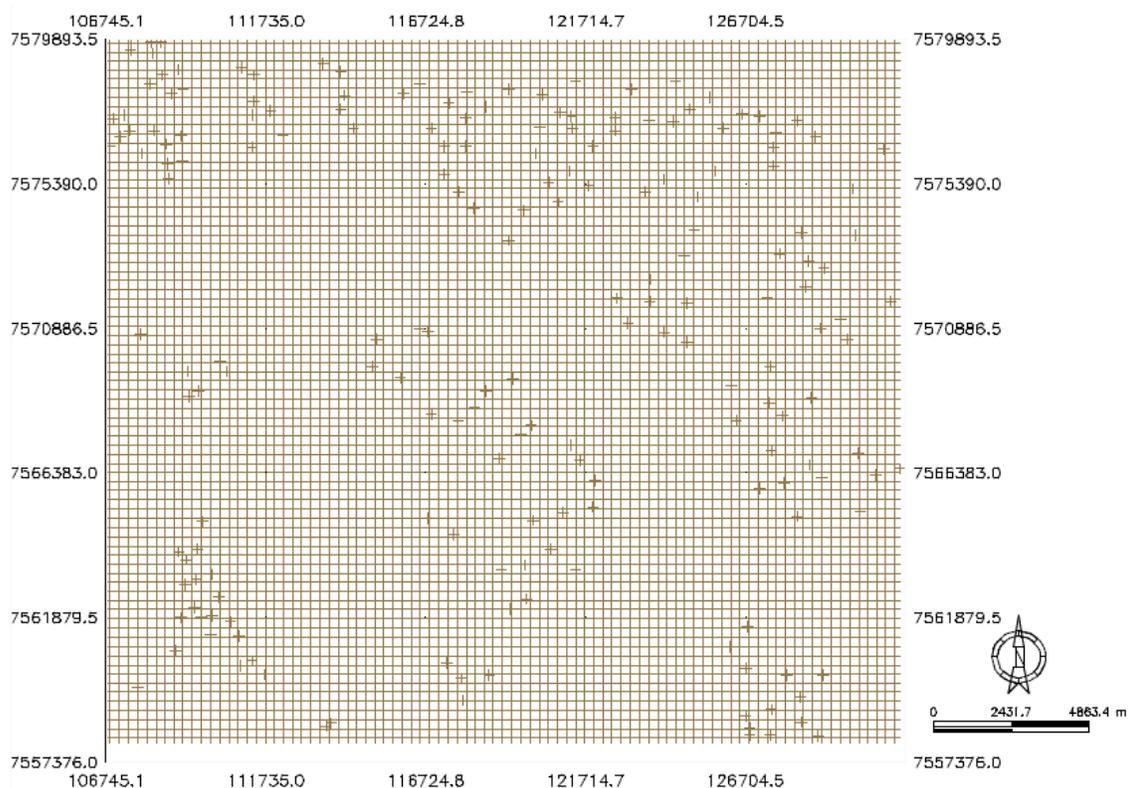


Figura 9. Pontos amostrais da Banda 4 (infravermelha) da câmara CCD do CBERS-2B.

A reflectância da banda 4 (infravermelha) ajustou-se melhor ao modelo exponencial (Tabela 3 e Figura 10), pois este modelo apresentou o menor valor de akaike com relação aos modelos esférico, potência e gaussiano. Em um raio de 4751,102 m os valores de reflectância são dependentes espacialmente, e este alcance foi considerado no processo de interpolação para obter um mapa final com valores confiáveis.

O índice de dependência espacial (IDE) da reflectância foi considerado moderado ( $25\% < IDE < 75\%$ ), segundo a classificação proposta por Zimback (2001). Pode-se dizer que 62% da variância dos dados tem relação espacial e não são ao acaso, foi considerada na interpretação dos dados.

Tabela 3. Modelo e parâmetros do ajuste do variograma da Banda 4 (infravermelha) da câmara CCD do CBERS-2B

Atributo	N	Modelo	A (m)	$C_0$	C	IDE (%)	CCP
B4	7074	Exponencial	4751,102	0,076	0,124	62	0,742

B4: banda 4 (infravermelha) da câmara CCD do CBERS-2B; N: número de pontos; A (m): alcance em m;  $C_0$ : efeito pepita; C: componente estrutural; IDE: índice de dependência espacial em porcentagem (%); CCP: coeficiente de correlação de Pearson dado pela validação cruzada.

O ajuste do variograma foi verificado pela validação cruzada obtendo um coeficiente de correlação de Pearson de 0,742 entre os valores observados e estimados, considerando assim que o modelo teórico ajustado ao modelo experimental é utilizado no processo de interpolação por KI.

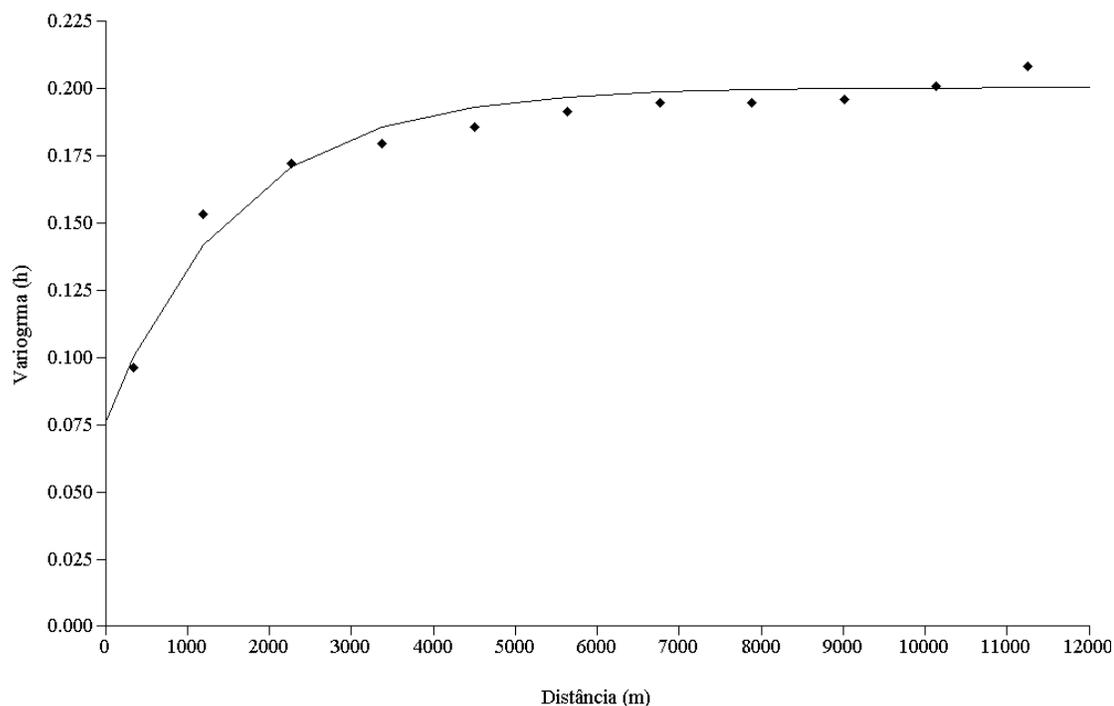


Figura 10. Variograma da Banda 4 (infravermelha) da câmara CCD do CBERS-2B.

O modelo ajustado, o alcance, o efeito pepita e o patamar foram utilizados na interpolação por krigagem indicativa, gerando o mapa de probabilidade de ocorrência de citros na área. Na Figura 11 observou-se que os tons mais claros são de maior probabilidade de ocorrência de citros, enquanto que os tons mais escuros têm menor probabilidade de ser citros.

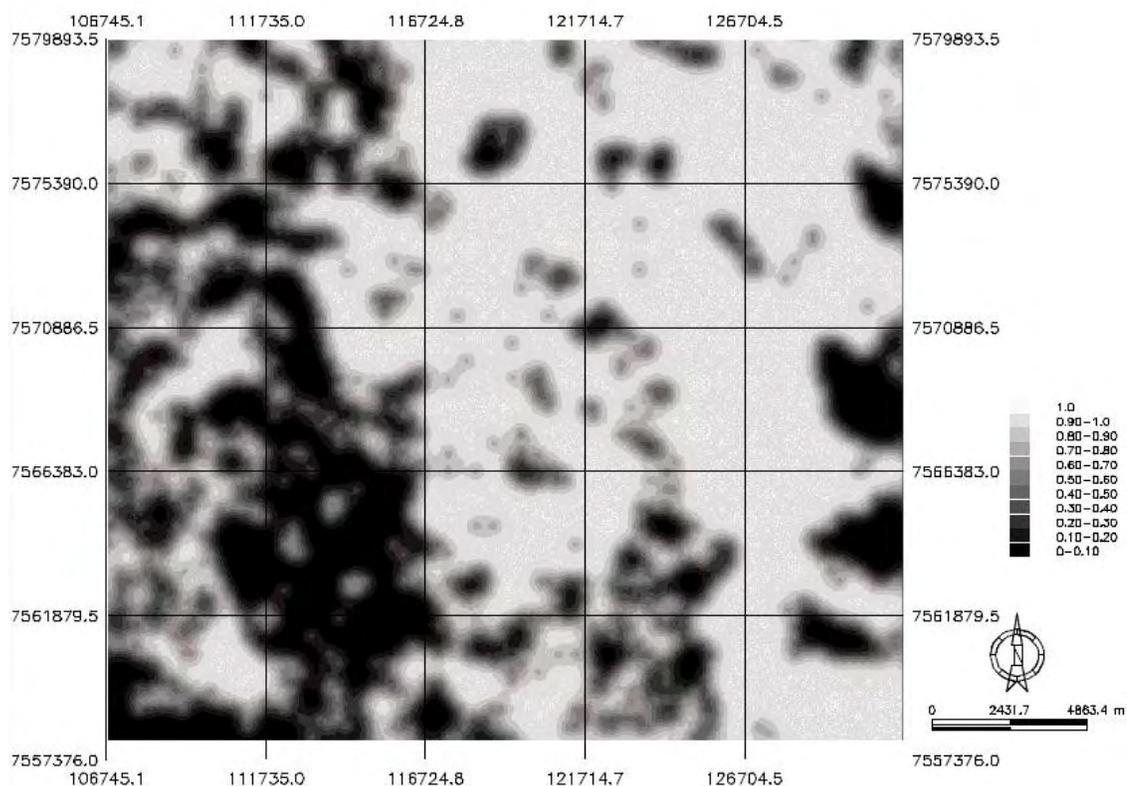


Figura 11. Mapa de probabilidade da Banda 4 (infravermelha) da câmara CCD do CBERS-2B.

Depois de gerado o mapa de probabilidade de ocorrência de citros, foi realizado o fatiamento do mesmo, considerando que o valor de 0 a 95 % de probabilidade como NÃO CITROS e acima de 95 % de probabilidade como CITROS (Figura 12). Outros intervalos de fatiamento foram testados, porém o que apresentou melhor classificação foi quando considerou o intervalo de 95% a 100% de probabilidade como citros.

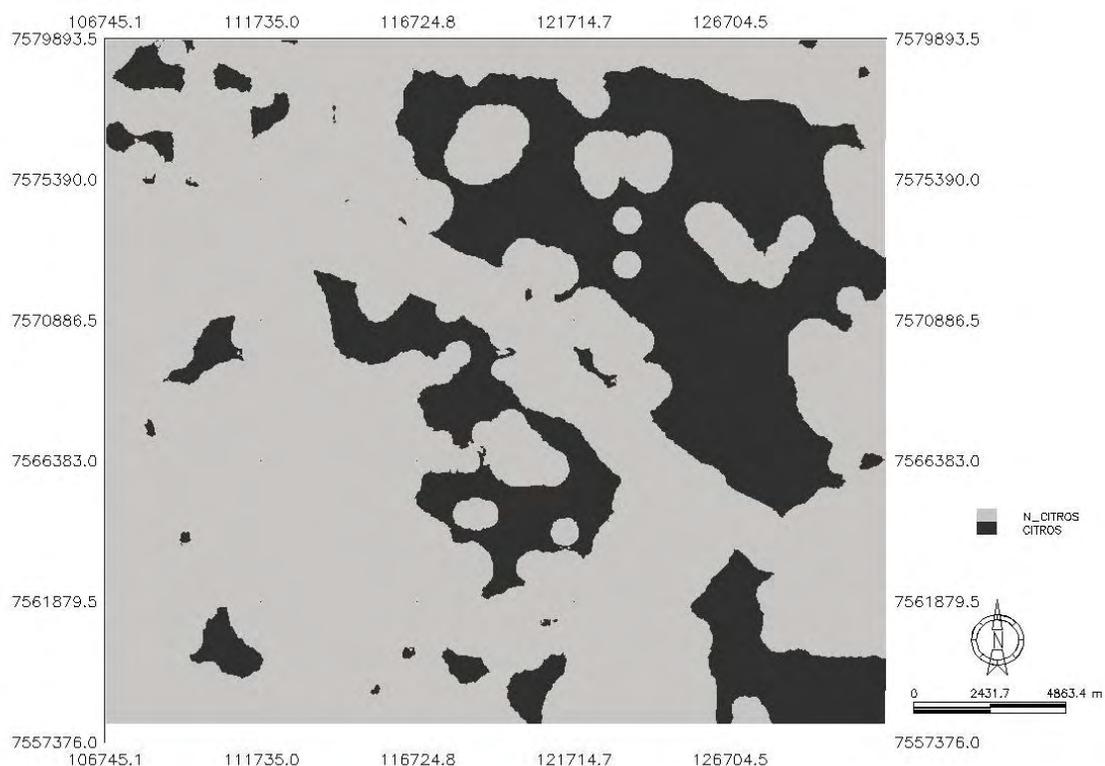


Figura 12. Classificação por KI da Banda 4 (infravermelha) da câmara CCD do CBERS-2B.

Ao relacionar o mapa da KI com o mapa de verdade terrestre verificou-se que as áreas maiores de CITROS foram melhor representadas na classificação por KI. Como a krigagem tem a característica de suavização, e como um dos principais parâmetros do variograma é o alcance que representa um raio de influência, o mapa gerado pela KI apresenta os limites das áreas de CITROS suavizados e de forma circular, ao contrário dos outros métodos que apresentam limites de áreas angulares e finalização brusca.

As áreas fragmentadas de CITROS que estavam próximas foram unidas em uma única área pela KI.

### 6.3 Máxima Verossimilhança - MAXVER

Como o MAXVER é um classificador que precisa de amostras de treinamentos, as quais são definidas pelo analista para agrupar as diferentes classes espectrais,

este método conseguiu determinar satisfatoriamente as áreas de CITROS (Figura 13). Observou-se que, assim como a KI, o MAXVER definiu melhor as áreas maiores de CITROS.

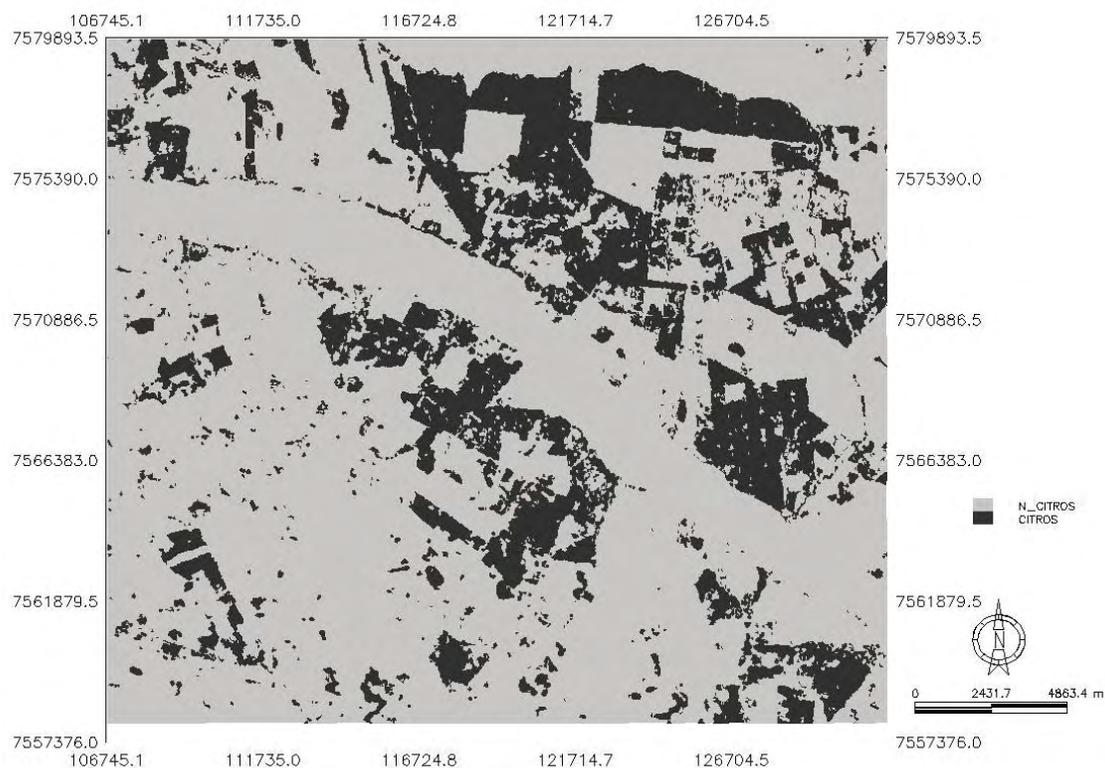


Figura 13. Classificação MAXVER para CITROS e NÃO CITROS.

No processo de análise das amostras de treinamento, o MAXVER teve um bom desempenho com uma confusão média de 12,11%, o que justifica as pequenas áreas que foram erroneamente classificadas com CITROS, sendo estas áreas próximas aos pequenos canais de drenagem não excluídos pela máscara.

#### **6.4 CLUSTER**

O classificador digital não supervisionado *CLUSTER* promove a identificação de classes espectrais distintas em uma imagem com muitas classes discriminadas. Posteriormente foi realizado um reagrupamento das classes para CITROS e NÃO CITROS. A classificação final do *CLUSTER* está apresentada na Figura 14.

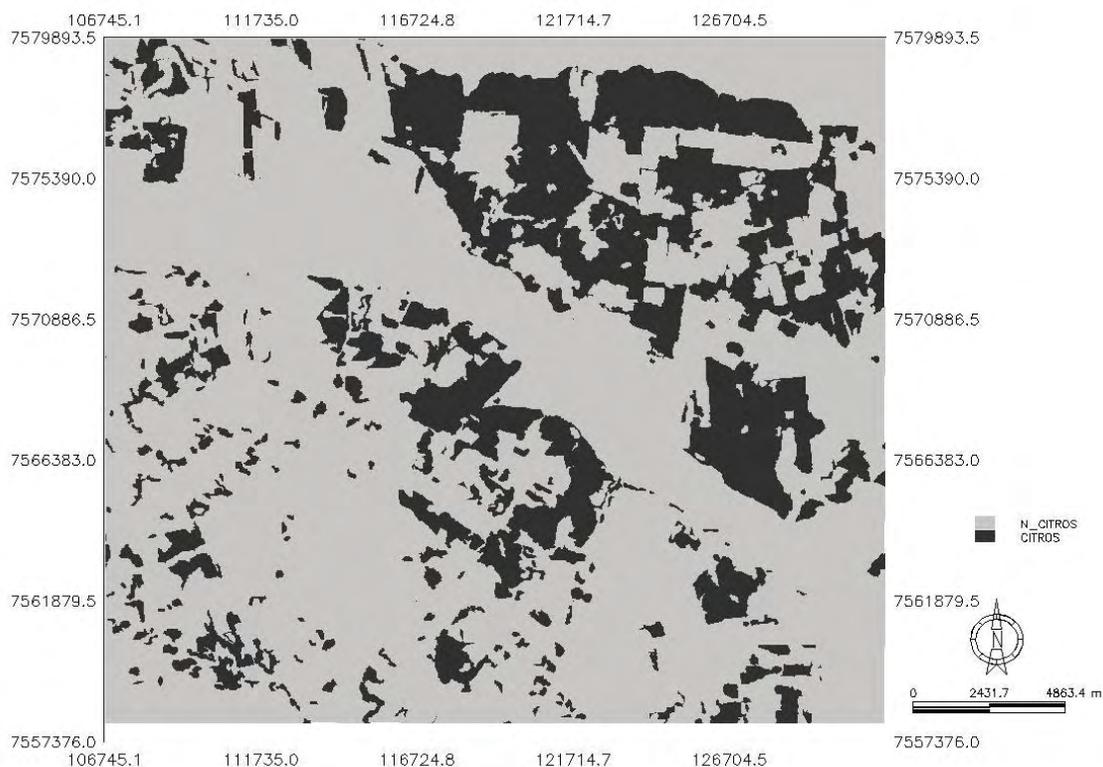


Figura 14. Classificação *CLUSTER* para CITROS e NÃO CITROS.

Com o classificador não-supervisionado *CLUSTER*, a classe de CITROS foi identificada e agrupada, observou-se que a reflectância de outros usos tiveram pouca influência neste processo, pois as áreas de confusão foram poucas e pequenas.

Ao observar o mapa de verdade terrestre e o do *CLUSTER*, verifica-se que as áreas maiores de CITROS foram bem classificadas, enquanto as áreas menores sofreram influência da reflectância dos outros usos do solo. Observou-se também que as áreas próximas aos pequenos canais de drenagem foram as que mais confundiram os valores espectrais com os do CITROS como ocorreu com o MAXVER.

Observando-se os mapas gerados pelos três classificadores digitais, detectou-se que a KI é a que não apresenta áreas fragmentadas e é a que menos classificou pequenas áreas de mata ciliar como CITROS.

## 6.5 Comparação de métodos de classificação de imagens

### 6.5.1 Índice Kappa

O Índice Kappa considera todos os elementos presentes no mapa classificado, ao invés de utilizar apenas os elementos da diagonal ou de alguns pontos. Os acertos e índices calculados para os classificadores estão apresentados na Tabela 4.

Tabela 4. Comparação dos classificadores pelo Índice Kappa

Método	Acertos (%)	Kappa	Qualidade de classificação
KI	82	0,5218	Moderada
MAXVER	86	0,6059	Forte
CLUSTER	86	0,6121	Forte

Na validação pelo Índice Kappa foram verificados todos os pixels das imagens. Observou-se que a KI obteve um acerto de 82%, ou seja, 567.201 pixels do total de 691250 dos pixels da imagem foram classificados corretamente pela KI.

Tanto o classificador *CLUSTER*, quanto o MAXVER tiveram 86% de acertos.

Verificou-se que o resultado na avaliação da qualidade da classificação foi moderado para a KI com um índice de 0,5218.

O MAXVER e o *CLUSTER* apresentaram qualidade de classificação forte, com índices de 0,6059 e 0,6121, respectivamente. Sanches et al. (2008), estudando a discriminação de variedades de citros em imagens CCD CBERS-2, utilizando o SIG-SPRING, encontrou valores de índice kappa inferior ao encontrado neste trabalho para os classificadores MAXVER e o *CLUSTER*. Dainese (2001), ao realizar estudo temporal do uso da terra e na comparação entre classificação não-supervisionada e análise visual, encontrou valores de Índice Kappa inferior ao encontrado neste trabalho para o classificador *CLUSTER*.

Nestas condições de estudos, a KI foi a classificação que teve menor qualidade em comparação com o *CLUSTER* e o MAXVER. No entanto, como classificador

supervisionado ela tem vantagem em relação ao MAXVER no treinamento ou amostragens, pois para o MAXVER é necessário fazer amostras de treinamento em todas as áreas de CITROS e de outros usos da imagem. Já na KI é preciso conhecer apenas o valor da reflectância do CITROS em uma área e, com base nestes valores, aplica-se o corte para a transformação binária dos dados.

### 6.5.2 Quantificação de áreas de citros

Na Tabela 5 está apresentada a quantificação de área plantada com citros pelos diferentes classificadores. O classificador MAXVER foi o que apresentou área total de citros mais próxima da interpretação visual (verdade terrestre), com uma diferença em porcentagem de área de 3,85 %, ou seja, ele classificou como CITROS 471,51 ha a mais do que realmente tem na área de estudo. A KI foi o classificador que mais super estimou a área total de CITROS (27,94 %).

Tabela 5. Quantificação de área de citros pelos classificadores e diferença de área

Classificador	CITROS (ha)	Diferença	Diferença em %
Visual	12235,90		
<i>CLUSTER</i>	13575,78	-1339,88	10,95
MAXVER	12707,41	-471,51	3,85
KI	15654,25	-3418,35	27,94

Diferença: área de citros da classificação visual com os outros classificadores.

### 6.5.3 Correlação dos classificadores

A correlação entre a interpretação visual e a KI foi de 66%, ou seja, dos 200 pontos amostrados 132 pontos do mapa resultante da KI tiveram classes iguais ao mapa da interpretação visual.

O MAXVER e o *CLUSTER* obtiveram uma correlação de 76% e 73%, representando 152 e 146 pontos coincidentes, respectivamente.

#### 6.5.4 Considerações Finais

Dois fatores importantes na detecção de plantas no campo não foram levados em consideração nas classificações devido à complexidade dos dados e análises. O primeiro fator refere-se ao estado fenológico das plantas e o segundo as diferentes variedades de citros na área de estudo.

Na construção do mapa de verdade terrestre foi verificado que os talhões de citros apresentavam diferentes estágios fenológicos e de sanidade, e estes fatores devem ter influenciado nos resultados das classificações, principalmente da KI, que foi baseada nos valores da reflectância para realizar o corte para a transformação binária.

Um outro fator que influencia no resultado final da classificação são as diferentes variedades de citros cultivadas, uma vez que cada variedade possui características diferentes quanto a cor e arquitetura foliar, que promove valores de reflectância diferentes nas imagens.

Como a distância entre amostras é fundamental para a qualidade da classificação por Krigagem Indicativa e a dependência espacial variável, seria interessante estudos futuros sobre este procedimento.

## 7 CONCLUSÕES

Pelos resultados obtidos nas classificações de imagem para a discriminação e quantificação de áreas cultivadas com citros na mesoregião de Bauru e Araraquara pode-se concluir:

- os classificadores obtiveram melhor qualidade de classificação para as áreas maiores com CITROS;

- a Krigagem Indicativa unificou as áreas pequenas de CITROS em uma única área;

- a Krigagem Indicativa foi o classificador que menos classificou área de mata ciliar como CITROS, já os demais confundiram consideravelmente mata ciliar com CITROS;

- pela validação, a Krigagem Indicativa foi o classificador que obteve a menor qualidade de classificação em comparação com o MAXVER e o *CLUSTER* e o maior tempo de processamento;

- o MAXVER foi o que apresentou área total de CITROS mais próxima da verdade terrestre, enquanto que a Krigagem Indicativa foi o classificador que mais super estimou a área total de CITROS em 27,94 %;

- a Krigagem Indicativa obteve uma correlação de 66% com a interpretação visual enquanto o MAXVER e o *CLUSTER* obtiveram uma correlação de 76% e 73%, respectivamente.

## 8 REFERÊNCIAS

ABECITRUS - Associação Brasileira Dos Exportadores de Citrus. **Citricultura brasileira: Um exemplo de capacidade e eficiência.** 2001. Disponível em: <[www.abecitrus.com.br/informativo/nota\\_citricultura\\_out05.html](http://www.abecitrus.com.br/informativo/nota_citricultura_out05.html)>. Acesso em: 15 jan. 2007.

ALVES, P. R. B.; MELO, B. **Cultura dos citros.** Disponível em: <<http://www.fruticultura.iciag.ufu.br/citros2.htm>>. Acesso em: 21 jan. 2010.

ANDRIOTTI, J. L. S. **Fundamentos de estatística e geoestatística.** São Leopoldo: Unisinos, 2005. 165 p.

ANUÁRIOS. **Vitamine-se.** Disponível em: <<http://www.anuarios.com.br/>>. Acesso em: 14 mai. 2010.

ARAGÃO, L. E. O. C. **Modelagem dos padrões temporal e espacial da produtividade primária bruta na região do Tapajós: uma análise multi-escala.** São José dos Campos: INPE, 2004. 286 f. Tese (Doutorado em Sensoriamento Remoto)-Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2004.

ATKINSON, P. M.; WEBSTER, R.; CURRAN, P. J. Cokriging with airborne MSS imagery. **Remote Sensing of Environment**, New York, v. 50, n. 3, p. 335-345, 1994.

ATKINSON, P. M.; CURRAN, P. J. Defining an optimal size of support for Remote Sensing Investigation. **IEEE Transactions on Geosciences and Remote Sensing**, New York, v. 33, n. 3, p. 768-776, 1995.

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

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

BECKER, A.; BRAUN, P. Disaggregation, aggregation and spatial scaling in hydrological modelling. **Journal of Hydrology**, Amsterdam, v. 217, n. 3/4, p. 239-52, 1999.

BENVENUTI, F. A. **Relação entre índices espectrais de vegetação com produtividade da cana e atributos edáficos**. 2005. 98 f. Dissertação (Mestrado em engenharia Agrícola)-Faculdade de Engenharia Agrícola, Universidade Estadual de Campinas, Campinas, 2005.

BERBEROGLU, S. et al. The integration of spectral and textural information using neural networks for land cover mapping in the Mediterranean. **Computers & Geosciences**, Oxford, v. 26, n. 4, p. 385-396, 2000.

BERNARDES, T. **Caracterização do ambiente agrícola do complexo serra negra por meio de sensoriamento remoto e sistemas de informação geográfica**. 2006. 131 f. Dissertação (Mestrado em Agronomia)-Universidade Federal de Lavras, Lavras, 2006.

BLAIS, R. A.; CARLIER, P. A. **Applications of geostatistics in ore evaluation**. Montreal: Canadian Institute of Mining and Metallurgy, Special v. 9, 1968. p. 41-48.

BRASIL. Serviço Nacional de Pesquisa Agrônômica, Comissão de Solos. **Levantamento de reconhecimento dos solos do Estado de São Paulo**. Ministério da Agricultura. CNEPA, 1960. 605 p. (Boletim, 12).

BUCENE, L. C. **Sistema de informação geográfica na classificação de terras para irrigação, em Pardinho-SP**. 2002. 177 f. Dissertação (Mestrado em Agronomia/Irrigação e Drenagem)-Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2002.

BURGESS, T. M.; WEBSTER, R. Optimal interpolation and isarithmic mapping, of soil properties. II. Block kriging. **The Journal of Soil Science**, Oxford, v. 31, p. 333-341, 1980.

CÂMARA, G. **Modelos, linguagens e arquiteturas para banco de dados geográficos**. 1995. 264 f. Tese (Doutorado em Sensoriamento Remoto)-Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1995.

CÂMARA, G. et al. Integrating remote sensing and GIS by object-oriented data modelling. **Computers and Graphics**, New York, v. 15, n. 6, July. 1996a.

CÂMARA, G. et al. Integrating remote sensing and GIS by object-oriented data modelling. **Computers and Graphics** New York, v. 20, n. 3, p. 395-403, may-jun., 1996b.

CÂMARA, G.; MEDEIROS, J. S. **Geoprocessamento para projetos ambientais**. São José dos Campos: INPE, 1996.

CÂMARA, G.; MEDEIROS, J. S. Princípios básicos de geoprocessamento. In: ASSAD, E. D.; SANO, E. E. **Sistema de informações geográficas: aplicações na agricultura**. 2. ed. Planaltina: Centro de Pesquisa Agropecuária dos Cerrados/Embrapa, 1998. p. 3-11.

CÂMARA, G.; DAVIS, C.; MONTEIRO, A.M.V. (Org.). **Introdução à ciência da geoinformação**. São José Dos Campos: INPE, 2001. 345 p. Disponível em: <[http://www.dpi.inpe.br/gilberto/tutoriais/gis\\_ambiente/3opera.pdf](http://www.dpi.inpe.br/gilberto/tutoriais/gis_ambiente/3opera.pdf)>. Acesso em: 15 set. 2006.

CAMBARDELLA, C. A. et al. Field-scale variability of soil properties in Central Iowa soils. **Soil Science Society of America Journal**, Madison, v. 58, n. 5, p. 1501-1511, 1994.

CASTRO, J. L. A. Metodologia para utilização de aeromodelos em monitoramento aéreo: análise de imagens. **Circular técnica 18**, São Carlos, p. 1-11, nov., 2003.

CASTRO, L. I. S. **Diagnóstico ambiental na sub-bacia do Ribeirão Pouso Alegre com a utilização de um sistema de informação geográfica**. 2008. 133 f. Dissertação (Mestrado em Energia na Agricultura)-Faculdade de Ciências Agrônomicas, Universidade Estadual Paulista, Botucatu, 2008.

CBERS. China-brazil Earth Resources Satellite. **Programa CBERS**. São José dos Campos. Disponível em: <[www.CBERS.inpe.br](http://www.CBERS.inpe.br)>. Acesso em: 21 jan. 2010.

CHICA-OLMO, M.; ABARCA-HERNÁNDEZ, F. Radiometric coregionalization of Landsat TM and SPOT HRV images. **International Journal of Remote Sensing**, Basingstoke, v. 19, p. 997-1005, 1998.

CHICA-OLMO, M.; ABARCA-HERNÁNDEZ, F. Computing geostatistical image texture for remotely sensed data classification. **Computers & Geosciences**, Oxford, v. 26, p. 373-383, 2000.

CONGALTON, R. A review of assessing the accuracy of classifications of remotely sensed data. **Photogrammetric Engineering and Remote Sensing**, Bethesda, v. 37, p. 35-46, 1991.

CONGALTON, R. G.; MEAD, R. A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering and Remote Sensing**, Bethesda, v. 49, n. 1, p. 69-74, jan. 1983.

COVRE, M. **Influência de parâmetros culturais de citros sobre os dados TM/Landsat**. 1989. 241 f. Dissertação (Mestrado em Sensoriamento Remoto)-Instituto de Pesquisas Espaciais, São José dos Campos, 1989.

CRESSIE, N. A. **Statistics for spatial data**. New York: John Wiley, 1991. 900 p.

CURRAN, P. J. The semivariogram in remote sensing: an introduction. **Remote Sensing of Environment, New York**, v. 24, n. 3, p. 493-507, 1988.

CURRAN, P. J.; ATKINSON, P. M. Geostatistics and remote sensing. **Progress in Physical Geography**, London, v. 22, n. 1, p. 61-78, 1998.

DAINESE, R. C. **Sensoriamento remoto e geoprocessamento aplicado ao estudo temporal do uso da terra e na comparação entre classificação não-supervisionada e análise visual.** 2001. 210 f. Dissertação (Mestrado em Agronomia/Energia na Agricultura)-Faculdade de Ciências Agronômicas, Universidade Estadual Paulista, Botucatu, 2001.

DELFINER, P.; DELHOMME, J. P. Optimum interpolation by Kriging. In: DAVIS, J. C.; MCCULLAGH, M. J. (Eds.). **Display and analysis of spatial data.** New York: John Wiley, 1975. p. 96-114.

DELHOMME, J. P. **Kriging in hydrosciences.** Fontainebleau: Centre D'Informatique Geologique, 1976.

DUARTE, V. Metodologia de interpretação visual de imagens de satélite. In ASSUNÇÃO, G. V. **Sensoriamento remoto na agricultura: conceitos básicos, metodologia e aplicações.** São José dos Campos: INPE, 1989. p. 91-106.

DUNGAN, J. L.; PETERSON, D. L.; CURRAN, P. J. Alternative approaches for mapping vegetation quantities using ground and image data. In: MICHENER, W., BRUNT, J., STAFFORD, S. (Eds.). **Environmental information management and analysis: ecosystem to global scales.** London: Taylor & Francis, 1994. p. 237-261.

DUTRA, L. V. et al. **Análise automática de imagens multiespectrais.** São José dos Campos: INPE, 1981. 161 p.

EASTMAN, J. R. **IDRISI 32 for Windows: guide to GIS and image processing.** Massachusetts: Clark University, 1999.

EASTMAN, J.R. **IDRISI for Windows: introdução e exercícios tutoriais.** Porto Alegre: UFRGS - Centro de Recursos Idrisi, 1998. Disponível em: <[www.ecologia.ufrgs.br/idrisi](http://www.ecologia.ufrgs.br/idrisi)>. Acesso em: 06 jun. 2002.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. Centro Nacional de Pesquisa de Solos. **Sistema Brasileiro de Classificação de Solos.** 2. ed. Rio de Janeiro: EMBRAPA, 2006. 374 p.

EPIPHANIO, J. C. N. CBERS: estado atual e futuro. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2009, Natal. **Anais...** Natal: INPE, 2009. p. 2001-2008.

FELGUEIRAS, C. A. **Modelagem ambiental com tratamento de incertezas em sistemas de informações geográficas**: paradigma geoestatístico por indicação. 1999. 181 f. Tese (Doutorado em Computação Aplicada)-Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1999.

GOOVAERTS, P. **Geostatistics for natural resources evaluation**. New York: Oxford University Press, 1997. 650 p.

GUERRA, P. A. G. **Geoestatística operacional**. Brasília: Ministério das Minas e Energia; Departamento de Produção Mineral, 1988. 145 p.

GUIMARÃES, E. C. **Geoestatística básica e aplicada**. UFU/ FAMAT. Núcleo de estudos estatísticos e biométricos. 2001. 48 p. Disponível em: <[www.famat.ufu.br/ednaldo/geoest/apgeo1.pdf](http://www.famat.ufu.br/ednaldo/geoest/apgeo1.pdf)>. Acesso em: 10 de ago. 2009.

HAJRASULIHA, S. et al. Spatial variability of soil sampling for salinity studies in southwest Iran. **Irrigation Science**, New York, v. 1, p. 197-208, 1980.

IBGE. Instituto Brasileiro de geografia e estatística. Disponível em: <<http://www.ibge.gov.br>>. Acesso em: 14 mai. 2010.

INOUE, N.; XAVIER, S.R.; ROMANEL, C. Análise geoestatística do subsolo da usina nuclear de Angra 2. In: CONGRESSO E FEIRA PARA USUÁRIOS DE GEOPROCESSAMENTO DA AMÉRICA LATINA - GIS BRASIL 99, 5., Salvador, 1999. **Anais...** Salvador, 1999. 1 CD-ROM.

INPE. Instituto Nacional de Pesquisas Espaciais. **Sistema de processamento de informações georeferencias – SPRING 3.5.1 – Tutoriais**. São José dos Campos: INPE, 2001.

INSTITUTO DE PESQUISAS TECNOLÓGICAS - IPT. **Mapa geológico do Estado de São Paulo**. Escala 1:500.000. São Paulo: IPT, 1981.

IPPOLITI-RAMILO, G.A.; EPIPHANIO, J.C.N.; SHIMABUKURO, Y.E. Landsat-5 thematic mapper data for pre-planting crop area evaluation in tropical countries. **International Journal of Remote Sensing**, Basingstoke, v. 24, n. 7, p. 1521-1534, jul., 2003.

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

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 2. ed. New Jersey: Prentice Hall, 1996. 316 p.

JENSEN, J.R. Remote sensing of vegetation. In. \_\_\_\_\_. **Remote sensing of the environment, an earth resource perspective**. Upper Saddle River: Prentice Hall, 2000. p. 333-377.

JIM, A. S. **Geoprocessamento aplicado no diagnóstico físico-ambiental**. 2006. 109 f. Dissertação (Mestrado em Energia na Agricultura)-Faculdade de Ciências Agrônomicas, Universidade Estadual Paulista, Botucatu, 2006.

JOURNEL, A. G.; HUIJBREGTS, Ch. J. **Mining geostatistics**. Academic Press: London, 1978. 600 p.

JOURNEL, A. G. Nonparametric estimation of spatial distributions. **Mathematical Geology**, New York, v. 15, n. 3, p. 445-468, 1983.

JUPP, D. L. B.; STRAHLER, A. H.; WOODCOCK, C. E. Autocorrelation and regularization in digital images. II: Simple image models. **IEEE Transactions on Geoscience and Remote Sensing**, New York, v. 27, p. 463-473, 1989.

KANE, V. et al. Interpretation of regional geochemistry. **Computational Geosciences**, Amsterdam, v. 8, p. 117-136, 1982.

KITANIDIS, P. K.; VOMVORIS, E. G. A geostatistical approach to the inverse problem in groundwater modelling (steady state) and one dimensional simulations. **Water Resources Research**, Washington, v. 19, n. 3, p. 677-690, 1983.

KOFFLER, N.F. Técnicas de sensoriamento remoto orbital aplicadas ao mapeamento da vegetação e uso da terra. **Geografia**, Rio Claro, v. 17, n. 2, p. 14-17, out., 1992.

KRIGE, D.G. A statistical approach to some basic mine evaluation problems on the Witwatersrand. **Journal of the South African Institute of Mining and Metallurgy**, Johannesburg, v. 52, p. 119-139, 1951.

LACAZE, B.; RAMBAL, S.; WINKEL, T. Identifying spatial patterns of Mediterranean landscapes from geostatistical analyses of remotely-sensed data. **International Journal of Remote Sensing**, Basingstoke, v. 15, p. 2437-2450, 1994.

LAJAUNIE, C. A geostatistical approach to air pollution modelling. In: JOURNEL, A. G.; MARECHAL, A. **Geostatistics for natural resources characterization**. Dordrecht: Reidel, 1984. p. 877-891.

LAMPARELLI, R.A.C.; ROCHA, J.V.; BORGHI, E. **Geoprocessamento e agricultura de precisão: fundamentos e aplicações**. Guaíba: Agropecuária, 2001. 118 p.

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

LANDIM, P. M. B. **Análise estatística de dados geológicos multivariados**. Rio Claro: Laboratório Geomatemático, UNESP/IGCE/DGA, 2002. 120 p. (Texto Didático 3). Disponível em: <[www.rc.unesp.br/igce/aplicada/textodi.html](http://www.rc.unesp.br/igce/aplicada/textodi.html)>. Acesso em: 25 jan. 2010.

LANDIM, P. M. B.; STURARO, J. R. **Krigagem indicativa aplicada à elaboração de mapas probabilísticos de riscos**. Texto Didático 06. Departamento de Geologia Aplicada – IGCE, 2002.

LANDIM, P.M.B.; STURARO, J.R. ; MONTEIRO, R. C. **Exemplos de aplicação da cokrigagem**. DGA, IGCE, UNESP/Rio Claro, Laboratório Geomatemática. Texto Didático 09, 17 pp. 2002. Disponível em <<http://www.rc.unesp.br/igce/aplicada/textodi.html>>. Acesso em: 25 jan. 2010.

LANDIM, P. M. B. Sobre geoestatística e mapas. **Terra e Didática**, Campinas, v. 2, n.1, p.19-33, 2006.

LARK, R. M. Geostatistical description of texture on an aerial photograph for discriminating classes of land cover. **International Journal of Remote Sensing**, Basingstoke, v. 17, p. 2115-2133, 1996.

LILLESAND, T.M.; KIEFER, R.W. **Remote sensing and image interpretation**. 2. ed. Chichester: John Willey & Sons, 1994. 740 p.

LILLESAND, T.M.; KIEFER, R.W. **Remote sensing and image interpretation**. 4. ed. Madison : University of Wisconsin, 1999. 750 p.

LONGLEY, P. A. et al. **Geographic information systems and science**. New York: Wiley, 2001. 454 p.

LOPES, E.S.S.; FERREIRA, H.S. **Tutorial 10 Aulas: SPRING Básico**. Disponível em: <<http://www.dpi.inpe.br/spring/>>. Acesso em: 01 set. 2005.

MACHADO, M. L. **Caracterização de agroecossistemas cafeeiros da Zona da Mata de Minas Gerais, usando sensoriamento remoto e sistemas de informações geográficas**. 2002. 137 f. Dissertação (Mestrado em Solos e Nutrição de Plantas)-Universidade Federal de Lavras, Lavras, 2002.

MASCARENHAS, N. D. A.; VELASCO, F. R. D. **Processamento de imagens** São José dos Campos: INPE, 1989. 315 p.

MATHER, P. M. **Computer processing of remotely-sensed images: an introduction**. 2. ed. Chichester: John Wiley & Sons, 1999. 292 p.

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

MATHERON, G. **The theory of regionalized variables and its applications**. Les Cahiers du Centre de Morphologie Mathématique de Fontainebleau. Fontainebleau: Ecole des Mines de Paris, Fascicule 5, 1971. 211 p.

MATTOS JUNIOR, D. et al. **Citros: principais informações e recomendações de cultivo**. Cordeirópolis-SP. Versão eletrônica do Boletim Técnico 200 (IAC), mar. 2005. Disponível em: <<http://www.iac.sp.gov.br/Tecnologias/Citros/Citros.htm>>. Acesso em: 19 ago. 2009.

MOREIRA, C.S.; MOREIRA, S. História da citricultura no Brasil. In: RODRIGUEZ, O.; VIÉGAS, F. (Eds.) **Citricultura brasileira**, Campinas, v. 2, p. 793, 1980.

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 2. ed. Viçosa: Universidade Federal de Viçosa, 2004. 307 p.

MOREIRA, M. A. et al. Comparação da resposta espectral de alvos em imagens CBERS-2/CCD e LANDSAT-5TM. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 2005, Goiânia. **Anais ...** Goiânia: INPE, 2005. p. 1027-1034.

MOTOMIYA, A. V. A.; CORÁ, J. E.; PEREIRA, G. T. Uso da krigagem indicatriz na avaliação de Indicadores de fertilidade do solo. **Revista Brasileira de Ciências do Solo**, Viçosa, v. 30, p. 485-496, 2006.

MYERS, J. C. **Geostatistical error management**. Qualifying uncertainty for environmental sampling and mapping. New York: Van Nostrand Reinhold, 1997. 571 p.

NOVO, E. M. I. de M. **Sensoriamento remoto: princípios e aplicações**. 3. ed. São Paulo: Blucher, 2008. 363 p.

OETTER, D.R.; COHEN, W.B.; BERTERRETICHE, M.; MAIERSPERGER, T.K.; KENNEDY, R.E. Land cover mapping in an agricultural setting using multiseasonal Thematic Mapper data. **Remote Sensing of Environment**, New York, v. 76, n. 2, p. 139-155, 2000.

OLEA, R.A. **Measuring spatial dependence with semivariograms**. Lawrence: Kansas: University of Kansas, 1977. (Series on Spatial Analysis n. 2).

OLIVER, M. A., WEBSTER, R. Kriging: a method of interpolation for geographical information systems. **International Journal of Geographical Information System**, Trier, v. 4, n. 3, p. 313-332, 1990.

PERES, R.M.P. **Geoprocessamento aplicado ao desenvolvimento de uma base de dados do Município de Botucatu - SP**. 2006. 101 f. Dissertação (Mestrado em Irrigação e Drenagem)-Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2006.

PREVIDELLI, I.T.S. **Estimadores de máxima verossimilhança corrigidos para modelos superdispersados não lineares**. 2004. Tese (Doutorado em Economia)-Universidade Federal de São Carlos, São Carlos: UFSC 2004.

RAMSTEIN, G.; RAFFY, M., Analysis of the structure of radiometric remotely-sensed images. **International Journal of Remote Sensing**, Basingstoke, v. 10, p. 1049-1073, 1989.

RANSON, K. J.; BIEHL, L. L.; BAUER, M. E. Variation in spectral response of soybeans with respect to illumination, view, and canopy geometry. **LARS Technical Reports**, West Lafayette, Paper 97,1984. 27 p.

RICHARDS, J. A. **Remote sensing digital image analysis: an introduction**. Berlin: Springer-Verlag, 1986. 281 p.

RICHARDS, J.A.; JIA, X. **Remote sensing digital image analysis**. 3. ed. Berlin: Springer-Verlag, 1999. 365 p.

RIZZI, R.; RUDORFF, B. F. T. Imagens landsat na estimativa da área plantada com soja em municípios do Rio Grande do Sul. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. **Anais...** São José dos Campos: INPE, 2003. p. 231 - 238. Disponível em: <150.163.34.2:1908/rep-/ltid.inpe.br/sbsr/2002/11.18.16.47> Acesso em: 23 jun. 2003.

RIZZI, R. **Geotecnologias em um sistema de estimativa da produção de soja: estudo de caso no Rio Grande do Sul**. 2005. 216 f. Tese (Doutorado em Sensoriamento Remoto)-Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.

ROSSI, R. E.; DUNGAN, J. L.; BECK, L. R. Kriging in the shadows: geostatistical interpolation for remote sensing. **Remote Sensing of Environment**, New York, v.49, p. 32-40, 1994.

SALVIANO, A.A.C. **Variabilidade de atributos de solo e de *Crotalaria juncea* em solo degradado do município de Piracicaba-SP**. Piracicaba, 1996. 91 f. Tese (Doutorado em Agronomia) - Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo. 1996.

SANCHES, I. D.; GÜRTLER, S.; FORMAGGIO, A. R. Discriminação de variedades de citros em imagens CCD CBERS-2. **Ciência Rural**, Santa Maria, v. 38, n. 1, p. 103-108, jan-fev, 2008.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing**. 2.ed. New York: Academic Press. 1997. 522 p.

SHIMABUKURO, M. T. **Avaliação de classificadores espectrais de imagens Lansat- TM em áreas rurais densamente ocupadas: o caso da região de Brotas e Torrinha, São Paulo**. 1996. 193 f. Dissertação (Mestrado em Biologia Vegetal)-Universidade Estadual de Campinas - Campinas, 1996.

SILVA, A. P. **Variabilidade espacial de atributos físicos do solo**. 1988. 105 f. Tese (Doutorado) Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo. Piracicaba, 1988.

SILVA JÚNIOR, R. L. de. **Variabilidade espacial do índice de cone correlacionada com mapas de produtividade**. 2001. 132 f. Dissertação (Mestrado)-Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2001.

SILVEIRA, V. F. Geoprocessamento como instrumento de gestão ambiental. In: PHILIPPI JR.; ROMÉRIO, M.A.; BRUNA, G.C. **Curso de gestão ambiental**. Barueri: Nanole, 2004. p. 945-958.

SMITH, J.L.; HALVORSON, J. J.; PAPENDICK, R. I. Using multiple-variable indicator kriging for evaluating soil quality. **Soil Science Society of America**, Madison, v. 57, p. 743-749, 1993.

SOUZA, L. S. **Variabilidade espacial do solo em sistemas de manejo**. Porto Alegre, 1992. 162 f. Tese (Doutorado)-Universidade Federal do Rio Grande do Sul, Porto Alegre, 1992.

STEFFEN, C. A. **Introdução ao sensoriamento remoto**. Apostila. INPE- Divisão de Sensoriamento Remoto. Disponível em:  
<<http://www.inpe.br/unidades/cep/atividadescep/educasere/image37.gif&imgrefurl>>. Acesso em 25 mai. 2010.

STORY, M.; CONGALTON, R.G. Accuracy assessment: a user's perspective. **Photogrammetric Engineering and Remote Sensing**, Falls Church, v. 52, n. 3, p. 397-399, 1986.

STURARO, J.R. **Estudo do comportamento espacial de variáveis geológicas e hidrogeológicas da área urbana de Ribeirão Preto-SP**. 1988. 124 f. Dissertação (Mestrado), Universidade de São Paulo, São Carlos, 1988.

TEIXEIRA, A. L. A.; MORETI, E.; CHRISTOFOLETTI. **Introdução aos sistemas de informação geográfica**. Rio Claro: Edição do Autor, 1992. 80 p.

TRANGMAR, B.B.; YOST, R.S.; UEHARA, G. Application of geostatistics to spatial studies of soil properties. **Advances in Agronomy**, San Diego, v. 38, p. 45-94, 1985.

TRIETZ, P.; HOWARTH, P. High spatial resolution remote sensing data for forest ecosystem classification: an examination of spatial scale. **Remote Sensing of Environment**, New York, v. 72, p. 268-289, 2000.

UZUMAKI, E. T. **Geoestatística multivariada**: estudo de métodos de predição. 1994. 104 f. Dissertação (Mestrado em Estatística)-Instituto de Matemática, Estatística e Ciência da Computação), Universidade Estadual de Campinas, Campinas, 1994.

VALENTIN, J. L. **Ecologia numérica**: uma introdução à análise multivariada de dados ecológicos. Rio de Janeiro: Interciência, 2000. 117 p.

VALÉRIO FILHO, M.; PINTO, S. A. F. Imagens orbitais aplicadas ao levantamento de dados do meio físico: contribuição ao planejamento de microbacias hidrográficas. In: CONGRESSO BRASILEIRO E ENCONTRO NACIONAL DE PESQUISA SOBRE CONSERVAÇÃO DO SOLO, 8., 1996, Londrina. **Anais...**, Campinas: Sociedade Brasileira de Ciência do Solo, 1996. p. 77-94.

VAN DER MEER, F. Classification of remotely-sensed imagery using an indicator kriging approach-application to the problem of calcite-dolomite mineral mapping. **International Journal of Remote Sensing**, Basingstoke, v. 17, n. 6, p. 1233-1249, 1996.

VAN DER MEER, F. Geostatistical approaches for image classification and assessment of uncertainty in geologic processing. In: ATKINSON, P.M., TATE, N.J. (Eds.). **Advances in Remote Sensing and GIS Analysis**. Chichester: Wiley, 1999. p. 147-166.

VAUCLIN, M.; VIEIRA, S.R.; BERNARD, R.; HATFIELD, J.L. Spatial variability two transects of a bare soil. **Water Resources Research**, Washington, v. 18, n. 6, p 1677-1686, 1982.

VENTURIERI, A. **Segmentação de imagens e lógica nebulosa para treinamento de uma rede neural artificial na caracterização do uso da terra na Região de Tucuruí (PA)**. 1996. 115 f. Dissertação (Mestrado). Instituto Nacional de Pesquisas Espaciais, São José dos Campos: INPE, 1996. 115 p.

VENTURIERI, A.; SANTOS, J. R. Técnicas de classificação de imagens para análise de cobertura vegetal. In: Assad, E. D.; Sano, E. E. ed. **Sistemas de informação geográfica: aplicações na agricultura**. 2. ed. Brasília: Embrapa-CPAC, 1998. p. 13-29.

VERHAGEN, J.; BOUMA, J. Modeling soil variability. In: PIERCE, J.F.; SADLER, E.J., eds. **The state of sitespecific management for agriculture**. Madison, American Society of Agronomy, p. 55-68, 1997.

VIEIRA, S. R.; NIELSEN, D. R.; BIGGAR, J. W. Spatial variability of field-measured infiltration rate. **Soil Science Society of America Journal**, Madison, v. 45. p. 1040-1048, 1981.

VIEIRA, S. R.; HATFIELD, J. L.; NIELSEN, D. R.; BIGGAR, J. W. Geostatistical theory and application to variability of some agronomical properties. **Hilgardia**, Berkeley, v.51, n.3, p.1-75, 1983.

VIEIRA, S. R., HATFIELD, J. L. Temporal variability of air temperature and remotely sensed surface temperature for bare soil. **International Journal of Remote Sensing**, Basingstoke, v. 5, n. 3, p. 587-596, 1984.

VIEIRA, S. R. et al. Caracterização da variabilidade espacial de propriedades físicas. In: LOMBARDI NETO, F.; CAMARGO, O.A. **Microbacia do Córrego São Joaquim (Município de Pirassununga, SP)**. Campinas: Documento IAC n. 29, 1992.

VIEIRA, S. R. Variabilidade espacial de argila, silte e atributos químicos em uma parcela experimental de um Latossolo roxo de Campinas (SP). **Bragantia**, Campinas, v. 56, n.1, p. 1-13, 1997.

VIEIRA, S.R. **Geoestatística em estudos de variabilidade espacial**. Campinas: IAC, 1998.  
VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAIS, R. F. de; ALVAREZ V., V. H.; SCHAEFER, C. E. G. R. (Ed.). **Tópicos em ciência do solo**. Viçosa: Sociedade Brasileira de Ciência do Solo, 2000. v. 1, p. 1-54.

VIEIRA, T. G. C. et al. Crop parameters and spectral response of coffee (*coffea arabica* l.) Areas within the state of Minas Gerais, Brazil. **Coffee Science**, Lavras, v. 1, n. 2, p. 111-118, jul./dez. 2006.

WALLACE, C. S. A.; WATTS, J. M.; YOOL, S. R. Characterizing the spatial structure communities in the Mojave Desert using geostatistical techniques. **Computers & Geosciences**, Oxford, v. 26, n. 4, p. 397-410, 2000.

WEBER, E. et al. Comparação entre resultados de classificação de imagens Landsat e CBERS para estimativa de área cultivada com soja no planalto do Rio Grande do Sul. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. **Anais...** Goiânia: INPE, 2005. p. 321-328.

WEBSTER, R. Quantitative spatial analysis of soil in field. **Advances in Soil Science**, Boca Raton, v.3, p.1-70, 1985.

WOODCOCK, C. E.; STRAHLER, A. H.; JUPP, D. L. B. The use of variogram in remote sensing: scene models and simulated images. **Remote Sensing of Environment**, New York, v. 25, p. 323-348, 1988.

ZHAN, Q.; MOLENAAR, M.; LUCIEER, A. Pixel unmixing at the subpixel scale based on land cover class probabilities: application to urban areas. In: FOODY, G.M.; ATKINSON, P.M. (Eds.). **Uncertainty in remote sensing and GIS**. Chichester: Wiley, 2002. p. 59-76.

ZIMBACK, C. R. L. **Análise espacial de atributos químicos de solos para fins de mapeamento da fertilidade**. 2001. 114 f. Tese (Livro-Docência em Levantamento do solo e Fotopedologia)-Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2001.