

DISSERTAÇÃO DE MESTRADO

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM

CIÊNCIA DA COMPUTAÇÃO

**“Processamento Digital de Imagens Para
Inferência de Risco de Doença Fúngica da
Bananicultura”**

Hugo do Nascimento Bendini

ORIENTADOR: Prof. Dr. Paulo Estevão Cruvinel

São Carlos

Abril/2012

CAIXA POSTAL 676
FONE/FAX: (16) 3351-8233
13565-905 - SÃO CARLOS - SP
BRASIL

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

**PROCESSAMENTO DIGITAL DE IMAGENS PARA
INFERÊNCIA DE RISCO DE DOENÇA FÚNGICA DA
BANANICULTURA**

HUGO DO NASCIMENTO BENDINI

ORIENTADOR: PROF. DR. PAULO ESTEVÃO CRUVINEL

São Carlos - SP
Abril/2012

**Ficha catalográfica elaborada pelo DePT da
Biblioteca Comunitária da UFSCar**

B458pd Bendini, Hugo do Nascimento.
 Processamento digital de imagens para inferência de
 risco de doença fúngica da bananicultura / Hugo do
 Nascimento Bendini. -- São Carlos : UFSCar, 2013.
 134 f.

 Dissertação (Mestrado) -- Universidade Federal de São
 Carlos, 2012.

 1. Processamento de imagens. 2. Fusão de imagens. 3.
 Sensoriamento remoto. 4. Modelos de risco. 5. Krigagem. I.
 Título.

CDD: 006.42 (20ª)

Universidade Federal de São Carlos
Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

**“Processo Digital de Imagens para Inferência de
Risco de Doença Fúngica da Bananicultura”**

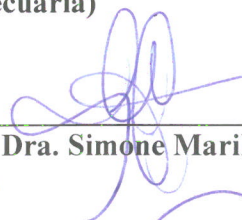
Hugo do Nascimento Bendini

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação

Membros da Banca:



Prof. Dr. Paulo Estevão Cruvinel
(Orientador – EMBRAPA/Instrumentação
Agropecuária)



Profa. Dra. Simone Marilene Sievert da Costa
(INPE)



Prof. Dr. Maurício Fernando Lima Pereira
(UFMT)

São Carlos
Junho/2012

Dedico esta dissertação à contribuição para a Ciência e ao Progresso do Brasil.

*"O homem
nada mais é do que
aquilo que ele faz de
si mesmo"*

(Jean-Paul Sartre)

AGRADECIMENTOS

Ao Professor Doutor Paulo Estevão Cruvinel, pela orientação, confiança, sabedoria e motivação à pesquisa desenvolvida.

Ao Programa de Pós-Graduação em Ciências da Computação da Universidade Federal de São Carlos – PPGCC/UFSCar, representado pelo seu Coordenador Professor Doutor Estevam Rafael Hruschka Junior.

Ao Campus Experimental de Registro, da Universidade Estadual Paulista, representado pelos Professores Doutores, Silvia Helena Modenese Gorla da Silva e Wilson da Silva Moraes, pela parceria na realização deste trabalho.

À EMBRAPA Instrumentação Agropecuária, na pessoa do Pesquisador Doutor Luiz Henrique Caparelli Mattoso, pelo acolhimento institucional.

À Coordenação de Aperfeiçoamento de Pessoal de Nível (CAPES) pelo incentivo com auxílio financeiro.

A Secretaria do PPGCC/UFSCar, pela disponibilidade e atendimento.

Aos Professores Doutores, Nelson Delfino d'Ávila Mascarenhas e José Hiroki Saito, pelas contribuições na banca de Qualificação deste trabalho.

Ao Instituto Nacional de Pesquisas Espaciais (INPE), pela disponibilização das imagens de satélite utilizadas nesse trabalho.

Ao Instituto Nacional de Meteorologia (INMET) e ao Centro Integrado de Informações Agrometeorológicas (CIAGRO), pela disponibilização das séries de dados meteorológicos utilizados nesse trabalho.

Aos meus pais, João Marcos Bendini e Teresa Cristina do Nascimento Bendini e minha irmã Juliana do Nascimento Bendini, pelo amor, apoio e incentivo incondicionais, nas minhas realizações.

À cidade de São Carlos, em especial aos colegas de convívio, pela hospitalidade e oportunidade de crescimento profissional, cultural e pessoal.

Aos produtores rurais Isaac Albanaz e seu filho Augusto Albanaz, por terem cedido à propriedade para realização da validação da metodologia.

RESUMO

O processamento de imagens digitais tem auxiliado na solução de um expressivo número de problemas do setor agrícola, sobretudo com a evolução dos sistemas de sensoriamento remoto. Este trabalho tem por objetivo apresentar um modelo computacional baseado em processamento digital de imagens e sensoriamento remoto para inferência de risco em ambiente agrícola. Para validação do método, foi realizado estudo experimental sobre o risco de ocorrência da doença fúngica em bananais. Foram utilizadas séries temporais de dados meteorológicos e de monitoramento da doença, organizados em classes para a definição de modelos de distribuição de probabilidades, baseados em funções polinomiais, bem como imagens de satélites, organizadas com técnicas de fusão, correções geométricas e re-amostragem, com interpoladores baseados em técnicas de krigagem. Foram testados os métodos de fusão por IHS (*Intensity, Hue, Saturation*) e PCA (*Principal Component Analysis*), bem como os modelos gaussiano, exponencial e cilíndrico para a krigagem ordinária. A técnica de fusão por IHS demonstrou-se mais interessante em relação à técnica por PCA, apresentando coeficientes de correlação entre as bandas 2, 3 e 4 originais e híbridadas, de 0,2318, 0,0304 e 0,1800, respectivamente. O método de krigagem ordinária para re-amostragem das imagens apresentou melhores resultados quando ajustado pelo modelo gaussiano. A metodologia proposta se apresentou viável e adequada para a elaboração de mapas de risco de ocorrência da doença, uma vez que confere variabilidade espacial e temporal ao modelo já existente na literatura para aquela região.

Palavras-chave: Processamento de Imagens, Fusão de imagens, Sensoriamento Remoto, Modelos de probabilidade, Risco climático, Sigatoka-Negra, Modelo de Risco.

ABSTRACT

The digital image processing has been used to solve a significant number of problems in the agricultural sector, especially with the evolution of remote sensing systems. This work presents a computational model based on digital image processing and remote sensing to infer about the risk in the agricultural environment. To validate the method, an experimental study was conducted about the risk of fungal disease in banana plantations. Temporal series of meteorological and monitoring data of the disease, organized in classes for the definition of probability distribution models, based on polynomial functions were used to validate results as well as satellite images integrated by fusion techniques, geometric corrections and re-sampling with interpolators based on kriging techniques. Fusion methods by IHS (Intensity, Hue, and Saturation) and PCA (Principal Component Analysis) and the Gaussian models, exponential and cylindrical for the ordinary kriging were tested. The IHS fusion technique demonstrated to be more interesting in relation to the PCA technique, with correlation coefficients between bands 2, 3 and 4 originals and hybrids, of 0.2318, 0.0304 and 0.1800, respectively. The method of ordinary kriging for re-sampling of the images showed better results when adjusted by the Gaussian model. The proposed method is feasible to the development of risk maps of disease occurrence, since it confers spatial and temporal variability in relation to the model existing in the literature for the region.

Keywords: *Image processing, Image Fusion, Remote Sensing, Models of Probability, Climatic Risk, Black Sigatoka, Risk Model.*

LISTA DE FIGURAS

Figura 1. Imagem gerada pelo Sensor CCD do satélite CBERS 2B, com resolução de 30 metros.....	29
Figura 2. Imagem do sensor HRC do satélite CBERS 2B, com resolução de 5 metros	29
Figura 3. Imagem gerada pelo sensor CCD do satélite CBERS 2B, com resolução de 30 metros.	30
Figura 4. Imagem do sensor HRC do satélite CBERS 2B, com resolução de 5 metros	30
Figura 5. Espectro eletromagnético (a) e resolução espectral (b)	31
Figura 6. Cena de imagem pancromática do sensor HRC do satélite CBERS 2B.....	32
Figura 7. Produto híbrido das bandas 3, 4, 5 do sensor CCD multiespectrais com a banda pancromática HRC, do satélite CBERS 2B.....	33
Figura 8. Detalhe de resolução radiométrica em imagem de 8 Bits do sensor CCD do satélite CBERS- 2B.	34
Figura 9. Detalhe de resolução radiométrica em imagem de 2 Bits da mesma cena, do sensor CCD do satélite CBERS 2B	34
Figura 10. Fases do processamento digital de imagens	43
Figura 11. Cubo do espaço de cores RGB	45
Figura 12. Representação gráfica do espaço IHS	46
Figura 13. Transformações de translação, rotação e escala	52
Figura 14. Ilustração da transformação espacial e mapeamento inverso da imagem registrada	55
Figura 15. O problema da re-amostragem: compatibilizar a radiometria da imagem original para uma nova distribuição de pixels.	55
Figura 16. Interpolação Bilinear	56
Figura 17. Exemplo de um semivariograma ideal.....	60
Figura 18. Diagrama de blocos da metodologia desenvolvida	64
Figura 19. Estrutura dos campos das <i>Look-Up-Tables</i>	68
Figura 20. Exemplo de figura de mérito para cálculo da área integrada	69
Figura 21. Diagrama de blocos da operação de registro de imagens	70
Figura 22. Modelo do processo de degradação da imagem.....	72
Figura 23. Organização esquemática do módulo de geoestatística do SPRING	74
Figura 24. Tela principal do sistema SPRING, com ênfase no módulo de geoestatística	75
Figura 25. Fluxograma de blocos para a operação de fusão pelo método IHS	76
Figura 26. Fluxograma de blocos para a operação de fusão pelo método PCA	77
Figura 27. Localização da área utilizada para validação do método.	82
Figura 28. Gráfico de caixa para os valores de Tmax	84
Figura 29. Ajuste do modelo para a função de probabilidades para a variável Tmax [°C].....	85
Figura 30. Gráfico de caixa para dos valores de Tmin.	87
Figura 31. Ajuste do modelo para a função de probabilidades para a variável Tmin [°C].....	87
Figura 32. Gráfico de caixa para os valores de Pp.	89

Figura 33. Ajuste do modelo para a função de probabilidades para a variável Pp [mm]	90
Figura 34. Gráfico de caixa para os valores de UR.	91
Figura 35. Ajuste do modelo para a função de probabilidades para a variável UR [%]	92
Figura 36. Gráfico de caixa para os valores de DPM.	94
Figura 37. Ajuste do modelo para a função de probabilidades para a variável DPM [h].....	94
Figura 38. Tela do SPRING para execução do registro de imagens.....	96
Figura 39. Gráfico de histograma dos dados.	98
Figura 40. Semivariogramas experimentais para diferentes direções	998
Figura 41. Semivariogramas ajustados para os modelos: (a) esférico, (b) exponencial e (c) gaussiano	100
Figura 42. Histograma do erro associado à execução da re-amostragem por krigagem ordinária.....	101
Figura 43. (a) Imagem original. (b) Imagem reamostrada pelo método do vizinho-mais-próximo. (c) Imagem reamostrada pelo método Bilinear (d) Imagem reamostrada pelo método de krigagem ordinária.....	102
Figura 44. Resultado do realce de imagens, de acordo com o histograma da imagem HR	103
Figura 45. (a) Composição BGR das bandas 2, 3 e 4 originais reamostradas.	106
(B) Composição BGR das bandas híbridas 2, 3 e 4, obtidas pelo método IHS.	106
Figura 46. (A) Composição BGR das bandas 2, 3 e 4 originais reamostradas (B) Composição BGR das bandas híbridas 2, 3 e 4, obtidas pelo método PCA.....	107
Figura 47. Recorte da área de estudo.	108
Figura 48. Modelo polinomial que estabelece a relação entre as variáveis Estado da Evolução (EE) e Nível de Cinza (NC) da banda 4 da imagem Landsat 5-TM.....	109
Figura 49. Gráfico de caixa para os valores de NC	110
Figura 50. Ajuste do modelo para a função de probabilidades para a variável NC, referente ao polinômio selecionado	111
Figura 51. Figuras de méritos para as diferentes datas.....	112
Figura 52. Mapas de risco de ocorrência da Sigatoka negra na propriedade do estudo, para a data de 22 de fevereiro de 2005	113
Figura 53. Mapas de risco de ocorrência da Sigatoka Negra na propriedade do estudo, para a data de 13 de maio de 2005.....	114
Figura 54. Mapas de risco de ocorrência da Sigatoka Negra Na propriedade de estudo, para a data de 30 de junho de 2005.....	115
Figura 55. Mapas de risco de ocorrência da Sigatoka Negra na propriedade de estudo, para a data de 16 de julho de 2005.....	116
Figura 56. Mapas de risco de ocorrência da Sigatoka Negra na propriedade de estudo, para a data de 1 de agosto de 2005.....	117
Figura 57. Mapas de risco para a data de 17 de agosto de 2005.	118

LISTA DE TABELAS E QUADROS

Tabela 1. Síntese das principais características dos satélites da série Landsat.....	37
Tabela 2. Síntese das principais características dos satélites da série CBERS	39
Quadro 1. Pontuação ou coeficiente de gravidade da sigatoka-negra em função da folha afetada	80
Tabela 3. Número de medidas N e medidas descritivas de Tmax [°C].	84
Tabela 4. Intervalos das classes, probabilidades ajustadas pelo modelo e os respectivos níveis de risco.	85
Tabela 5. Número de medidas N e medidas descritivas de Tmin [°C].	86
Tabela 6. Intervalos das classes, probabilidades ajustadas pelo modelo e os respectivos níveis de risco.	88
Tabela 7. Número de coletas e medidas para precipitação acumulada [mm].	89
Tabela 8. Intervalos das classes, probabilidades ajustadas pelo modelo e os respectivos níveis de risco.	90
Tabela 9. Número de registros e medidas descritivas de UR [%].	91
Tabela 10. Intervalos das classes, probabilidades ajustadas pelo modelo e os respectivos níveis de risco.	92
Tabela 11. Número de registros e medidas descritivas de DPM [h].	93
Tabela 12 - Intervalos das classes, probabilidades ajustadas pelo modelo e os respectivos níveis de risco.	95
Tabela 13. Estatísticas descritivas da análise exploratória.	98
Tabela 14. Estatísticas do erro associado à execução da re-amostragem por krigagem ordinária. ...	101
Tabela 15. Coeficientes de correlação entre as bandas originais reamostradas, a imagem hr e os produtos híbridos gerados pelos diferentes métodos.	104
Tabela 16. Produtos dos índices de qualidade de imagens (IQI) entre as bandas originais reamostradas e as imagens híbridas para os métodos IHS e PCA.....	105
Tabela 17. Coeficientes de correlação entre as bandas originais reamostradas e as imagens híbridas para os métodos IHS e PCA	105
Tabela 18. Número de registros e medidas descritivas de NC.....	110
Tabela 19 - Classes, intervalos e probabilidades ajustadas pelo modelo e os respectivos níveis de risco.	111
Tabela 20. Funções de distribuições ajustadas pelo modelo polinomial, para as diferentes variáveis.	112
Tabela 21. Cálculo das áreas (ha) para cada classe de risco, para a data de 22/fev/2005.....	114
Tabela 22. Cálculo das áreas (ha) para cada classe de risco para a data de 13/mai/2005.....	115
Tabela 23. Cálculo das áreas (ha) para cada classe de risco para 30/jun/2005.....	116
Tabela 24. Cálculo das áreas (ha) para cada classe de risco para 16/jul/2005.....	117
Tabela 25. Cálculo das áreas (ha) para cada classe de risco, para 01/ago/2005.....	118
Tabela 26. Cálculo das áreas (ha) para cada classe de risco, para 17/ago/2005.....	119

LISTA DE ABREVIATURAS E SIGLAS

AWiFS - *Advanced Wide Field Sensor*
CBERS - *China-Brazil Earth Resources Satellite*
CCD - *Camera Imageadora de Alta Resolução*
CIIAGRO - *Centro Integrado de Informações Agrometeorológicas*
DGI - *Divisão de Geração de Imagens*
DPM - *Duração de Período de Molhamento Foliar*
EE - *Estado de Evolução*
EOS - *Earth Observing System*
ETM - *Enhanced Thematic Mapper*
HIS - *Hue, Intensity, Saturation*
HR - *High Resolution*
HRC - *High-resolution Camera*
HRVIR - *High-Resolution Visible and Infrared*
HTML - *HyperText Markup Language*
IDE - *Integrated Development Environment*
IFOV - *Instantaneous Field of View*
INMET - *Instituto Nacional de Meteorologia*
INPE - *Instituto Nacional de Pesquisas Espaciais*
IQI - *Image Quality Index*
IRS - *Indian Remote Sensing*
LDCM - *Landsat Data Continuity Mission*
LISS - *Linear Imaging Self-Scanner*
LR - *Low Resolution*
MODIS - *MODerate resolution Imaging Spectroradiometer*
MSS - *Multispectral Scanners System*
NASA - *National Aeronautics and Space Administration*
NC - *Nível de Cinza*
ND - *Níveis digitais*
NDVI - *Normalized Difference Vegetation Index*
NIR - *Near Infra Red*
PCA - *Principal Component Analysis*
PNG - *Portable Network Graphics*
POCS - *Projeções em Conjuntos Convexos*
Pp - *Precipitação Acumulada*
RBV - *Return Beam Vidicon*
RE - *Taxa de Otimização*
REM - *Radiância eletromagnética*
RGB - *Red, Green, Blue*
SIG - *Sistema de Informações Geográficas*
SPOT - *Système d'Observation de la Terre*
SPRING - *Sistema para Processamento de Informações Georreferenciadas*
SVR - *Synthetic Variable Rate*
SWIR - *Short Wave InfraRed*
TIR - *Thermal InfraRed*
TM - *Thematic Mapper*
Tmax - *Temperatura Máxima*
Tmin - *Temperatura Mínima*
Ur - *Umidade Relativa*
USGS - *United States Geological Service*
UTM - *Universal Transverse Mercator*
WFI - *Wide Field Imager*
WGS - *World Geodetic System*

SUMÁRIO

CAPÍTULO 1 - CONTEXTUALIZAÇÃO.....	15
CAPÍTULO 2 - SENSORIAMENTO REMOTO.....	21
2.1 Introdução.....	21
2.2 Imagens de Sensoriamento Remoto.....	24
2.3 Energia Eletromagnética.....	25
2.4 Resoluções de Imagens de Satélite.....	27
2.4.1 Resolução Espacial.....	27
2.4.2 Resolução Espectral.....	30
2.4.3 Resolução Temporal.....	33
2.4.4 Resolução Radiométrica.....	33
2.5 Aplicações do Sensoriamento Remoto.....	35
2.6 Sistemas de Satélites de Sensoriamento Remoto.....	36
CAPÍTULO 3 - REGISTRO E FUSÃO DE IMAGENS.....	41
3.1 Introdução.....	41
3.2 Registro de Imagens.....	49
3.2.1 Estimativa da função de mapeamento.....	52
3.2.2 Mapeamento e Re-amostragem.....	54
3.3 Fusão de Imagens.....	62
3.3.1 Fusão IHS.....	66
3.3.2 Fusão PCA.....	70
3.3.3 Outros métodos de fusão.....	73
CAPÍTULO 4 - MODELO COMPUTACIONAL BASEADO EM PROCESSAMENTO DE IMAGENS PARA INFERÊNCIA DE RISCO DE OCORRÊNCIA DE SIGATOKA NEGRA ..	62
4.1 Introdução.....	62
4.2 Metodologia.....	63
4.2.1 Aquisição das séries temporais.....	65
4.2.2 Tratamento das Séries Temporais.....	65
4.2.3 Organização das classes de intervalos.....	66
4.2.4 Ajuste da curva de probabilidades.....	66
4.2.5 Normalização.....	67
4.2.6 Atribuição dos Níveis de Favorabilidade.....	67

4.2.7 Re-normalização.....	67
4.2.8 Cálculo do Risco.....	68
4.2.9 Processamento Digital de Imagens.....	70
4.2.9.1 Registro de imagens.....	70
4.2.9.2 Realce.....	72
4.2.9.3 Re-amostragem.....	73
4.2.9.4 Fusão das imagens.....	76
4.2.9.5 Recorte da área de interesse.....	79
4.2.9.6 Extração de Atributos.....	79
4.2.10 Mapeamento do Risco.....	81
CAPÍTULO 5 - RESULTADOS E CONCLUSÕES.....	82
5.1.1 Introdução.....	82
5.1.1.1 Temperatura Máxima (Tmax).....	83
5.1.1.2 Temperatura Mínima (Tmin).....	85
5.1.1.3 Precipitação acumulada (Pp).....	88
5.1.1.4 Umidade Relativa (UR).....	90
5.1.1.5 Duração do Período de Molhamento Foliar (DPM).....	93
5.1.2 Processamento de Imagens.....	95
5.1.2.1 Registro de Imagens.....	95
5.1.2.2 Re-amostragem.....	97
5.1.2.3 Realce de Imagens.....	103
5.1.2.4 Fusão.....	103
5.1.2.5 Recorte da Área de Interesse.....	107
5.1.2.6 Extração de Atributos.....	108
5.1.2.7 Geração dos Mapas de Risco.....	111
5.1.2.8 Visualização dos Mapas.....	113
5.2 Publicações relevantes.....	119
5.3 Trabalhos Futuros.....	120
5.4 Conclusões.....	120
CAPÍTULO 6 - REFERÊNCIAS BIBLIOGRÁFICAS.....	122

Capítulo 1

CONTEXTUALIZAÇÃO

Estimativas da incidência e severidade de doenças também podem ser obtidas em nível de campo por meio de métodos indiretos. Dentre os vários métodos utilizados, encontram-se a estimativa dos parâmetros de incidência e severidade com as técnicas de processamento de imagens e sensoriamento remoto (MAFFIA *et al.*, 2007). A interação entre a energia eletromagnética e a vegetação pode ser estudada a partir do princípio de que os vegetais extraem da radiação eletromagnética parte da energia que necessitam para viver. Dado o dossel vegetal, a folha é o principal constituinte do sistema, pois é basicamente nela que ocorrem interações da energia solar com a planta (PONZONI, 2001).

Quando os fitopatógenos infectam plantas, a absorção da luz incidente apresenta mudanças no intervalo da região do visível e do infravermelho do espectro eletromagnético. Este acontecimento é devido, provavelmente, a diminuição do teor de clorofila, alterações em outros pigmentos e a estrutura interna da folha. A mudança na absorção da luz incidente influencia na refletância de plantas infectadas. Doenças de plantas, em alguns casos, diminuem o teor de clorofila e a absorção da radiação solar incidente na planta doente, resultando em diminuição na região do visível e, conseqüentemente, a refletância, geralmente, é maior na faixa do visível (NAUE *et al.*, 2011).

A banana representa a fruta mais consumida no mundo (FAO, 2007), sendo considerado um alimento básico para diversos países. O Brasil é o quarto maior produtor mundial de bananas (FAO, 2008), porém exporta apenas cerca de 1% de

sua produção.

Existem vários fatores que afetam diretamente a produção e conseqüentemente os rendimentos. Os principais fatores estão relacionados ao manejo nutricional, controle de plantas invasoras e doenças. Sendo uma cultura que possui alta taxa de exportação de nutrientes, em um sistema onde é exigida maior produtividade, a necessidade de utilização é consideravelmente maior. Além disso, nas regiões onde o relevo é muito declivoso, é exigido que a aplicação de fungicidas seja feita por meio de aviação agrícola, o que eleva muito o custo da operação e conseqüentemente do custo de produção da banana.

A Sigatoka Negra é uma doença causada pelo fungo *Mycosphaerella fijiensis* Morelet sendo responsável por perdas de produção superiores a 50%. O primeiro registro da doença, em território brasileiro, ocorreu no estado do Amazonas no ano de 1998 e, em 2004, a doença já foi constatada em bananais do Vale do Ribeira, em São Paulo. Atualmente, encontra-se disseminada em todas as regiões produtoras do estado de São Paulo (MORAES *et al.*, 2006).

O controle da doença é feito por meio de pulverizações fungicidas e são determinadas em função do seu monitoramento, que é uma tarefa trabalhosa, custosa e exige mão de obra especializada. Uma alternativa para minimizar o controle químico é proteger a cultura no estágio em que ela encontra-se mais suscetível a doença e as condições climáticas estejam favoráveis à ocorrência de infecção pelos patógenos. Para verificar se as condições meteorológicas estão favoráveis à ocorrência dos patógenos, podem ser utilizados sistemas, que normalmente são baseados em modelos de probabilidade de combinação da ocorrência de condições biológicas e meteorológicas que afetam o desenvolvimento da doença em plantas (KRAUSE *et al.*, 1975; FERNANDES, 1996; FRY *et al.*, 1982;

JONHSON, 1987; PUGSLEY *et al.*, 2001; BENDINI *et al.*, 2010).

A influência do clima sobre as doenças se faz principalmente sob o efeito de períodos de molhamento foliar e temperaturas favoráveis durante este período (BERGER, 1989; BERGAMIN FILHO; AMORIM, 1996). Para a Sigatoka Negra na região do Vale do Ribeira, Fukuda e colaboradores (FUKUDA *et al.*, 2007) determinaram que, considerando um intervalo semanal, os valores de precipitação acumulada em até 100 milímetros, temperaturas mínimas inferiores a 18 °C (graus Celsius) e máximas inferiores as 28 °C, são desfavoráveis a seu desenvolvimento. Senhor e co-autores (SENHOR *et al.*, 2009), determinaram que a umidade relativa média semanal de 84,4% favorecem o desenvolvimento da Sigatoka Negra, na região amazônica. Cronshaw e colaboradores (CRONSHAW *et al.*, 1982), relacionaram o efeito do acúmulo de horas semanais com a umidade relativa acima de 90% com o progresso da doença e propôs que valores superiores a 60 horas são favoráveis a doença; entre 40 e 50 horas são moderadamente favoráveis; entre 10 e 40 horas são ligeiramente favoráveis e valores inferiores a 10 horas, não são favoráveis ao desenvolvimento da Sigatoka Negra. O uso de umidade relativa acima de 90% foi utilizado por Gasparotto que encontrou alta correlação entre os períodos com umidade relativa neste intervalo e os de molhamento foliar (GASPAROTTO, 1988).

Dispondo de uma rede de estações meteorológicas, localizadas às proximidades da região monitorada é possível elaborar mapas de zonas de risco de epidemias para definir um zoneamento agroclimático (CARAMORI *et al.*, 1994; PUGSLEY *et al.*, 2001; CRUVINEL *et al.*, 2002). O desenvolvimento de mapas de zonas de risco acoplados a modelos de predição pode ser útil para indicar áreas geográficas ou épocas do ano mais favoráveis à ocorrência de epidemias. A partir

dessa base de dados, sistemas computacionais podem ser utilizados para verificar se as condições meteorológicas estão favoráveis à ocorrência de infecção pelos patógenos (GHINI *et al.*, 2008; GIRALDO *et al.*, 2010).

Ghini e colaboradores avaliaram os possíveis impactos das mudanças climáticas sobre a distribuição espaço-temporal da Sigatoka-negra, por meio da elaboração de mapas de distribuição da doença confeccionados a partir dos cenários disponibilizados pelo IPCC. Para isso, médias mensais de temperatura, umidade relativa do ar e classes de favorabilidade, foram utilizadas com base nos efeitos sobre variáveis epidemiológicas. Entre os resultados, observaram que houve redução da área favorável à doença no país, mas, extensas áreas ainda continuarão favoráveis à ocorrência da doença, especialmente no período de novembro a abril (GHINI *et al.*, 2007).

Moraes e co-autores analisaram o progresso da Sigatoka-negra, durante o período de fevereiro a dezembro de 2005, numa propriedade do município de Jacupiranga (SP), região do Vale do Ribeira, e demonstraram que a severidade da doença foi mais expressiva entre os meses de novembro a março, quando foram observadas temperaturas e precipitações mais elevadas, enquanto o período menos chuvoso com temperaturas mais amenas, entre junho a dezembro, a doença foi desfavorecida. No mesmo trabalho, houve a simulação do comportamento da doença por uma função de regressão, onde às médias de temperatura máxima e mínima e a precipitação acumulada, durante uma e duas semanas antes da leitura, foram os parâmetros de entrada, obtendo-se maior correlação destes fatores com a severidade da doença com duas semanas de antecedência. Tal simulação foi realizada em um bananal específico de 15 hectares, com base nos dados de severidade e meteorológicos predominantes no bananal (MORAES *et al.*, 2006).

A utilização de imagens de satélite torna-se importante para o desenvolvimento de mapas de risco, uma vez que conferem as componentes espacial e temporal aos mesmos, ou seja, imagens de alta resolução permitem se analisar espaços menores, como pequenas propriedades rurais, bem como o fato de ser possível obter imagens de um mesmo local em datas diferentes, possibilitando a geração de mapas em função do tempo. No entanto, muitas vezes uma imagem de um sensor específico não possui todas as características desejáveis para a aplicação, fazendo-se necessário o emprego de técnicas de processamento digital de imagens, como a fusão de imagens, que trata de integrar características de diferentes sensores, em uma imagem híbrida. Tal técnica exige uma série de pré-processamento, entre eles a re-amostragem, onde as imagens são interpoladas para uma mesma grade espacial. Nesta área do conhecimento, existem diferentes métodos para se realizar a re-amostragem das imagens e entre os mais utilizados estão o método do vizinho-mais-próximo, o método bilinear e splines. Entretanto, verificou-se na literatura, que existem poucos estudos referentes ao uso de métodos baseados em técnicas da geoestatística, como a krigagem.

Sendo assim, este trabalho tem como objetivo geral, desenvolver um modelo computacional baseado em processamento digital de imagens e sensoriamento remoto para inferência de risco em ambiente agrícola, utilizando re-amostragem baseada em krigagem.

Como objetivos específicos são considerados:

- Realizar uma comparação entre os métodos de fusão IHS e PCA, para fusão de imagens multiespectrais do Landsat TM5 com imagens de alta-resolução obtidas no Google Earth, referentes a cenas do satélite

SPOT;

- Testar o método de krigagem ordinária sob os modelos de semivariograma cilíndrico, exponencial e gaussiano, para realização da re-amostragem das imagens.

Para validação do método e realização dos testes com as imagens satelitais, foi realizado um estudo de caso em uma propriedade de bananicultura, contendo uma área de 20 hectares de produção de banana, localizada no Bairro do Guaraú, município de Jacupiranga, no Vale do Ribeira, Estado de São Paulo, nas coordenadas $24^{\circ} 52' 53,8''$ de latitude sul e $48^{\circ} 06' 22,1''$ de longitude oeste.

Capítulo 2

SENSORIAMENTO REMOTO

2.1 Introdução

Segundo Florenzano, o termo sensoriamento remoto é definido como sendo o conjunto de atividades que permitem a obtenção de dados de objetos que compõem a superfície terrestre, que não estão em contato, por meio da captação e do registro da energia refletida ou emitida (FLORENZANO, 2002).

De acordo com Lillesand e Kiefer, o sensoriamento remoto ainda pode ser conceituado como a ciência e arte de receber informações sobre um objeto, uma área ou fenômeno pela análise dos dados obtidos de uma maneira tal que não haja contato direto com esse objeto, essa área ou fenômeno. As imagens de sensoriamento remoto são adquiridas por sensores orbitais, ou seja, aqueles presentes nos satélites (LILLESAND E KIEFER, 2000). O sensoriamento remoto orbital possibilita acompanhar, de modo sistemático, as mudanças na superfície da Terra e devido a esta característica tornou-se uma importante ferramenta para a obtenção de informação espaço-temporal.

Existem diferentes satélites na órbita terrestre, com diferentes aplicações, desde os satélites meteorológicos, que orbitam em maiores altitudes e coletam imagens com menor resolução espacial, porém com maior resolução temporal,

assim permitindo monitorar o tempo, como os satélites de observação da Terra, que orbitam em altitudes menos elevadas, possibilitando a geração de imagens com maior resolução espacial, entretanto, com menor resolução temporal.

A integração de dados reais de campo com dados de sensoriamento remoto pode ser realizada utilizando um sistema de informação geográfica (SIG). Tais sistemas fornecem ferramentas computacionais para que diferentes analistas integrem dados geográficos e determinem possíveis mudanças espaciais e temporais de fenômenos naturais ou antrópicos em um espaço geográfico, bem como as inter-relações entre diferentes fenômenos de uma forma detalhada e abrangente (CÂMARA *et al.*, 1993). Segundo Tomlin, a modelagem cartográfica é uma metodologia para análise e síntese de dados geográficos, baseada em operações algébricas aplicadas a mapas representadas na forma matricial (TOMLIN, 1991).

Os dados de sensoriamento remoto processados em um SIG podem ser analisados de diversas maneiras, via interpretação visual ou automaticamente através de algoritmos de classificação com bases na resposta espectral de pixels ou regiões homogêneas conforme relatou Crosta, relacionando essas informações com o processamento digital de imagens (CROSTA, 1992).

A quantidade de informações geradas por estes sensores cria um ambiente favorável ao desenvolvimento de diversas aplicações na área do sensoriamento remoto. Dessa forma surge a necessidade de técnicas para sintetizar e combinar as informações a fim de reduzir a quantidade de dados e produzir imagens de melhor qualidade. Dentro desse contexto, as técnicas de fusão de imagens têm sido utilizadas para combinar as informações de diferentes fontes e produzir imagens sintéticas que integram as melhores características das imagens.

Na agricultura, por exemplo, o sensoriamento remoto aliado ao geoprocessamento constitui-se como uma tecnologia importante no apoio ao levantamento de dados, permitindo estudos e o entendimento das relações ambientais em que uma determinada cultura está inserida.

Existem diversos trabalhos que demonstram a importância da utilização de geotecnologias no estudo da aptidão agrícola de terras, manejo de bacias hidrográficas, estudo e modelagem de relevo, análise ambiental de espaços geográficos e zoneamento ecológico econômico. Todos relevam a importância de imagens orbitais como suporte a extração de dados temáticos (FELGUEIRAS *et al.*, 1988; KURKDJIAN *et al.*, 1992; ZIMBACK, 1997; VENTURIERI, 1999; CREPANI *et al.*, 2001; CREPANI E MEDEIROS, 2004).

A origem do sensoriamento remoto da forma como conhecemos hoje, com a obtenção de imagens da superfície da Terra, se deu em 1858, quando Gaspard Felix Tournachon tirou uma fotografia aérea a partir de um balão (JENSEN, 2009). Sabe-se também que há pouco mais de 100 anos, pombos com câmeras fotográficas amarradas em seus peitos eram utilizados para a tomada de fotografias aéreas (RUDORFF *et al.*, 2009).

Entretanto, o sensoriamento remoto orbital, com a aquisição sistemática de imagens da superfície terrestre, teve início com o lançamento do primeiro satélite norte-americano da série Landsat, em 1972. Este satélite possuía a bordo os sensores MSS e RBV, para captar a energia eletromagnética refletida pelos alvos na superfície da Terra (JENSEN, 2009). O Brasil foi o terceiro país do mundo a se capacitar para adquirir imagens do Landsat em julho de 1973, completando em 2009, 36 anos de aquisição de imagens sobre todo o território brasileiro a partir da antena de recepção de dados do INPE, localizada em Cuiabá-MT.

2.2 Imagens de Sensoriamento Remoto

As imagens de sensoriamento remoto são constituídas por um arranjo de pixels sob a forma de uma malha ou grade (grid). Cada célula dessa grade tem uma localização definida por um sistema de coordenadas “linha e coluna” representadas por “x” e “y”, respectivamente. Por convenção, a origem desse plano é sempre o canto superior esquerdo. Para um mesmo sensor remoto, cada pixel representa sempre uma área com as mesmas dimensões na superfície da Terra. As demais características de imagem, utilizadas nas definições e operações com imagens digitais, também se aplicam para as imagens de sensoriamento remoto.

De acordo com Rosenfeld e Kak, quando uma cena é vista de um determinado ponto, a luz recebida pelo observador varia em função de fatores como coordenadas angulares de iluminação e posição do observador (geometria de aquisição); reflectância do alvo e características da iluminação (ROSENFELD E KAK, 1982).

Em um instrumento óptico os raios de luz de cada ponto da cena, dentro do campo de visada, são coletados por uma lente e direcionados ao ponto correspondente da imagem. Pontos na cena a diferentes distâncias da lente (coletor) vão dar origem a pontos em diferentes distâncias na imagem. Porém, quando a cena está muito distante do sensor os pontos da imagem formam-se aproximadamente no mesmo plano, dito plano focal.

O imageamento consiste então, em transformar uma informação da cena em padrão de iluminação no plano da imagem. O padrão de iluminação da cena pode ser gravado ou medido colocando-se algum tipo de detector no plano da imagem.

Cada detector tem uma responsividade espectral característica, isto é, sua resposta varia com a cor da luz. A resposta total (γ) em um dado ponto (λ) pode ser expressa por uma integral na forma:

$$\gamma = \int_0^{\infty} R(\lambda)\Phi(\lambda)d\lambda \quad (1)$$

onde $\Phi(\lambda)$ é o fluxo radiante da luz e $R(\lambda)$ a responsividade em função do comprimento de onda (*American Society of Photogrammetry, 1983*). Isto significa que quando se usa apenas um detector esta se representando a informação da cena por um valor de brilho para cada pixel.

2.3 Energia Eletromagnética

Os principais conceitos envolvidos no sensoriamento remoto estão relacionados à energia eletromagnética que é refletida pelos objetos. Essa energia varia em diferentes comprimentos de ondas e os satélites são capazes de absorver energia em diferentes faixas de comprimento de onda, chamadas bandas espectrais.

A quantidade de bandas espectrais de um satélite é o que determina a resolução multiespectral do mesmo. Como os objetos das cenas podem refletir energia em diferentes comprimentos de onda, quanto maior a resolução espectral de um sensor, ou seja, quanto maior o número de bandas, melhor a capacidade de visualizar separadamente, em cada banda, diferentes objetos.

Para se obter essas informações, usa-se um meio, que neste caso é a radiação eletromagnética, supondo que esta possa incidir diretamente ao sensor. No entanto, isto não é possível para todas as regiões do espectro eletromagnético,

porque a transmissividade atmosférica é variável para diversos comprimentos de onda (ENVI, 2000). O grau de transmissividade representa a capacidade das ondas eletromagnéticas penetrarem na atmosfera.

A radiação eletromagnética é emitida por qualquer corpo que possua temperatura absoluta superior ao zero absoluto (zero Kelvin). Tal radiação não precisa de um meio material para se propagar, sendo definida como uma energia que se move na forma de ondas eletromagnéticas na velocidade da luz (300.000 km/s).

Segundo Novo, sob uma perspectiva quântica a radiação eletromagnética (REM) é concebida como o resultado da emissão de pequenos pulsos de energia, enquanto sob uma perspectiva ondulatória, a REM se propaga pela oscilação dos campos, elétrico e do campo magnético (NOVO, 1989). No modelo ondulatório, a REM é caracterizada em comprimentos de onda que representam a distância entre dois pontos de igual intensidade dos campos, elétrico e magnético.

A energia eletromagnética pode ser ordenada de maneira contínua em função do seu comprimento de onda ou de sua frequência, sendo essa disposição denominada espectro eletromagnético. De acordo com Brys, cada subdivisão é função do tipo de processo físico que dá origem a energia eletromagnética, do tipo de interação que ocorre entre a radiação e o objeto sobre o qual esta incide e da transparência da atmosfera em relação à radiação eletromagnética (BRYs, 2008).

Os objetos da superfície terrestre como a vegetação, a água e o solo podem refletir, absorver e transmitir a radiação eletromagnética em proporções que variam com o comprimento de onda, de acordo com as suas características biológicas, físicas e químicas. As variações da energia refletida pelos objetos podem ser representadas através de curvas espectrais.

Outro conceito está relacionado à frequência de amostragem, ou seja, a frequência em que o sensor é capaz de discretizar a intensidade eletromagnética em níveis digitais, o que determina o tamanho do pixel produzido, ou seja, sua resolução espacial.

O que determina a frequência de amostragem e o número de bandas espectrais é a quantidade de energia que o sensor é capaz de coletar em cada ciclo de amostragem. Isso está relacionado com o tamanho e complexidade dos sistemas eletrônicos dos sensores. Assim, existe um compromisso entre resolução espectral e espacial, de modo que atualmente não existem sensores de satélites capazes de conciliar ambas as características de uma só vez. Por isso, muitos satélites possuem dois sensores, sendo um específico para gerar imagens multiespectrais e outro para gerar imagens de melhor resolução espacial, porém com uma banda apenas, com ampla faixa de comprimento de onda, conhecida como banda pancromática.

2.4 Resoluções de Imagens de Satélite

As características das imagens de sensoriamento remoto variam de acordo com o sensor utilizado nos satélites. Os principais aspectos são relacionados às resoluções radiométrica, espacial, espectral e temporal.

2.4.1 Resolução Espacial

De acordo com Rudorff e co-autores, o conceito de resolução espacial pode descrever de diferentes maneiras as características de um sistema imageador. No

caso mais simples, resolução espacial pode ser definida como a menor distância entre dois objetos que um sensor pode gravar distintamente. A maneira de medir esta grandeza varia com o tipo de sensor em estudo, não havendo possibilidade de converter as medidas de um sensor para outro (RUDORFF *et al.*, 2009).

Segundo o Manual de Sensoriamento Remoto publicado pela Sociedade Americana de Fotogrametria, a definição de resolução espacial pode ser enquadrada em uma das quatro categorias (APRS, 1983):

- a) Propriedades geométricas do sistema imageador;
- b) Capacidade de distinção entre alvos pontuais;
- c) Capacidade de medir a periodicidade de alvos repetidos;
- d) Capacidade de medir propriedades espectrais de pequenos objetos finitos.

Segundo Florenzano, o efeito da resolução espacial baseia-se na projeção geométrica do detector na superfície terrestre, definindo sua área do campo de visada do instrumento numa certa altitude e num determinado instante. O ângulo definido por esta projeção é denominado campos de visada instantânea (*Instantaneous Field of View – IFOV*). O IFOV define a área do terreno focalizada a uma dada altitude pelo instrumento sensor (FLORENZANO, 2002).

Segundo Begni e colaboradores, a resolução espacial, em termos de propriedades geométricas do sistema imageador é usualmente descrita como campo de visada instantaneamente (IFOV). Esta grandeza é função da altitude da órbita do satélite, tamanho do detector e distância focal do sistema óptico. O ângulo sólido, que descreve o IFOV, quando projetado sobre a cena nos dá a resolução em termos geométricos (BEGNI *et al.*, 1985). As Figuras 1 e 2 apresentam em detalhe a resolução espacial de imagens do satélite CBERS 2B, de sensores diferentes, onde é possível se observar a diferença no tamanho do pixel.



Figura 1. Imagem gerada pelo sensor CCD do satélite CBERS 2B, com resolução de 30 metros.




Figura 2. Imagem do sensor HRC do satélite CBERS 2B, com resolução de 5 metros.

Nas Figuras 3 e 4 as imagens da mesma área são apresentadas, com resoluções diferentes, onde é possível notar a diferença na discriminação de detalhes espaciais.



Figura 3. Imagem gerada pelo sensor CCD do satélite CBERS 2B, com resolução de 30 metros.



Figura 4. Imagem do sensor HRC do satélite CBERS 2B, com resolução de 5 metros.

2.4.2 Resolução Espectral

A resolução espectral é definida pelo número de bandas espectrais de um sistema sensor e pela largura do intervalo de comprimento de onda coberto por cada banda. Segundo Novo, a resolução espectral é uma medida da largura das faixas

espectrais e da sensibilidade do sistema sensor em se distinguir dois níveis de intensidade do sinal de retorno (NOVO, 1989). Na Figura 5 são mostrados os comprimentos de onda de alvos diferentes, detectados pelas bandas de dois sensores.

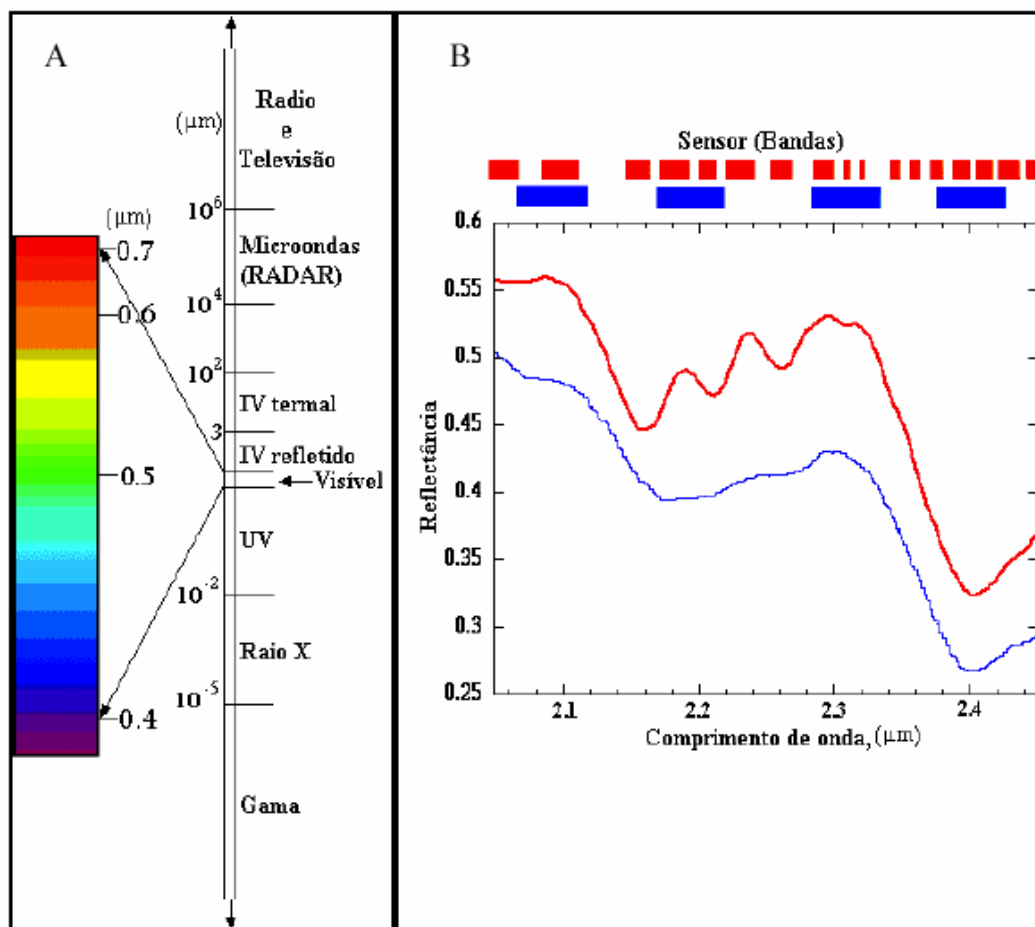


Figura 5. Espectro Eletromagnético (A) e Resolução espectral (B).

(Fonte: JENSEN E JACKSON, 2001).

De acordo com Jensen e Jackson destacam dois pontos importantes: o comprimento da onda detectado pelo sensor e a quantidade de faixas espectrais. Diferentes tipos de superfície (cobertura vegetal, alvos urbanos, água) refletem a energia em diferentes intervalos de comprimento de onda, o que permite que quanto

maior o número de bandas, mais detalhes podem ser distinguidos pela informação espectral (JENSEN E JACKSON, 2001).

Como pode ser observado na Figura 5, o comportamento da onda eletromagnética depende do seu comprimento de onda. Frequências altas são curtas e as baixas são longas. A faixa do visível está compreendida entre 0,4 μm a 0,7 μm . No entanto, as outras faixas de comprimento de onda permitem a identificação de alvos que não são visíveis ao ser humano.

Quanto maior o número de bandas e menor a largura de intervalo, maior a discriminação do objeto na cena e melhor a resolução espectral.

Nas Figuras 6 e 7 são ilustradas as diferenças entre as características de imagens com diferentes resoluções espectrais.



Figura 6. Cena de imagem pancromática do sensor HRC do satélite CBERS 2B.



Figura 7. Produto híbrido das bandas 3, 4, 5 do sensor CCD multiespectrais com a banda pancromática HRC, do satélite CBERS 2B.

2.4.3 Resolução Temporal

A resolução temporal, que é o tempo em que o satélite leva para dar uma volta completa em sua órbita determina o intervalo em que se pode obter uma imagem de uma mesma área. Este ciclo está relacionado a características orbitais como altitude, velocidade, inclinação e ao ângulo total de abertura do sensor. A resolução temporal é de grande interesse especialmente em estudos relacionados a mudanças de paisagem na superfície terrestre e ao seu monitoramento.

2.4.4 Resolução Radiométrica

A resolução radiométrica é dada pelo número de níveis digitais, que representam níveis de cinza, utilizados para expressar os dados coletados pelo sensor. Quanto maior o número de níveis, maior é a resolução radiométrica. Nas

Figuras 8 e 9 são ilustradas as diferenças entre as características de imagens com diferentes resoluções radiométricas.




Figura 8. Detalhe de resolução radiométrica em imagem de 8 bits do sensor CCD do satélite CBERS-2B.




Figura 9. Detalhe de resolução radiométrica em imagem de 2 bits, da mesma cena, do sensor CCD do satélite CBERS-2B.

Como visto anteriormente, segundo Brys a radiância de cada pixel passa por uma codificação digital, obtendo um valor numérico, expresso em bits, denominado de número digital (ND) (BRYs, 2008). De acordo com Schowengerdt este valor é facilmente traduzido para uma intensidade visual ou ainda, a um nível de cinza, localizado num intervalo finito $[0, k-1]$, onde k é o número de níveis de quantização (SCHOWENGERDT, 1983).

2.5 Aplicações do Sensoriamento Remoto

Considerando estas características, as imagens possuem diferentes qualidades para diferentes aplicações. Porém, muitas vezes são necessárias imagens que integrem diferentes tipos de resoluções, por exemplo, no caso mais comum, imagens que possuam alta resolução espacial e espectral.

Entre as diversas aplicações das imagens de sensoriamento remoto, podem ser citadas, por exemplo: o mapeamento da cana-de-açúcar (RUDORFF *et al.*, 2007b); o estudo da geomorfologia (FLORENZANO, 1998); o mapeamento do solo (ZEILHOFER, 2006); o estudo das condições de umidade do solo (DARCH, 1979), bem como o monitoramento da cobertura vegetal e uso da terra (SHIMABUKURO E RUDORFF, 2006). Outras aplicações relevantes são estudos realizados visando a previsão de safras e estimativa de área de cultivo de culturas agrícolas.

Epiphany e colaboradores propuseram um método amostral aleatório simples para a quantificação de áreas de soja e milho. Com base na interpretação não exaustiva das áreas de soja e milho, de uma imagem Landsat-5, contabilizaram-se as áreas parciais. Amostraram-se diversos pontos sobre a imagem, aos quais foram

atribuídas as classes de uso. Pela simulação de subconjuntos e assumindo uma distribuição hipergeométrica pôde-se avaliar o nível de variabilidade das estimativas em função dos tamanhos de amostras. A amostragem com base na estrutura das imagens de satélite permitiu um levantamento ágil e com conhecida precisão da área cultivada com grandes culturas no município (EIPHANIO *et al.*, 2002).

Trabaquini e coautores realizaram um trabalho onde se objetivou relacionar as variáveis físicas, como, altimetria, declividade e tipo de solo com o agrossistema pelo uso de geotecnologias. Foi utilizada a imagem do satélite LANDSAT 5/TM (*Thematic Mapper*) e o software SPRING (CÂMARA *et al.*, 1996) (TRABAQUINI *et al.*, 2010).

2.6 Sistemas de Satélites de Sensoriamento Remoto

O Brasil recebe, atualmente, imagens dos satélites Landsat, IRS-P6 (*Resourcesat-1* – sensores AWiFS e LISS-III), CBERS, Terra-MODIS e Aqua-MODIS, entre outros, para todo o território brasileiro e boa parte da América do Sul, através de uma antena de recepção localizada no centro geométrico da América do Sul, em Cuiabá-MT. Imagens de outros satélites como, por exemplo, o IKONOS II e *RapidEye*, podem ser adquiridas sobre o Brasil através de um gravador de bordo dos satélites e posterior transmissão dos dados para uma estação de recepção localizada em outra parte do planeta. Toda essa variedade de imagens possibilita aplicações diversas, inclusive em biomas específicos.

De acordo com Rudorff e colaboradores o programa norte-americano Landsat provavelmente é o programa de sensoriamento remoto mais conhecido e difundido

em todo o mundo. Este programa tem como principal característica o grande acervo de imagens da superfície do globo terrestre.

Apenas o satélite Landsat-5, lançado em 1984 e operando até os dias atuais, já coletou mais de 700 mil imagens da Terra, segundo a *United States Geological Service – USGS* (2009). O último satélite da série foi lançado em 15 de abril de 1999 (Landsat-7) e operou normalmente até maio de 2003. Segundo a *National Aeronautics and Space Administration – NASA* (2008), o programa Landsat terá continuidade, com um novo satélite previsto para ser lançado em 2012, quando o programa completará 40 anos de existência. Esta nova etapa do programa Landsat foi denominada *Landsat Data Continuity Mission* (LDCM) (RUDORFF *et al.*, 2009). A Tabela 1 mostra uma síntese sobre os satélites da série Landsat.

Tabela 1. Síntese das principais características dos satélites da série Landsat (RUDORFF *et al.*, 2009).

Satellite ¹	Sensor ²	Resolução Espacial (m)	Bandas ³	Resolução Temporal	Lançamento
Landsat 1	MSS	56 x 79	B, G, R, NIR	18 dias	27/07/1972
Landsat 2	RBV	80	B-G, G-R, R-NIR		22/01/1975
Landsat 3	MSS	56 x 79	B, G, R, NIR	18 dias	05/03/1978
	RBV	20 x 25	PAN		
Landsat 4	MSS	56 x 79	B, G, R, NIR	16 dias	16/07/1982
	TM	30 (120 TIR)	B, G, R, NIR, SW11R, TIR		
Landsat 5	MSS	56 x 79	B, G, R, NIR	16 dias	01/03/1984
	TM	30 (120 TIR)	B, G, R, NIR, SW11R, SWIR2, TIR		
Landsat 7	ETM+	30 (60 TIR)	B, G, R, NIR, SW11R, SWIR2, TIR	16 dias	15/04/1999

¹ Landsat-6 foi perdido no lançamento, em 5 de outubro de 1993.

² MSS: *Multi-Spectral Scanner*; RBV: *Return Beam Vidicon*; TM: *Thematic Mapper*; ETM+: *Enhanced Thematic Mapper plus*.

³ B: *Blue* (azul); G: *Green* (verde); R: *Red* (vermelho); NIR: *Near InfraRed* (infravermelho próximo); SWIR: *Short Wave InfraRed* (infravermelho de ondas curtas); TIR: *Thermal InfraRed* (infravermelho termal); PANchromatic (pancromática).

	ETM+	15 BAN	B, G, R, NIR		
--	------	--------	--------------	--	--

Atualmente, encontra-se em operação normal apenas o Landsat-5 com o sensor *Thematic Mapper* (TM). Esse possui a capacidade de imagear nas regiões do visível, infravermelho próximo (NIR: *Near InfraRed*), infravermelho de ondas curtas (SWIR: *Short Wave InfraRed*) e infravermelho termal (TIR); todos com 8 bits (256 níveis) de resolução radiométrica.

O programa CBERS (*China-Brazil Earth Resources Satellite*), resultante do acordo entre Brasil e China foi iniciado em 1988 e tem como principal elemento de missão o monitoramento da superfície terrestre (CBERS, 2009). As imagens dos satélites da série CBERS têm sido usadas em várias aplicações em sensoriamento remoto tais como monitoramento de desmatamento e queimadas na Amazônia Legal, monitoramento de recursos hídricos, áreas agrícolas, crescimento urbano, ocupação do solo, educação e outras aplicações (SILVA *et al.*, 2009 (b), NASCIMENTO *et al.*, 2009, ALCANTARA, *et al.*, 2009, SAITO *et al.*, 2009). O satélite CBERS-2B, lançado em setembro de 2007, possui uma câmera pancromática de alta resolução (*HRC – High Resolution Camera*) com resolução espacial nominal de 2,7 m, uma câmera multiespectral (CCD) com 20 metros de resolução espacial nominal, além do Imageador de Amplo Campo de Visada (*WFI Wide Field Imager*), com 260 m de resolução espacial nominal. Imagens da câmera HRC podem ser fusionadas com as imagens da câmera CCD para gerar produtos híbridos que permitam mapear fragmentos de vegetação arbórea com melhor acuidade. Os satélites CBERS 3 e CBERS 4 estão com lançamento previsto para os próximos anos. Estes apresentarão um novo instrumento a bordo: a câmera MUX, que terá 20 metros de resolução espacial e está sendo totalmente desenvolvida e produzida no Brasil.

A Tabela 2 apresenta uma síntese sobre os satélites da série CBERS.

Tabela 2. Síntese das principais características dos satélites da série CBERS (RUDORFF *et al.*, 2009).

Satélite	Sensor ⁴	Resolução Espacial (m)	Bandas ⁵	Resolução Temporal	Lançamento
CBERS 1	CCD	20	B, G, R, NIR, PAN	26 dias	14/10/1999
CBERS 2	IRMSS	80 (160 TR)	PAN, SWIR 1, SWIR 2, TIR	26 dias	21/10/1975
	WFI	260	R, NIR	5 dias	
CBERS 2B	CCD	20	B, G, R, NIR	26 dias ⁶	05/03/1978
	HRC	2,5	PAN	130 dias	
	WFI	80	R, NIR	5 dias	

Dois outras séries de satélites de SR de particular relevância para o Brasil são: a série SPOT (*Satellite Pour l'Observation de la Terre*) dos franceses e a série IRS (*Indian Remote Sensing*) dos indianos.

O Brasil, por meio da Divisão de Geração de Imagens (DGI) do INPE, capacitou sua antena de recepção para receber, a partir de 1988, imagens dos satélites SPOT 1, 2 e 3, bem como em 1999 capacitou-se a receber também imagens do SPOT 4 (sensor HRVIR). Entretanto, devido aos elevados preços, a demanda por imagens SPOT foi muito pequena no Brasil e a aquisição das mesmas ficou restrita às encomendas feitas pelos usuários, resultando em um acervo de imagens bastante limitado. Atualmente, as imagens do SPOT (inclusive SPOT 5) são comercializadas pela iniciativa privada.

O programa indiano de satélites de observação da Terra iniciou-se em 1988 com o lançamento do IRS-1A. O Brasil negociou com a Índia um acordo para

⁴ CCD: high resolution CCD camera; IRMSS: Infra-Red MultiSpectral Scanner; WFI: Wide Field Imager; HRC: High-Resolution panchromatic Camera.

⁵ B: *Blue* (azul); G: *Green* (verde); R: *Red* (vermelho); NIR: *Near InfraRed* (infravermelho próximo); SWIR: *Short Wave InfraRed* (infravermelho de ondas curtas); TIR: *Thermal InfraRed* (infravermelho termal); PAN*chromatic* (pancromática).

⁶ Variável devido à capacidade de visada lateral.

recepção e distribuição das imagens do satélite IRS-P6 (*Resourcesat-1*). O acordo foi efetivado em setembro de 2009 e desde então o Brasil está capacitado a receber e distribuir imagens do território brasileiro captadas pelos sensores AWiFS e LISS-III a bordo do Resourcesat-1, que possuem resoluções radiométricas de 10 e 7 bits, respectivamente.

O programa espacial denominado *Earth Observing System* (EOS) lançou, nos anos 1999 e 2002, dois satélites: Terra (EOS-AM) e Aqua (EOS-PM), respectivamente. Ambos os satélites possuem um sensor de grande aplicabilidade para o monitoramento de sistemas terrestres, aquáticos e atmosféricos: o sensor MODIS (*MODerate Resolution Imaging Spectroradiometer*). Esse sensor possui 32 bandas espectrais, imageando no intervalo espectral de comprimento de onda de 0,4 a 14,4 micrometros. A resolução espacial varia entre 250, 500 e 1000 metros. Além das bandas espectrais, os dados deste sensor também são disponibilizados em forma de produtos, como índices de vegetação, por exemplo. O MODIS alia moderada resolução espacial com alta resolução temporal (1 dia). Mais informações a respeito do MODIS e suas aplicações podem ser encontradas em documentos preparados por Rudorff e colaboradores (RUDORFF *et al.*, 2007a).

Capítulo 3

REGISTRO E FUSÃO DE IMAGENS

3.1 Introdução

Uma imagem digital é uma representação visual de uma cena, onde sua energia luminosa refletida e/ou emitida é captada por um sensor e discretizada em níveis digitais. Segundo Gomes e Velho (GOMES E VELHO, 1994), um sinal se manifesta a partir da variação de uma determinada grandeza física em relação ao espaço ou ao tempo.

Uma imagem pode também ser definida como um sinal, cuja variação se dá na cor dos diversos pixels do plano. Um sinal pode ser representado por um objeto matemático que estabeleça a variação da grandeza física.

Nos modelos funcionais, um sinal é representado por uma função $f:U \subset R^m \rightarrow R^n$, ou seja, a grandeza física do sinal é representada por um vetor n -dimensional que varia em um espaço com m graus de liberdade.

Chama-se espaço de sinais a um subespaço de funções $\{f:U \subset R^m \rightarrow R^n\}$ com U , m e n fixos. Portanto, um espaço de sinais é um espaço de funções, ou seja, naturalmente, um espaço vetorial em relação às operações matemáticas usuais.

No modelo espacial, dada uma função $f:U \subset R^m \rightarrow R^n$, o subconjunto U representa a região do espaço no qual varia a grandeza física. Por essa razão, U é

chamado de domínio do espaço. A grandeza física é representada por um vetor R^n e a lei de definição da função f fornece as regras de variação da grandeza. A dimensão m do domínio determina a dimensão do sinal. No caso da imagem, U é um subconjunto do plano euclidiano R^2 e a função f associa a cada ponto p do plano o vetor $f(p)$ que fornece a informação de cor em p .

Uma imagem monocromática digital é uma matriz de números inteiros, cujos elementos são chamados de pixels (binários 0 ou 1 ou em níveis de cinza entre 0 e 255). Em uma imagem digital colorida no sistema RGB (do inglês *Red*, *Green* e *Blue*), pode-se considerar um pixel como um vetor de cor cujas componentes representam as intensidades de vermelho, verde e azul. Pode-se considerar que a imagem colorida é a composição de três imagens monocromáticas, da forma $f(x,y)=f_r(x,y)+f_g(x,y)+f_b(x,y)$, onde $f_r(x,y)$, $f_g(x,y)$ e $f_b(x,y)$ são, respectivamente, as intensidades das componentes, vermelho (R), verde (G) e azul (B) da imagem no plano (x,y) . As imagens $f_r(x,y)$, $f_g(x,y)$ e $f_b(x,y)$ são denominadas, respectivamente, de banda vermelha, banda verde e banda azul da imagem em cores.

Deste modo, o processamento de imagens consiste em corrigir, ajustar e extrair características de imagens, permitindo a análise e classificação das mesmas de acordo com uma determinada aplicação.

O processamento de imagens e sinais tem sido aplicado em diversas áreas, tais como: medicina, cartografia, indústria, agricultura e outros (MERIAUDEAU *et al.*, 1996; CRUVINEL *et al.*, 1996; TRAINA Jr., 1997; BUENO, 2001; MODENESE, 2008).

O processamento digital de imagens envolve as fases de aquisição da imagem, pré-processamento, segmentação e análise (GONZALEZ E WOODS, 2000).

Conforme ilustrado na Figura 10, na aquisição das imagens, os sinais eletromagnéticos são captados por um sensor e, convertidos do analógico para o digital, através do processo de quantização em níveis digitais e armazenados na memória de um computador.

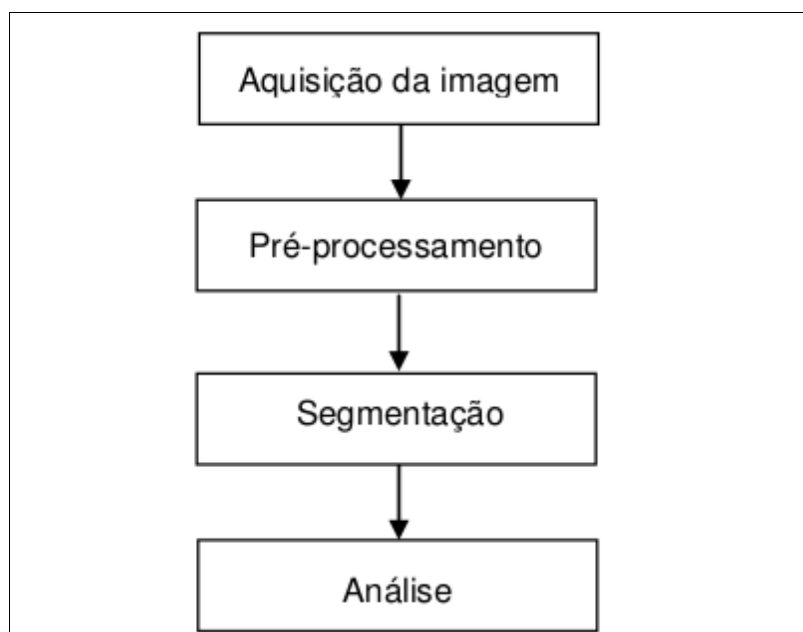


Figura 10. Fases do Processamento Digital de Imagens. (GONZALEZ E WOODS, 2000).

O pré-processamento consiste de técnicas necessárias para corrigir e ajustar as imagens, de modo a melhorar sua qualidade. Após a digitalização e armazenamento da imagem, as técnicas de pré-processamento consistem na maioria das vezes na utilização de funções lineares e não-lineares na composição de métodos de ajuste de histograma para melhoramento do contraste, restauração de imagens, remoção de ruídos, re-amostragem de pixels, entre outras (HWANG *et al.*, 2004; HSITMG-CHANG *et al.*, 2009; WANG *et al.*, 2010). As técnicas de pré-processamento envolvem duas categorias principais que podem operar nos domínios espacial ou da frequência. Segundo Nevatia e colaboradores, a segmentação é a operação de separar os componentes de uma imagem em

subconjuntos que correspondem a objetos ou regiões, cuja classificação tem por finalidade agrupar cada objeto em diferentes categorias. Os métodos clássicos de segmentação estão divididos em três grandes grupos: limiarização, segmentação por bordas e segmentação por regiões (NEVATIA *et al.*, 1986). Outras abordagens têm sido utilizadas, como o uso de redes neurais, algoritmos genéticos ou técnicas de análise multivariada de dados (ZHAO *et al.*, 2008; RISTIC *et al.*, 2008; AWAD *et al.*, 2010).

Uma vez segmentados os objetos de interesse e efetuados os processamentos básicos, a última etapa para completar o estudo pelo processamento de imagens é a análise. Nessa fase, buscam-se extrair informações úteis e relevantes para cada aplicação desejada (SIMARD *et al.*, 2000; BENEDKTSOHN *et al.*, 2005; KIM *et al.*, 2009).

Um conceito importante a ser abordado trata sobre modelos de representação de cores. De acordo com Gonzalez e Woods, o propósito de um modelo de cores é facilitar a especificação das cores em alguma forma padrão e de aceitação geral. Essencialmente, um modelo de cor é uma especificação de um sistema de coordenadas tridimensionais e um subespaço dentro deste sistema onde cada cor é representada por um único ponto (GONZALEZ E WOODS, 2000).

De acordo com Centeno e co-autores, para visualização de dados espectrais usando um computador é necessário associar às leituras do contador digital em diferentes bandas as intensidades de cor no monitor. As cores podem ser representadas por um vetor tridimensional e os valores digitais possíveis dependem da resolução radiométrica da imagem. Para uma imagem de 8 bits, assume-se a forma de um cubo de 256 valores digitais em cada eixo (Figura 11) (CENTENO *et al.*, 2007).




Figura 11. Cubo do espaço de cores RGB (GONZALEZ E WOODS, 2000).

Com o objetivo de descrever as cores usando termos mais comuns aos seres humanos, foi criado o sistema IHS (*Intensity, Hue, Saturation*). Segundo Harris e Murray, a intensidade (*Intensity*) corresponde ao total de energia incidente em todos os comprimentos de onda percebidos pelo olho. O matiz (Hue) ou tonalidade é o aspecto colorido da impressão visual, que corresponde ao estímulo da retina por determinados comprimentos de onda. A saturação (*Saturation*) se refere ao grau de pureza da cor predominante, ou também é descrita como o conteúdo de branco de um estímulo percebido (HARRIS E MURRAY, 1990).

Schowengerdt compara os sistemas IHS e RGB. Ele relata que a intensidade pode ser estimada pela média das componentes R, G e B. A saturação é medida como o afastamento da cor em relação à diagonal principal (SCHOWENGERDT, 1983). A tonalidade é a medida angular entre a linha que une a diagonal principal e a cor vermelha pura e a linha que une a diagonal principal e a cor em questão. Para a determinação do ângulo associado à tonalidade, é conveniente projetar ambas as linhas num plano perpendicular à diagonal principal (Figura 12).




Figura 12. Representação gráfica do espaço IHS (GONZALEZ E WOODS, 2000).

Os principais modelos encontrados na literatura são os descritos por Pratt (PRATT, 1991) e Gonzalez e Woods (GONZALEZ E WOODS, 2000), que diferem principalmente na escolha do sistema de coordenadas (cilíndrico ou esférico); a cor primária usada como ponto de referência para o matiz (Hue) e o cálculo da componente intensidade, das transformações.

Muitos algoritmos de transformação IHS têm sido desenvolvidos para converter valores RGB tricromáticos para os parâmetros de percepção humana de cores IHS e vice-versa (SMITH, 1978; ACM, 1979; SIEGAL e GILLESPIE, 1980; HAYDN *et al.*, 1982). Além da velocidade computacional, estes algoritmos diferem principalmente no método utilizado para cálculo da componente intensidade das transformações. Em geral, enquanto a velocidade e complexidade desses modelos variam, eles tendem a produzir valores similares de matiz e saturação.

De acordo com Sonka e colaboradores (SONKA *et al.*, 1999) a transformação RGB – IHS é dada por:

$$\left. \begin{aligned} i &= \frac{(r+g+b)}{3} \\ s &= 1 - \left(\frac{3}{(r+g+b)} \right) * \min(r, g, b) \\ h &= a \cos \left[\frac{0,5*(r-g) + (r-b)}{\left[(r-g)^2 + (r-g)*(g-b) \right]^{0,5}} \right] \end{aligned} \right\} \quad (2)$$

onde r , g e b são as componentes R, G e B normalizadas no intervalo $0 \leq r, g, b \leq 1$.

A transformação inversa pode ser obtida desta forma:

Para $0 \leq H \leq \frac{2\pi}{3}$:

$$\left. \begin{aligned} r &= i * \left[\frac{1 + s * \cos(H)}{\cos((\pi/3) - H)} \right] \\ b &= i * (1 - s) \\ g &= 3i * \left(1 - \frac{r+b}{3i} \right) \end{aligned} \right\} \quad (3)$$

Para $\frac{2\pi}{3} \leq H \leq \frac{4\pi}{3}$:

$$\left. \begin{aligned} H &= h - \frac{2\pi}{3} \\ g &= i * \left[\frac{1 + s * \cos(H)}{\cos((\pi/3) - H)} \right] \\ r &= i * (1 - s) \\ b &= 3i * \left(1 - \frac{r+b}{3i} \right) \end{aligned} \right\} \quad (4)$$

Para $\frac{4\pi}{3} \leq H \leq 2\pi$:

$$\left. \begin{aligned} H &= h - \frac{4\pi}{3} \\ b &= i * \left[\frac{1 + s * \cos(H)}{\cos((\pi/3) - H)} \right] \\ g &= i * (1 - s) \\ r &= 3i * \left(1 - \frac{g + b}{3i} \right) \end{aligned} \right\} \quad (5)$$

onde h , s e i são as componentes H, S e I normalizadas no intervalo $0 \leq h, s, i \leq 1$.

Um modelo mais simplificado descrito por Tu e co-autores é apresentado como uma transformação linear dada por:

$$\left. \begin{aligned} \begin{bmatrix} I \\ v1 \\ v2 \end{bmatrix} &= \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ -\sqrt{2}/6 & -\sqrt{2}/6 & 2\sqrt{2}/6 \\ 1/\sqrt{2} & 1/\sqrt{2} & 0 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix} \\ e \\ \begin{bmatrix} R \\ G \\ B \end{bmatrix} &= \begin{bmatrix} 1 & -1/\sqrt{2} & 1/\sqrt{2} \\ 1 & -1/\sqrt{2} & -1/\sqrt{2} \\ 1 & \sqrt{2} & 0 \end{bmatrix} * \begin{bmatrix} I \\ v1 \\ v2 \end{bmatrix} \end{aligned} \right\} \quad (6)$$

onde $v1$ é o eixo x, $v2$ o eixo y e I, o eixo z. Desta forma a matiz (H) e a saturação (S) podem ser representadas por:

$$H = \operatorname{tg}^{-1} \left(\frac{v2}{v1} \right) \text{ e } S = \sqrt{v1^2 + v2^2} \quad (7)$$

Alternativamente, pode-se rotacionar o cubo RGB até o plano horizontal, que é paralelo ao triângulo de Maxwell, de forma que o eixo vertical passa a situar-se na linha do cinza do cubo RGB, como visto anteriormente na Figura 12. Desta forma, um sistema não-linear de conversão RGB pode ser representado por:

$$\left. \begin{aligned}
 i &= \frac{(r + g + b)}{3} \\
 H &= \cos^{-1}(\alpha) & p/G \geq R \\
 H &= 2\pi - \cos^{-1}(\alpha) & p/G \leq R \\
 s &= 1 - \frac{3 \min(R, G, B)}{R + G + B} \\
 \alpha &= \frac{(2B - G - R)/2}{(B - G)^2 + (B - R)(G - R)}
 \end{aligned} \right\} \quad (8)$$

Os dois sistemas diferem principalmente na representação da saturação. Nas primeiras equações (6 e 7), pixels com $\sqrt{v1^2 + v2^2}$ idênticos possuem o mesmo valor de saturação, que independe da intensidade I . Estes pixels formam uma barreira de saturação no espaço IHS.

Para o sistema de conversão (equação 8), pixels com $\sqrt{v1^2 + v2^2}$ idênticos são locados na superfície do cone de saturação com valores de saturação proporcionais a intensidades distintas (TU *et al.*, 2001).

3.2 Registro de Imagens

Segundo Fonseca e colaboradores o registro de imagens é um processo de combinação de duas imagens para que os pontos de coordenadas nas duas imagens correspondam à mesma região física da cena a ser imageada (FONSECA *et al.*, 1996).

A fusão de imagens é utilizada em problemas clássicos de aplicações que necessitam de combinação de duas ou mais imagens da mesma cena. No processo de fusão, o registro de imagens é o primeiro passo. A imagem que é registrada é

chamada de imagem de referência e a imagem que será combinada com a imagem de referência é chamada imagem de ajuste, ou imagem de registro.

De acordo com Fedorov, o processo de registro pode ser realizado em três etapas básicas:

1. Obtenção de pontos de controle
2. Estimação da função de mapeamento
3. Composição das imagens

A etapa de obtenção dos pontos de controle nas imagens é composta pela extração e combinação das feições que a compõem. As feições podem ser linhas, contornos, pontos de saliência em curvas e bordas ou interseção de áreas.

Especificamente no que diz respeito às imagens de satélites, os pontos de controle mais comuns são cruzamentos de estradas, pontes, ou seja, referências que podem ser visivelmente localizadas em ambas as imagens, desde que não tenham sofrido alterações físicas entre a data da imagem de referência e a imagem de ajuste. Quanto maior a precisão na determinação destes pontos, ou seja, quanto menor o deslocamento entre os dois pontos, melhor será o resultado do registro (FEDOROV, 2003). Assim, baseado nesses pontos de controle, a próxima etapa trata-se da determinação de uma função de transformação que faz a relação entre os pontos na imagem de referência e na imagem de ajuste. Desta forma, é calculada a transformação espacial que modela as distorções entre as imagens, bem como o registro é realizado através de um método de interpolação. De um modo geral, os métodos de registro podem ser classificados como:

- a) Manual;
- b) Semi-automático;
- c) Automático.

O método manual envolve um processo demorado e depende dos conhecimentos e experiência do usuário, mas ainda é bastante utilizado. Nesse caso, o usuário escolhe os pontos de controle manualmente e as imagens são sobrepostas automaticamente. Trata-se de um processo exaustivo e demorado, o que pode levar o registro manual a erros, o que ocorre se o usuário não tiver experiência ou trabalhar sem a devida atenção.

O método semi-automático envolve a interação com o usuário. Isto facilita a determinação de pontos de controle precisos em um período de tempo mais curto. Tal método consiste portanto, em oferecer mecanismos para otimizar o processo de seleção dos pontos de controle. A ideia mais simples é aquela em que o usuário somente precisa escolher uma pequena área, ou seja, uma janela de pixels, que envolva potenciais pontos de controle, que serão identificados automaticamente. Neste caso, podem ser utilizados métodos estatísticos para comparação das duas janelas, ou ainda operadores morfológicos, para identificar os pontos correspondentes em cada área.

O método automático, idealmente, não tem interação com o usuário e todo o processo de registro é realizado de forma automática. Muitos métodos têm sido desenvolvidos, entretanto, para aplicações específicas, o que torna necessário a intervenção do usuário em alguns casos.

Algumas ideias de desenvolvimento de um algoritmo completamente automático baseiam-se em Inteligência Artificial. Um sistema inteligente neste caso determina o tipo de imagem e toma a decisão sobre o algoritmo que deverá ser empregado, para certa aplicação especial.

3.2.1 Estimativa da função de mapeamento

De acordo com Fedorov, as imagens a serem registradas podem ser relacionadas através de funções de transformação simples se a geometria das mesmas for semelhante. Neste caso, transformações como translação, rotação e escala (Figura 13), podem ser utilizadas.




Figura 13. Transformações de translação, rotação e escala (FEDOROV, 2003).

Sejam g e G as imagens de ajuste e de referência, respectivamente. As imagens são relacionadas pela transformação de distorção geométrica $T: g = G \circ T$.

Então, definindo $G(X, Y) = g(x, y)$, onde $(X, Y) = T(x, y)$, as transformações mais simples são rotação, escalonamento e translação, de modo que:

$$\begin{bmatrix} X \\ Y \end{bmatrix} = r \begin{bmatrix} \cos \theta & \sin \theta \\ -\sin \theta & -\cos \theta \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} + \begin{bmatrix} dx \\ dy \end{bmatrix} \quad (9)$$

onde r e θ são parâmetros de escala e rotação, respectivamente e dx e dy são parâmetros de deslocamento (FEDOROV, 2003).

Caso não exista similaridade entre a geometria das imagens, deverá ser utilizado um modelo genérico e flexível o suficiente para abranger todas as possíveis distorções que possam surgir. A tarefa então consiste da escolha do tipo da função de mapeamento e a estimativa de seus parâmetros. Neste caso, as transformações podem ser aproximadas utilizando uma função polinomial cujos parâmetros são

determinados a partir das coordenadas dos pontos de controle. O desempenho deste modelo depende de uma boa distribuição dos pontos de controle, da precisão das coordenadas dos pontos de controle e, o mais importante, da adequação da função polinomial escolhida ao que se pretende modelar. Assim tem-se:

1. Polinômio de primeiro grau:

$$X = a_1x + b_1y + d_1 \quad (10)$$

$$Y = a_2x + b_2y + d_2 \quad (11)$$

O polinômio de primeiro grau também é chamado de “Função Afim” que é a função mais utilizada para registro de imagens. Para facilitar a utilização usa-se a seguinte representação matricial:

$$\begin{bmatrix} X \\ Y \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} X \\ Y \end{bmatrix} + \begin{bmatrix} a_{13} \\ a_{23} \end{bmatrix} \quad (12)$$

2. Polinômio de segundo grau:

$$X = a_0 + a_1x + a_2y + a_3xy + a_4x^2 + a_5y^2 \quad (13)$$

$$Y = b_0 + b_1x + b_2y + b_3xy + b_4x^2 + b_5y^2 \quad (14)$$

Uma vez determinados os pontos de controle, por meio de um sistema de equações, pode-se determinar 6 parâmetros no caso de polinômio de 1º grau e 12 parâmetros, para o 2º grau. O número mínimo de pontos de controle representa a situação de um sistema de equações determinado.

Entretanto, como as coordenadas medidas dos pontos de controle estão sujeitas a erros, convém usar um número de pontos maior que o número mínimo, o que define um sistema de equações sobre-determinado. Ou seja, o sistema tem mais equações que incógnitas e permite tratar e distribuir os erros de medição dos pontos de controle.

3.2.2 Mapeamento e Re-amostragem

As funções de mapeamento construídas durante o processo da etapa anterior são usadas para transformar a imagem de ajuste e portanto, registrar a imagem. Segundo Zitová e colaboradores, a transformação espacial pode ser feita no sentido da imagem de referência para a imagem de ajuste (*forward*) e no sentido inverso (*backward*). Alguns autores descrevem esse processo como mapeamento direto e inverso.

No método direto, cada pixel da imagem de registro pode ser diretamente transformado usando a função de mapeamento estimada. Porém, é um método complicado para ser implementado e produz buracos e sobreposições na imagem de saída. Sendo assim, o mapeamento inverso tem sido mais apropriado (ZITOVÁ *et al.*, 2003).

Como ilustrado na Figura 14, a imagem registrada é obtida da imagem de ajuste a partir das coordenadas do pixel alvo (mesmo sistema de coordenadas da imagem de referência) e da inversa da função de mapeamento estimada.

A interpolação da imagem ocorre na imagem de ajuste sobre a grade regular da imagem de referência. Desta forma não ocorrem buracos ou sobreposições na imagem de saída.




Figura 14. Ilustração da transformação espacial e mapeamento inverso da imagem registrada.

O grande problema da re-amostragem encontra-se na determinação exata do nível de cinza a ser destinado aos pixels da nova imagem.

Assim, conforme mostrado na Figura 15 percebe-se que o pixel destacado deve influenciar radiometricamente ao menos outros quatro pixels na imagem registrada. A re-amostragem, neste caso, faz-se necessária para que os novos pixels tenham os níveis de cinza correspondentes à imagem original.

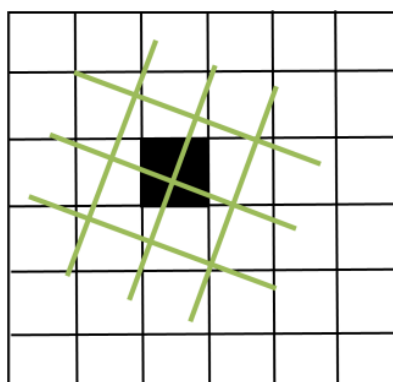


Figura 15. O problema da re-amostragem: compatibilizar a radiometria da imagem original para uma nova distribuição de pixels.

A interpolação é geralmente realizada via convolução da imagem com um núcleo de interpolação. Um interpolador ótimo é a função sinc 2-D, porém é de difícil implementação na prática, devido sua extensão infinita. Por outro lado, existem muitos interpoladores mais simples, de suporte limitado. Pode-se citar neste caso, o método do vizinho mais próximo, bilinear, krigagem, bicúbico, polinomial e splines (DOGSON *et al.*, 1992, 1997; PARKER *et al.*, 1993; LEHMANN *et al.*, 2001; GÖÇERI *et al.*, 2010).

3.2.3 Método do Vizinho-mais-próximo

Conforme mostra a Figura 16, após a transformação, as coordenadas inteiras são mapeadas em coordenadas fracionárias (x,y) . Assim para interpolação, o nível de cinza correspondente a coordenada inteira mais próxima vizinha de (A, B, C ou D) é atribuído ao pixel selecionado em (x,y) .




Figura 16. Interpolação bilinear.

Apesar de ser um método mais simples de ser implementado, apresenta frequentemente a desvantagem de produzir artefatos indesejáveis, tal como a distorção de bordas retas em imagens de resoluções finas.

3.2.4 Método Bilinear

Em resumo, mesmo que a interpolação bilinear seja superada por métodos de ordem superior, em termos de precisão e aparência visual da imagem transformada, oferece provavelmente a melhor relação entre precisão e complexidade computacional, portanto, tem sido mais comumente utilizada. Essa abordagem utiliza os níveis de cinza dos quatro vizinhos mais próximos (Figura 16) do par de coordenadas não inteiras (x,y) . Assim, o novo valor de nível de cinza, denotado por $v(x,y)$ pode ser interpolado a partir da relação:

$$v(x,y) = ax + by + cxy + d \quad (15)$$

3.2.5 Krigagem

Técnicas de krigagem podem ser entendidas como uma predição linear ou uma forma da interferência bayesiana (KRIGE, 1951). Parte do princípio que pontos próximos no espaço tendem a ter valores mais parecidos do que pontos mais afastados. Porém, a partir de determinada distância, certamente não se encontrarão valores próximos porque a correlação espacial pode deixar de existir.

Resumidamente, os passos para emprego de geoestatística incluem:

- a) Análise exploratória dos dados;

- b) Análise estrutural (cálculo e modelagem do variograma);
- c) Realização de inferências (Krigagem ou Simulação).

Em 1987 Burrough mostrou que a variação espacial de uma variável regionalizada pode ser expressa pela soma de três componentes (BURROUGH, 1987):

- a) Uma componente estrutural, associada a um valor médio constante ou a uma tendência constante;
- b) Uma componente aleatória, espacialmente correlacionada;
- c) Um ruído aleatório ou erro residual. Se x representa uma posição em uma, duas ou três dimensões, então o valor da variável Z , em x , é dada por:

$$Z(x) = m(x) + \varepsilon'(x) + \varepsilon'' \quad (16)$$

onde:

- $m(x)$ é uma função determinística que descreve a componente estrutural de Z em x ;
- ε' é um termo estocástico, que varia localmente e depende espacialmente de $m(x)$;
- ε'' é um ruído aleatório não correlacionado, com distribuição normal com média zero e variância σ^2 .

Diferente de outras técnicas de inferência, a krigagem simples e ou ordinária requer algumas hipóteses (DAVID, 1977). No caso mais simples, admite-se que a componente determinística, $m(x)$, é constante (não há tendências na região). Então, $m(x)$ é igual ao valor esperado da variável aleatória Z na posição x e a diferença média entre os valores observados em x e $(x+h)$ separados por um vetor de distância h (módulo e direção), é nula. Logo pode-se escrever:

$$E[Z(x) - Z(x+h)] = 0 \quad \text{ou} \quad E[Z(x)] = E[Z(x+h)] = m(x) = m \quad (17)$$

Admite-se também neste contexto a estacionariedade da covariância, isto é, a covariância entre dois pares quaisquer $Z(x)$ e $Z(x+h)$, separados por um vetor distância h , existe e depende somente de h . Então:

$$C(h) = Cov[Z(x), Z(x+h)] = E[Z(x) \cdot Z(x+h)] - m^2, \forall x \quad (18)$$

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

$$2\gamma(h) = E\{[Z(x) - Z(x+h)]^2\} \quad (19)$$

As considerações acima resumem a hipótese de estacionariedade de 2ª ordem. Porém, na geoestatística adota-se uma hipótese de estacionariedade menos restritiva denominada Intrínseca.

Neste caso, admite-se que $E[Z(x)] = m(x), \forall x$, e que a variância das diferenças depende somente do vetor distância h , isto é:

$$Var[Z(x) - Z(x+h)] = E\{[Z(x) - Z(x+h)]^2\} = 2\gamma(h) \quad (20)$$

onde $2\gamma(h)$ é o variograma, definido.

Se as condições especificadas pela hipótese intrínseca são contempladas, então o semivariograma pode ser estimado a partir do dado amostral:

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \cdot \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (21)$$

onde $N(h)$ é o número de pares de pontos amostrais separados pelo vetor distância(h).

O gráfico $\gamma(h)$ versus h , conforme apresentado na Figura 17, é conhecido como semivariograma experimental. O seu padrão representa o que, intuitivamente, se espera de dados reais, isto é, que as diferenças $\{Z(x_i) - Z(x_i + h)\}$ decresçam à medida que h diminui.

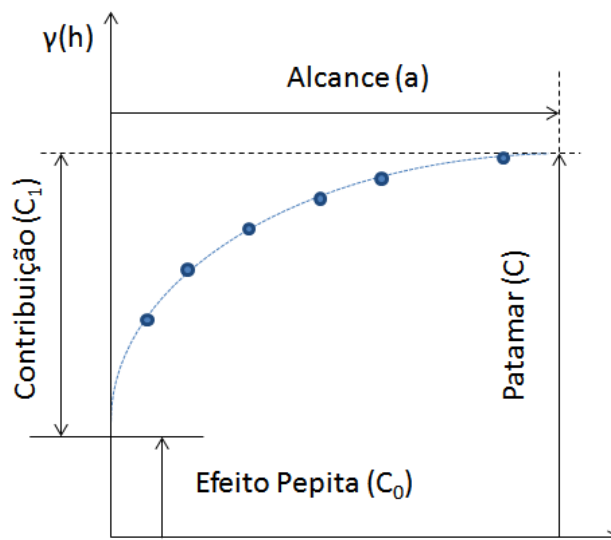


Figura 17. Exemplo de um semivariograma ideal.

É esperado que observações, mais próximas geograficamente, tenham um comportamento semelhante entre si do que aquelas separadas por maiores distâncias. Desta maneira, é esperado que $y(h)$ aumente com a distância h .

O procedimento de ajuste, do semivariograma experimental, não é direto e automático, como no caso de uma regressão, por exemplo, mas sim iterativo, pois nesse processo o intérprete faz um primeiro ajuste e verifica a adequação do modelo teórico. Resumidamente, os modelos de ajuste estão divididos em dois tipos (ISAAKS e SRIVASTAVA, 1989): modelos com patamar e modelos sem patamar. Modelos do primeiro tipo são referenciados na geoestatística como modelos transitivos. Exemplos de modelos transitivos são: Esférico, Exponencial e Gaussiano, conforme definidos, respectivamente, nas equações 22, 23 e 24:

$$\gamma(h) = \begin{cases} 0 & , |h| = 0 \\ C_0 + C_1 \left[\frac{3}{2} \left(\frac{|h|}{a} \right) - \frac{1}{2} \left(\frac{|h|}{a} \right)^3 \right] & , 0 \leq |h| \leq a \\ C_0 + C_1 & , |h| > a \end{cases} \quad (22)$$

$$\gamma(h) = C_0 + C_1 \left(1 - e^{-\frac{h}{a}} \right) \quad (23)$$

$$\gamma(h) = \begin{cases} C_0 + C_1 \left(1 - e^{-\frac{h^2}{a^2}} \right) & , 0 \leq |h| \leq a \\ C_0 + C_1 & , 0 \leq |h| \leq a \end{cases} \quad (24)$$

onde:

- C_0 é o efeito pepita;
- C_1 é a contribuição do modelo teórico;
- α é o alcance.

Modelos do segundo tipo não atingem o patamar, e continuam aumentando enquanto a distância aumenta. Tais modelos são utilizados para modelar fenômenos que possuem capacidade infinita de dispersão.

Quantos aos métodos de inferência de krigagem simples e ordinária, seus estimadores são conforme as equações (25) e (26) respectivamente (JOURNEL, 1988):

$$Z_{x_0}^* = m + \sum_{i=1}^n \lambda_i [Z(x_i) - m] \quad (25)$$

$$Z_{x_0}^* = \sum_{i=1}^n \lambda_i Z(x_i), \quad \text{com } \sum_{i=1}^n \lambda_i = 1 \quad (26)$$

Nas equações (25) e (26) o que difere o estimador de krigagem simples do estimador de krigagem ordinária, é que este último não requer o prévio conhecimento da média amostral m . Em 1988, Journel mostrou que, os sistemas de krigagem simples e ordinária podem ser escritos em notação matricial como:

$$K \cdot \lambda = k \Rightarrow K^{-1} \cdot k \quad (27)$$

onde:

- K e k são matrizes das covariâncias (ou variogramas);
- λ é o vetor dos pesos.

Por exemplo, no caso da krigagem ordinária as matrizes são assim definidas:

$$K = \begin{bmatrix} C_{11} & C_{12} & \cdots & C_{1n} & 1 \\ C_{21} & C_{22} & \cdots & C_{2n} & 1 \\ \vdots & \vdots & & \vdots & \vdots \\ C_{n1} & C_{n2} & \cdots & C_{nm} & 1 \\ 1 & 1 & \cdots & 1 & 0 \end{bmatrix}, \quad \lambda = \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \\ \vdots \\ \lambda_\alpha \end{bmatrix} \quad e \quad k = \begin{bmatrix} C_{10} \\ C_{20} \\ C_{30} \\ \vdots \\ C_1^{n0} \end{bmatrix} \quad (28)$$

onde:

C_{nm} são os valores de covariância;

λ_n são os pesos determinados pela equação 27.

Determinado os pesos, aplica-se o estimador da equação (25) ou (26). Além da inferência de valores, esta técnica fornece também uma medida de imprecisão denominada de variância de krigagem (Simples ou Ordinária), dada por (JOURNEL, 1988) como:

$$\sigma_k^2 = C(0) - \lambda^T \cdot k \quad (29)$$

3.3 Fusão de Imagens

Segundo Agüena, fusão é uma técnica natural utilizada para sobrevivência de todas as espécies, sem exceção, é a instintiva combinação dos dados obtidos pelos coletores externos conhecidos como sentidos (como a visão, tato ou olfato) e a análise do seu significado em conjunto, armazenado em base de dados dos conhecimentos adquiridos ou instintivos, para a escolha de uma estratégia de ação (AGÜENA, 2002).

De acordo Wald fusão de dados ainda pode ser definida como um ambiente no qual meios e ferramentas são expressos para a integração de dados de

diferentes fontes, desejando obter informação de qualidade maior. A exata definição de qualidade maior dependerá da aplicação (WALD, 1998).

No contexto do processamento de imagens, pode-se definir fusão como o campo que estuda diferentes técnicas de integração de informações espaciais e espectrais, com objetivo de se obter um produto imagem de maior qualidade, visto que o fator qualidade está relacionado com o objetivo da aplicação.

Na literatura, encontram-se variados métodos de fusão de imagens. Dutra e colaboradores (DUTRA *et al.*, 1989) utilizaram a transformação do espaço de cores RGB para o IHS das bandas TM (Thematic Mapper), que eram interpoladas nesse espaço e tinham substituído o canal I (de intensidade) pela banda pancromática do SPOT (*Système d'Probatoire Observation de la Terre*). O resultado final foi obtido transformando-se novamente as bandas de IHS para RGB. Posteriormente, esta ideia foi aprimorada, dando origem inclusive a uma classe de métodos, baseada na transformada IHS (HAYDAN *et al.*, 1982; CARPER *et al.*, 1990; TU *et al.*, 2001a; TU *et al.*, 2004).

Existem também, os métodos baseados na transformada PCA (CHAVEZ; KWARTENG, 1989; ZHOU, 1998; CAO *et al.*, 2003; GONZÁLEZ-AUDÍCANA *et al.*, 2004) e na transformada Wavelet (MALLAT, 1989; LI *et al.*, 1994; GARGUETDUPORT *et al.*, 1996; CHIBANI; HOUACINE, 2000; OTAZU *et al.*, 2005; LILLOSAAVEDRA; GONZALO, 2006). A maioria destes métodos combina a informação de detalhes contida na imagem pancromática (HR) com a informação espectral das imagens multiespectrais (LR).

No Brasil, a fusão de imagens tem sido amplamente utilizada em aplicações com imagens de sensoriamento remoto (SCHNEIDER *et al.*, 2003; VELLOSO *et al.*, 2005; ACERBI-JUNIOR *et al.*, 2006; MARCELINO *et al.*, 2009).

Mascarenhas e seus colaboradores (MASCARENHAS *et al.*, 1991) propuseram a simulação da banda pancromática degradada do SPOT por combinação linear das bandas multiespectrais, como um exemplo de método potencial para diminuir a taxa de dados na comunicação entre o satélite e a Terra.

Candeias e co-autores propuseram um novo método para fusão de dados de imagens multiespectrais utilizando uma abordagem bayesiana. O método foi aplicado para a síntese de novas bandas do satélite SPOT, onde combinando o vetor de observações e a informação interpolada a priori, representada pelo vetor interpolado das bandas multiespectrais e sua matriz de covariância, uma estimação linear de erro médio quadrático foi realizada, utilizando o princípio da ortogonalidade, resultando nas bandas estimadas sintéticas (CANDEIAS *et al.*, 1992).

Pinho e colaboradores (PINHO *et al.*, 2005), avaliaram 5 diferentes técnicas relacionadas à capacidade de transferir detalhes e de preservação espectral. Para isso, utilizaram duas imagens do satélite Quickbird, sendo uma multiespectral com 4 bandas e resolução espacial de 2,4 metros e outra pancromática, com resolução de 0,6 metros. Para facilitar a identificação dos alvos, realizou-se uma fusão entre as imagens e assim, gerou-se uma imagem sintética multiespectral com alta resolução espacial. Testaram-se diferentes técnicas de fusão, para avaliar qual teria o melhor desempenho. As técnicas testadas foram a fusão por IHS, Brovey, PCA, Gram Schmidt e CN Spectral Sharpening. Para análise dos resultados, considerou-se o teste proposto por Ventura e seus colaboradores (VENTURA *et al.*, 2003) e observou-se que as técnicas de PCA e Gram-Schmidt apresentaram-se melhores para identificação de alvos urbanos.

Leonardi e seus colaboradores (LEONARDI *et al.*, 2005) avaliaram os métodos de fusão por PCA, IHS e Transformada Wavelet, com o objetivo de

comparar tais técnicas de fusão de imagens, para diferentes sensores orbitais. Os sensores considerados foram o SPOT 4, SPOT 5, CBERS 2, LANDSAT ETM-7 e Quickbird, onde foram realizadas fusões entre as bandas pancromáticas, de alta resolução, com as bandas multiespectrais. Utilizaram-se as medidas estatísticas (histograma, variância e correlação), imagem diferença e o IQI (*Image Quality Index*) para avaliação dos resultados. Observou-se que o método por Transformada Wavelet preservou melhor as características espectrais dos dados originais, porém o método por PCA apresentou-se melhor visualmente e preservou melhor as características espaciais, da imagem pancromática.

Debiasi e colaboradores (DEBIASI *et al.*, 2007) desenvolveram um estudo onde se utilizou a transformação IHS, substituindo a banda intensidade por um produto NDVI⁷ gerado a partir de uma imagem do sensor LANDSAT TM5. Tal estudo teve o objetivo de melhorar a visualização para a identificação de áreas agrícolas pequenas. Como resultado observou-se que a transformação IHS proporcionou um grande desempenho na interpretação visual da imagem sintética de saída e possibilitou a identificação dos alvos, tendo sido demonstrada como uma técnica promissora para tal fim.

Adami e colaboradores (ADAMI *et al.*, 2007) avaliaram a técnica de fusão IHS aplicada em imagens Landsat7-ETM+ para a substituição das fotografias aéreas de arquivo, em trabalhos de coleta de dados de campo e delimitação de elementos amostrais para estimativas de área de culturas agrícolas. As bandas 3, 4, 5 e 7 do sensor de ETM+ foram usadas nas diferentes combinações de RGB e fundidas por IHS com a banda PAN para produzir imagens com melhor definição espacial. As

⁷ O Índice de Vegetação por Diferença Normalizada (NDVI) é um indicador gráfico que permite ressaltar o comportamento espectral da vegetação em relação ao solo e a outros alvos da superfície terrestre (CRIPPEN *et al.*, 1990). Trata-se de um índice muito simples, resultante da diferença entre a reflectância do infravermelho próximo e reflectância do vermelho, dividida pela soma das duas reflectâncias respectivamente (TOWNSHEND *et al.*, 1994).

imagens resultantes foram impressas na escala de 1: 25.000 e usadas em trabalho de campo, em 85 elementos amostrais. As imagens fundidas permitiram identificar o uso e a cobertura do solo nos elementos amostrais. Conseqüentemente, as imagens fundidas de ETM+ apresentaram grande potencial para o levantamento de dados de campo, mapeamento das características de uso e cobertura do solo e estimativas da área cultivada, baseadas em técnicas de amostragem da área.

3.3.1 Fusão IHS

A fusão IHS busca na propriedade desta transformada separar a informação espectral de uma composição RGB em duas componentes H e S. Também, busca isolar a informação espacial na componente I (POHL; GENDEREN, 1998).

Existem diversos trabalhos na literatura onde se aplicou o método de fusão por IHS. Haydan e co-autores apresentam um dos primeiros trabalhos usando este método (HAYDAN *et al.*, 1982). Em Welch e Ehlers, a transformada foi utilizada para a geração de imagens de áreas urbanas para melhorar a interpretação (WELCH E EHLERS, 1987). Carper e colaboradores (CARPER *et al.*, 1990) propuseram um método para produzir imagens SPOT com 10m a partir da fusão da banda Pancromática de 10m com as bandas multiespectrais de 20m do próprio satélite, ponderando a informação pancromática e inserindo informação da banda NIR (infravermelho próximo) no processo.

Entretanto, de acordo com Silva os primeiros trabalhos não se preocupavam com um detalhe importante, que é o fato de que junto com a informação espacial, a componente I também possui alguma informação espectral. Do mesmo modo, um pouco de informação espacial também está presente nas componentes H e S (SILVA, 2009). Além disso, a banda pancromática também possui informação

espectral (GONZÁLEZ-AUDÍCANA *et al.*, 2004). Essa inseparabilidade das informações causa problemas no processo de fusão. Um deles é a distorção espectral da imagem fusionada. Isso acontece principalmente, quando a fusão é realizada com bandas de diferentes sensores, onde a faixa espectral da banda pancromática é diferente da faixa espectral das bandas multiespectrais.

Diante desta questão, muitos trabalhos têm sido desenvolvidos com o intuito de minimizar a distorção espectral da imagem fusionada. Tu e colaboradores (TU *et al.*, 2001a; 2001b) apresentam estudos detalhados indicando que o problema da distorção de cor provém da mudança da componente saturação durante o processo de fusão.

Entretanto, existem aplicações onde a distorção espectral não é um problema. Em uma classificação de imagens, por exemplo, não importa a cor de cada objeto, mas sim que ele seja facilmente distinguido dos demais. Silva e co-autores (SILVA *et al.*, 2007) apresentam uma transformada IHS generalizada que aceita n -bandas de entrada, sem a preocupação com a distorção de cor. Basicamente, a fusão IHS baseia-se em um processo onde a componente Intensidade, é substituída pela banda pancromática de uma imagem de alta resolução. Então, é realizada uma transformação inversa da banda pancromática juntamente com as componentes H e S, para então obter-se um produto imagem da fusão IHS, no espaço RGB.

Utilizando as mesmas nomenclaturas apresentadas anteriormente, a componente Intensidade (I_0), de baixa resolução no espaço IHS é substituída por uma imagem em nível de cinza de alta resolução espacial (I_{new}) e transformada novamente para o espaço RGB com as componentes H e S originais, pela equação (30).

Assim é possível considerar os seguintes passos:

Passo 1:

$$\begin{bmatrix} I_0 \\ v1_0 \\ v2_0 \end{bmatrix} = \begin{bmatrix} 1/3 & 1/3 & 1/3 \\ -\sqrt{2}/6 & -\sqrt{2}/6 & 2\sqrt{2}/6 \\ 1/\sqrt{2} & 1/\sqrt{2} & 0 \end{bmatrix} * \begin{bmatrix} R_0 \\ G_0 \\ B_0 \end{bmatrix} \quad (30)$$

Passo 2: I_0 é substituída por I_{new} .

Passo 3:

$$\begin{bmatrix} R_{new} \\ G_{new} \\ B_{new} \end{bmatrix} = \begin{bmatrix} 1 & -1/\sqrt{2} & 1/\sqrt{2} \\ 1 & -1/\sqrt{2} & -1/\sqrt{2} \\ 1 & \sqrt{2} & 0 \end{bmatrix} * \begin{bmatrix} I_{new} \\ v1_0 \\ v2_0 \end{bmatrix} \quad (31)$$

onde R_0 , G_0 , B_0 , I_0 , $v1_0$, $v2_0$ representam os valores correspondentes para a imagem multiespectral original redimensionada. R_{new} , G_{new} e B_{new} são os valores correspondentes para a imagem fusionada.

Entretanto, devido ao alto custo computacional para 30 e 31, de acordo com Tu e colaboradores, um método mais eficiente computacionalmente, sem transformação de coordenadas, pode ser obtido reescrevendo tais equações da seguinte forma:

$$\left. \begin{aligned} \begin{bmatrix} R_{new} \\ G_{new} \\ B_{new} \end{bmatrix} &= \begin{bmatrix} 1 & -1/\sqrt{2} & 1/\sqrt{2} \\ 1 & -1/\sqrt{2} & -1/\sqrt{2} \\ 1 & \sqrt{2} & 0 \end{bmatrix} * \begin{bmatrix} I_0 + (I_{new} - I_0) \\ v1_0 \\ v2_0 \end{bmatrix} \\ &= \begin{bmatrix} 1 & -1/\sqrt{2} & 1/\sqrt{2} \\ 1 & -1/\sqrt{2} & -1/\sqrt{2} \\ 1 & \sqrt{2} & 0 \end{bmatrix} * \begin{bmatrix} I_0 + \delta \\ v1_0 \\ v2_0 \end{bmatrix} \\ &= \begin{bmatrix} R_0 + \delta \\ G_0 + \delta \\ B_0 + \delta \end{bmatrix} \end{aligned} \right\} \quad (32)$$

onde $\delta = I_{new} - I_0$.

A equação (32) demonstra que a imagem fundida $[R_{new}, G_{new}, B_{new}]^T$ pode ser facilmente obtida a partir da imagem original redimensionada $[R_0, G_0, B_0]^T$ simplesmente por adição, aumentando assim a eficiência na implementação.

No trabalho de Tu e co-autores é proposta uma nova abordagem sobre o método IHS. Quando I_{new} é substituído por uma pancromática de alta resolução. De acordo com a equação (33), um método eficiente computacionalmente, sem transformação de coordenadas pode ser dado por:

$$\begin{bmatrix} R_{new} \\ G_{new} \\ B_{new} \end{bmatrix} = \begin{bmatrix} 1 & -1/\sqrt{2} & 1/\sqrt{2} \\ 1 & -1/\sqrt{2} & -1/\sqrt{2} \\ 1 & \sqrt{2} & 0 \end{bmatrix} * \begin{bmatrix} Pan \\ v1_0 \\ v2_0 \end{bmatrix} = \begin{bmatrix} R_0 + \delta \\ G_0 + \delta \\ B_0 + \delta \end{bmatrix} \quad (33)$$

onde $\delta = Pan - I_0$.

A maioria dos trabalhos na literatura da área reconhece o IHS como um método de terceira ordem, pois utiliza uma matriz 3x3 como núcleo. O método proposto por Tu e colaboradores (TU *et al.*, 2001), além da eficiência computacional, apresenta a capacidade de estender a transformação tradicional de 3ª ordem para ordem arbitrária. Isto é:

$$F_i = M_i + \beta_i, \quad (34)$$

onde M_i denota a imagem multiespectral redimensionada da banda i $\beta = Pan - k$,

$k = \left(\left(\frac{1}{l} \right) \sum_{i=1}^{l-1} M_i \right)$ e l representam a ordem ou o número de bandas.

Segundo Silva, o algoritmo para realizar a fusão de imagens de baixa resolução (LR) com uma imagem de alta resolução (HR) é executado nos seguintes passos:

Passo 1: Re-amostrar as bandas multiespectrais para a mesma resolução da banda HR de modo que as imagens tenham o mesmo número de linhas e colunas;

Passo 2: Transformar a composição de baixa resolução RGB em

componentes de intensidade (I), matiz (H) e saturação (S);

Passo 3: Ajustar o histograma da banda HR ao histograma da componente I para reduzir distorções espectrais;

Passo 4: Substituir a componente I pela banda HR;

Passo 5: Aplicar a transformada IHS inversa.

Com isso, uma composição colorida RGB é gerada contendo informação espacial da HR e informação espectral das componentes H e S (SILVA, 2009).

3.3.2 Fusão PCA

De acordo com Byrne e colaboradores, uma extensão da ideia dos métodos de fusão por transformação IHS são os métodos baseados em técnicas de projeções lineares como os de Análise de Componentes Principais (PCA) (BYRNE *et al.*, 1990).

A maioria dos sensores multiespectrais coleta as informações dos objetos em bandas adjacentes do espectro eletromagnético. Muitos objetos possuem respostas espectrais similares em faixas do espectro eletromagnético próximas gerando, desta forma, informações redundantes (correlacionadas). Dado um conjunto de bandas espectrais correlacionadas, a PCA (JOLLIFFE, 2002) permite gerar novas bandas decorrelacionadas por meio da reorganização das informações originais. Assim, em algumas aplicações os alvos de interesse podem ser melhor analisados por meio da PCA.

Em geral, a primeira componente principal coleta a informação que é comum a todas as bandas de entrada e assim apresenta a aparência de uma banda pancromática, que cobre uma faixa espectral larga (CHAVEZ; KWARTENG, 1989).

Essa característica torna a PCA um método muito adequado para realizar fusão entre imagens LR e HR.

Aplicada de maneira isolada ou combinada com outras transformadas a PCA tem sido bastante utilizada em vários trabalhos. Tu e colaboradores (TU *et al.*, 2001a) propõem o uso da PCA combinada com a transformada IHS. Cao e colaboradores (CAO *et al.*, 2003) comparam o seu método, que utiliza o algoritmo de Mallat e colaboradores (MALLAT *et al.*, 1989) para fundir imagens LR e HR por meio da PCA, com os métodos IHS e PCA clássicos, melhorando a qualidade espectral do resultado. González-Audicana e colaboradores (GONZÁLEZ-AUDÍCANA *et al.*, 2004) utilizam a PCA para injetar os detalhes espaciais da banda HR, que são extraídos através da decomposição Wavelet, nas bandas LR.

Trata-se um esquema de decorrelação utilizado para mapeamento e extração de informação em dados de sensoriamento remoto. Assim é possível obter um sistema de coordenadas ortogonais de cor, de Análise de Componentes Principais, como dado abaixo, ou seja:

$$\begin{bmatrix} PC1 \\ PC2 \\ PC3 \end{bmatrix} = \begin{bmatrix} \Phi_{11} & \Phi_{12} & \Phi_{13} \\ \Phi_{21} & \Phi_{22} & \Phi_{23} \\ \Phi_{31} & \Phi_{32} & \Phi_{33} \end{bmatrix} * \begin{bmatrix} R_0 \\ G_0 \\ B_0 \end{bmatrix} \quad (35)$$

$$H = \operatorname{tg}^{-1}\left(\frac{PC3}{PC2}\right) \text{ e } S = \sqrt{PC2^2 + PC3^2}$$

A matriz de transformação Φ composta pelo termo Φ_{ij} , consiste dos autovetores⁸ da matriz de covariância dos vetores RGB.

⁸ Em álgebra linear, um autovetor representa uma direção que é preservada por uma transformação linear. Mais precisamente, seja V um espaço vetorial sobre um corpo F , e $A: V \rightarrow V$ uma transformação linear, v é um autovetor quando não é nulo e existe um escalar λ tal que $Av = \lambda v$. Nesse caso, dizemos também que λ é um autovalor.

Se R representa a matriz de covariância com termos gerais r_{ij} , então a matriz de transformação satisfaz a relação:

$$\Phi \cdot R \cdot \Phi^T = \Lambda \quad (36)$$

onde $\Lambda = \text{diag}(\lambda_1, \lambda_2, \lambda_3)$ são autovalores⁹ correspondentes a Φ em ordem decrescente.

Para proceder a fusão de imagens, a primeira componente (PC1) do espaço PCA é substituída pela pancromática e o sistema é re-transformado para o espaço original RGB, isto é:

$$\begin{bmatrix} R_{new} \\ G_{new} \\ B_{new} \end{bmatrix} = \begin{bmatrix} \Phi_{11} & \Phi_{12} & \Phi_{13} \\ \Phi_{21} & \Phi_{22} & \Phi_{23} \\ \Phi_{31} & \Phi_{32} & \Phi_{33} \end{bmatrix} * \begin{bmatrix} PC1 \\ PC2 \\ PC3 \end{bmatrix} \quad (37)$$

Segundo Napoleão, o método PCA pode ser resumido nos seguintes passos (NAPOLEÃO, 2001):

Passo 1: Transformação do espaço RGB para o das PCA. Três ou mais bandas da imagem multiespectral são transformadas em três ou mais novas imagens do espaço das componentes principais, cada componente possuindo quantidades distintas de informações.

Passo 2: Cálculo das estatísticas de variância e média e com base no histograma é aplicado o contraste na imagem de resolução espacial maior, de forma a ter o mesmo colorido que a imagem da primeira componente (PC1), entretanto com uma resolução espacial maior.

Passo 3: Com as características espectrais semelhantes, pode-se substituir a PC1 pela imagem que foi contrastada, de resolução mais alta.

⁹ Um escalar λ é autovalor de um operador linear $A : V \rightarrow V$ se existir um vetor x diferente de zero tal que $Ax = \lambda x$.

Passo 4: Com a substituição, procede-se a inversão do espaço das PCA's para o espaço RGB, através de uma transformação inversa.

O uso da PCA para fusão de imagens está sujeito ao problema de distorção espectral mencionado anteriormente no método IHS.

3.3.3 Outros métodos de fusão

Existem outros métodos menos utilizados no sensoriamento remoto, mas que, tem trazido resultados relevantes.

Segundo Smith, o método Gram Schmidt, assim como a PCA, é uma operação sobre vetores com o objetivo de torná-los ortogonais¹⁰ (SMITH, 2003). Pode ser definida em duas etapas. A primeira diz respeito à simulação de uma banda pancromática a partir das bandas multiespectrais, onde a pancromática simulada é empregada como a primeira banda. Na segunda etapa, a primeira banda Gram Schmidt é trocada pela banda pancromática de alta resolução e uma transformação inversa é aplicada para formar a imagem sintética de saída (RSI, 2003).

No método Wavelet, realizado no domínio espacial, a pancromática de alta resolução é primeiramente decomposta em um conjunto de imagens Pan de baixa resolução com os coeficientes Wavelet's correspondentes (detalhes espaciais) a cada nível. Bandas individuais da imagem MS então substituem as PAN's de baixa resolução no nível de resolução da imagem MS original. Os detalhes de alta resolução espacial são injetados em cada banda MS por meio da transformada inversa de cada banda MS com o coeficiente Wavelet correspondente.

¹⁰ Dois vetores de R^n são ortogonais quando seu produto interno é igual a zero.

Diferentes combinações aritméticas também têm sido desenvolvidas em fusão de imagens. A transformação *Brovey*, SVR (Taxa Variável Sintética), RE (Taxa de Otimização), são alguns exemplos bem sucedidos. A ideia básica da transformação *Brovey* está em multiplicar cada banda MS pela pancromática de alta resolução e então dividir cada produto pela soma das bandas MS. As outras duas são similares, porém envolvem cálculos mais sofisticados para a soma MS para uma melhor qualidade na fusão.

De acordo com os trabalhos de Vrabel e co-autores, o método CN *Spectral Sharpening* trata-se de uma extensão do algoritmo *Brovey*, porém sem restrição quanto ao número de bandas e a resolução radiométrica da imagem sintética de saída, onde é capaz de fundir dados multiespectrais de resoluções espectrais e espaciais distintas, sendo aplicável em fusão hiperespectral (VRABEL, 2002a; VRABEL, 2002b). A única restrição existente nesse método é o fato de que o intervalo espectral das bandas de entrada (as que terão suas resoluções melhoradas) deve ser o mesmo das bandas *sharpening* (bandas de alta resolução espacial que fornecerão dados de alta frequência para o processo de fusão). A técnica pode ser descrita em dois passos:

Passo 1: envolve o agrupamento das bandas de entrada em segmentos espectrais que são definidos pelo intervalo espectral das bandas *sharpening*.

Passo 2: é realizada uma operação matemática semelhante à fusão *Brovey*.

Cada banda de entrada é multiplicada pela banda *sharpening* e, então normalizada pela divisão da soma de bandas de entrada no segmento (RSI, 2003).

Todos os métodos de fusão exigem algumas condições prévias para a integração das informações. Em primeiro lugar as imagens precisam ser registradas, ou seja, devem sofrer transformações geométricas de modo que sejam sobrepostas na

mesma grade de posicionamento. Além disso, as imagens devem estar amostradas na mesma frequência, ou seja, os pixels devem ser re-amostrados de modo que possuam o mesmo tamanho. Desta forma, a fusão de imagens contempla técnicas que a antecedem e por elas mesmas dão origem a novos campos de pesquisa.

Capítulo 4

MODELO COMPUTACIONAL BASEADO EM PROCESSAMENTO DE IMAGENS PARA INFERÊNCIA DE RISCO DE OCORRÊNCIA DE SIGATOKA NEGRA

4.1 Introdução

Este capítulo apresenta a metodologia fundamentada na aplicação do processamento digital de imagens e sensoriamento remoto para o monitoramento de risco de ocorrência da Sigatoka Negra.

A metodologia consiste em um sistema baseado na integração de dados de imagens de sensores orbitais e modelos de distribuição de probabilidades de variáveis meteorológicas em séries temporais.

Os modelos foram ajustados por métodos de interpolação baseados em funções polinomiais. Adicionalmente, foram atribuídos níveis de favorabilidade à doença decorrente de fungos em bananais, com base no conhecimento especialista e em dados da literatura. Algoritmos de fusão de imagens com base nas

transformadas IHS e PCA foram utilizados e implementados para gerar imagens com características adquiridas de diferentes sensores, ou seja, alta resolução espacial e espectral. No pré-processamento das imagens para a fusão, foram realizados testes com a aplicação de técnicas de krigagem para re-amostragem das imagens.

4.2 Metodologia

O modelo proposto envolve basicamente duas etapas. A primeira considera o uso de variáveis precipitação acumulada (P_p), temperaturas máxima (T_{max}) e mínima (T_{min}), umidade relativa (U_r), duração do período de molhamento foliar (DPM), nível de cinza (NC) e estado de evolução da doença (EE). A segunda etapa inclui o processamento de imagens satelitais. O diagrama apresentado na Figura 18 ilustra, de forma geral, as etapas envolvidas no desenvolvimento do modelo.

Séries temporais das variáveis meteorológicas escolhidas para o modelo, após tratamento de dados ausentes por interpolação linear, foram utilizadas para geração de modelos de probabilidade. Paralelamente foi realizado o processamento das imagens de satélite para extração dos valores de níveis de cinza (NC) dos pixels correspondentes à área de estudo. Os valores de NC são referentes à banda 4 ($0.75 \mu m$ a $0.9 \mu m$) de imagens do sensor TM Landsat-5, sob resolução espacial de 30 metros e referentes às órbitas-ponto 220/77, as quais foram obtidas entre fevereiro e dezembro de 2005.

Para melhoria da resolução espacial das imagens (de 30 a 5m), as técnicas de fusão foram utilizadas envolvendo imagens as imagens multiespectrais do TM Landsat-5 (30m) e a imagem pancromática de alta resolução (2,5m) do satélite

SPOT 5 (0,48 – 0,71 μ m), disponibilizadas no *Google Earth*.

Dessa forma, os valores de NC foram submetidos à modelagem probabilística, juntamente com os dados meteorológicos.

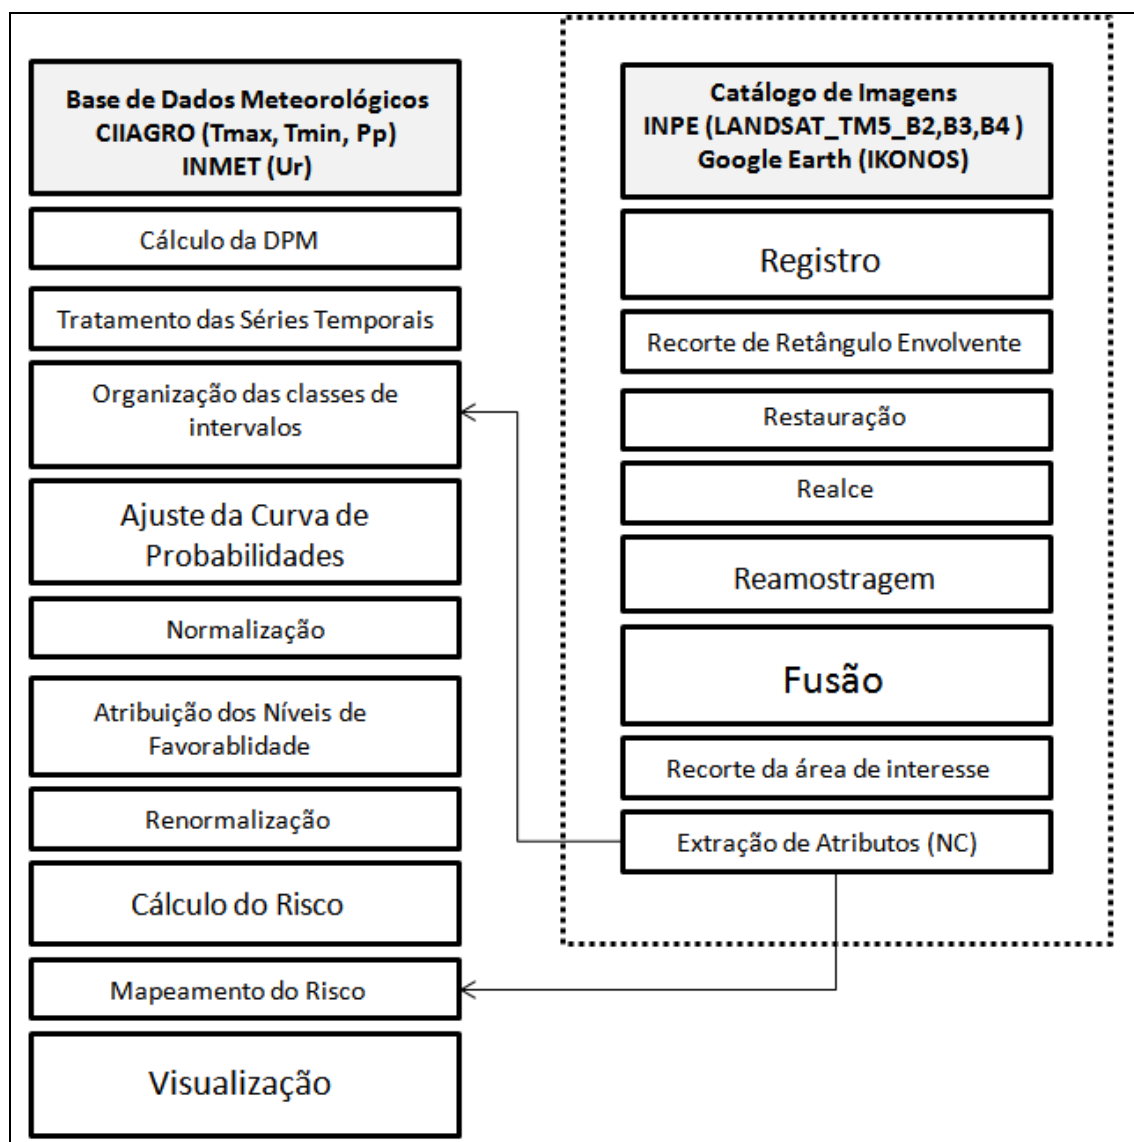


Figura 18. Diagrama de blocos da metodologia desenvolvida, onde o fluxo se dá da Entrada com as bases de dados meteorológicos e imagens e como Saída a visualização dos mapas de risco.

Na sequencia, após a seleção dos modelos, as probabilidades ajustadas pelo modelo são normalizadas entre 0 e 1 e, de acordo com o conhecimento especialista

sobre o desenvolvimento da doença, cada classe de intervalo de cada variável é classificada em níveis de favorabilidade a doença. Em seguida estes valores são renormalizados, de modo a se estabelecer 3 níveis de risco.

Finalmente, as probabilidades renormalizadas foram integradas sob uma Figura de mérito e o resultado apresentado em mapas de risco.

4.2.1 Aquisição das séries temporais

As séries temporais dos dados de Tmax, Tmin, Ur e Pp utilizadas foram adquiridas nas bases de dados das estações meteorológicas do CIIAGRO e INMET. Também, tais dados podem ser obtidos em sistemas online como o Agritempo (disponíveis em: <http://www.agritempo.gov.br>).

Os dados de duração do período de molhamento foliar (DPM) foram determinados utilizando a metodologia de Gasparotto (GASPAROTTO, 1988), onde o DPM é igual ao somatório do número de horas com umidade relativa superior a 90%.

4.2.2 Tratamento das Séries Temporais

Foi observado que a base de dados apresentava 12,08% de dados ausentes, especificamente para as variáveis obtidas nas estações convencionais (INMET). Não foram observados dados duvidosos. Tais dados foram corrigidas por interpolação linear.

4.2.3 Organização das classes de intervalos

Inicialmente, cada variável meteorológica foi organizada em classes. Tais classes foram baseadas na distribuição uniforme de um determinado número de intervalos, entre o valor máximo e mínimo, de cada variável.

4.2.4 Ajuste da curva de probabilidades

Foram calculadas as frequências relativas das classes e posteriormente, ajustadas por modelos polinomiais.

Os modelos polinomiais de diferentes ordens foram comparados e analisados. Os melhores modelos foram selecionados pelo coeficiente de determinação (R^2) e o erro padrão (ε) (WITTE, 2005), conforme as equações 38 e 39.

$$R^2 = \left[\frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} \right]^2 \quad (38)$$

$$\varepsilon = \sqrt{\frac{1}{n-2} \left[\sum (y - \bar{y})^2 - \frac{[\sum (x - \bar{x})(y - \bar{y})]^2}{\sum (x - \bar{x})^2} \right]} \quad (39)$$

onde:

- x representa o valor observado;
- y é o valor estimado;
- n é o total de observações consideradas na série temporal de dados;
- ε é o erro padrão calculado.

4.2.5 Normalização

Com os valores de probabilidade de ocorrência das classes ajustados pelo modelo, realizou-se uma normalização entre 0 e 1, a partir dos valores máximos e mínimos, utilizando a equação (40).

$$X_n = \frac{x_i - \min}{\max - \min} \quad (40)$$

onde:

- X_i é o valor a ser normalizado;
- i é o número de classes;
- \max e \min são os valores máximos e mínimos respectivamente.

4.2.6 Atribuição dos Níveis de Favorabilidade

A partir do conhecimento especialista e de dados da literatura sobre a relação entre as variáveis utilizadas e o desenvolvimento da doença, foram atribuídos níveis de favorabilidade a cada classe, sendo eles, alto, médio e baixo.

4.2.7 Re-normalização

Os valores de probabilidade foram re-normalizados, em função do nível de favorabilidade, utilizando a equação 40, sob o critério dos intervalos a seguir:

$$\begin{cases} 0,00 \leq \text{baixo} \leq 0,33 \\ 0,34 \leq \text{baixo} \leq 0,67 \\ 0,68 \leq \text{baixo} \leq 1,00 \end{cases}$$

Deste modo, foi composta uma *look-up-table* para cada variável, cuja estrutura é demonstrada na Figura 19.

Classe	Intervalo	Probabilidade re-normalizada	Risco
--------	-----------	------------------------------	-------

Figura 19. Estrutura dos campos das *Look-up-tables* geradas para cada variável do modelo.

4.2.8 Cálculo do Risco

Para cálculo do risco, foi utilizada a metodologia proposta por Cruvinel e colaboradores (CRUVINEL *et al.*, 2006), em que as probabilidades renormalizadas são plotadas nos eixos de uma circunferência de raio unitário e o risco total é correspondente à área inscrita obtida pela união dos vértices do polígono formado, que pode ser determinado pela soma das áreas dos triângulos formados dentro da figura de mérito, conforme ilustra o exemplo apresentado na Figura 20. Uma vez conhecidos um dos ângulos e os dois lados de cada triângulo a área total da figura pode ser determinada pela equação (41):

$$a_t = \frac{\sum_{i=1}^6 a_i b_i \text{sen}(x)}{2} \tag{41}$$

onde:

- a_t é área total da figura;
- i é o número de variáveis, neste estudo são considerados 6 (Figura 15);
- a e b são os lados conhecidos dos triângulos;
- α o ângulo é formado entre os vetores, neste caso, 60° .

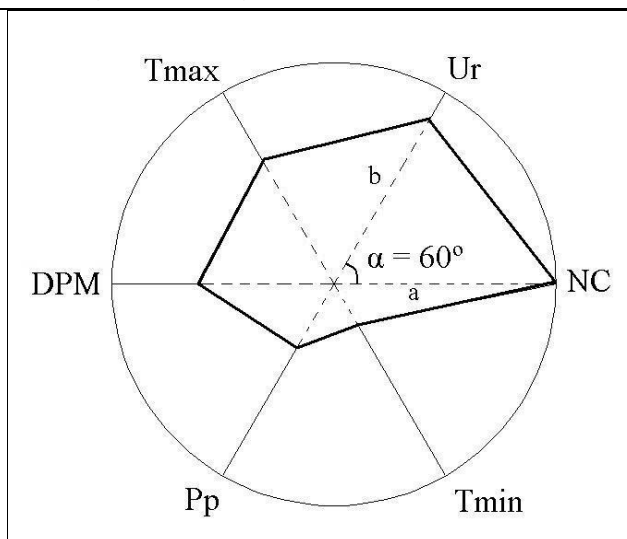


Figura 20. Exemplo de figura de mérito para cálculo da área integrada.

O risco total de ocorrência da Sigatoka Negra é a relação de intersecção entre as probabilidades re-normalizadas de ocorrência da respectiva classe de cada variável (Equação 42), ou seja:

$$P(\text{risco}) = P(T \text{ min}) \cap P(T \text{ max}) \cap P(Pp) \cap P(Ur) \cap P(DPM) \cap P(NC) \quad (42)$$

Com relação às variáveis meteorológicas, a variação do modelo é global, ou seja, existe um valor para a área toda e a variação é local no caso da variável NC, sendo a espacialização do risco determinada pela resolução espacial da imagem de satélite. Então, a partir deste ponto são geradas figuras de mérito para cada data correspondente a das imagens de satélite.

No caso da variável NC, devido sua variação local, a mesma pode assumir diferentes valores, em função do nível de favorabilidade em que o valor do pixel se encontra classificado.

4.2.9 Processamento Digital de Imagens

4.2.9.1 Registro de imagens

O primeiro passo para o pré-processamento de imagens consiste na realização do registro. A Figura 21 apresenta o diagrama de blocos para a realização do processo de registro.

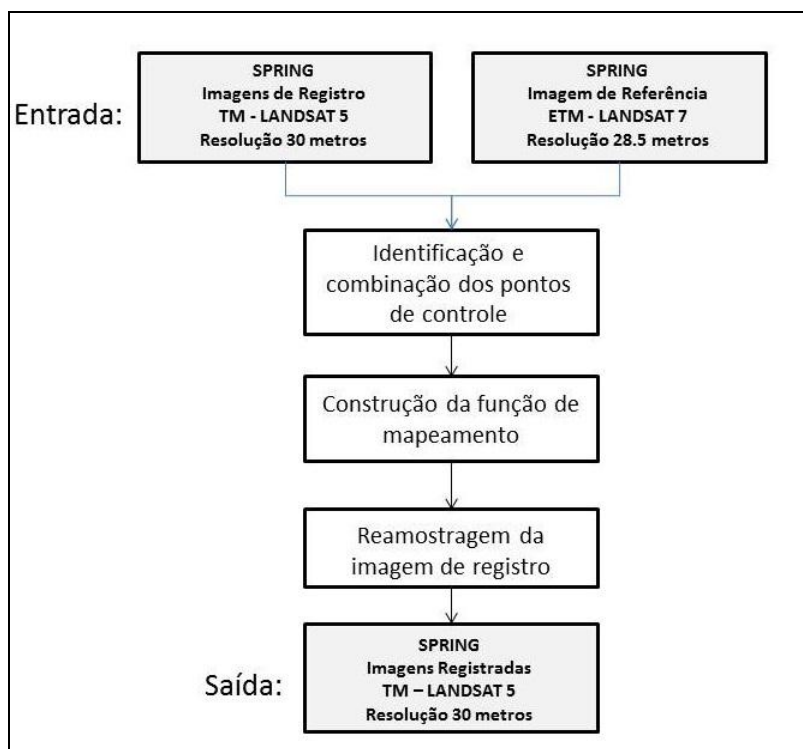


Figura 21. Diagrama de blocos da operação de registro de imagens.

Como se pode observar, a identificação e combinação dos pontos de controle são executadas no mesmo bloco, onde a operação será realizada manualmente, o que permite com que sejam realizadas simultaneamente.

Adicionalmente, é feita a correção radiométrica por meio da restauração de imagens, para eliminar erros provenientes dos sensores e da transmissão da

imagem do satélite para a plataforma terrestre, oriundos das distorções atmosféricas. Finalmente, as imagens são reamostradas, por meio do algoritmo bilinear, para ajustar o tamanho do pixel para o processo de fusão.

A correção radiométrica visa corrigir ruídos e distorções nas imagens causadas durante a transmissão entre os sensores ópticos e o receptor terrestre. Pode ser realizada por um filtro linear, obtido a partir das características específicas do sensor, da banda espectral e do tamanho do pixel da imagem de saída (5m, 10m, 15m, 20m) (FONSECA *et al.*, 1993). A restauração de imagens é uma técnica de correção radiométrica que visa à reconstrução ou recuperação da imagem que foi degradada utilizando um conhecimento a priori do fenômeno de degradação. A ideia é, através da modelagem da degradação, aplicar o processo inverso para obter uma aproximação da imagem original (GONZALEZ E WOODS, 2001).

De acordo com Papa *apud* Stark, numerosos métodos de restauração de imagens têm sido desenvolvidos para várias aplicações, dentre eles o filtro inverso, filtro de Wiener, técnicas de regularização e métodos de programação linear. Outra abordagem que tem sido amplamente referenciada é a que utiliza métodos de projeção (STARK E YANG, 1998).

Dentre eles podemos destacar o método de projeções em conjuntos convexos (POCS), também conhecido como método de projeções convexas, o qual utiliza informações a priori das imagens na forma de conjuntos de restrição a fim de tentar solucionar o problema (STARK, 1988).

Neste trabalho foi utilizado um método direto de restauração. Os métodos diretos são aqueles que necessitam de um único passo para encontrar uma solução para o problema. Estes métodos também são conhecidos como filtros clássicos por serem mais comumente difundidos. (PAPA, 2004).

O processo de degradação foi modelado como um operador ou sistema físico (H), que juntamente com um termo de ruído aditivo $n(x,y)$ opera sobre uma imagem de entrada $f(x,y)$ para produzir uma imagem degradada $g(x,y)$, conforme modelo visto na Figura 22 (GONZALEZ E WOODS, 2001).




Figura 22. Modelo do processo de degradação da imagem. FONTE: (GONZALEZ E WOODS, 2000).

A restauração de imagens digitais pode ser vista como o processo de obtenção de uma aproximação de $f(x,y)$ dada $g(x,y)$ e um conhecimento sobre a degradação na forma do operador H.

De modo geral, o problema de restauração consiste em recuperar a imagem original da melhor maneira possível (MASCARENHAS E VELASCO, 1984).

4.2.9.2 Realce

O realce de imagem foi executado pela alteração dos níveis digitais por meio da avaliação da forma do histograma. Uma imagem escura ou clara pode ser pouco ou muito contrastada, isto é, com pouca variância, dificultando a discriminação de alvos e, portanto, caracterizada pelo seu baixo valor de contraste. Para o aumento de contraste de imagens digitais pode ser usada uma transformação que multiplique o valor do pixel por uma constante (a) neste caso, a variância é aumentada.

Por meio de uma transformação linear, uma imagem pode ter seu contraste e brilho aumentado com o objetivo de melhorar a apreciação pelo olho humano. O resultado da transformação facilitou a realização de análises qualitativas onde estão incluídos o aumento de contraste (a) e o deslocamento da média, a alteração do brilho (b), conforme a equação 43:

$$g(x) = f(x) \cdot a + b \quad (43)$$

A mudança do histograma, para fins de fusão de imagens, consiste em ajustar o histograma da imagem de maior resolução espacial de maneira que este fique semelhante ao histograma da imagem intensidade. Com isto, as características espectrais da imagem não são alteradas.

4.2.9.3 Re-amostragem

Para realização da fusão, as imagens foram colocadas sob a mesma grade regular, possuindo a mesma resolução espacial. Assim, foram testadas diferentes técnicas de re-amostragem, sendo elas, vizinho-mais-próximo, bilinear e krigagem.

A Figura 23 ilustra o módulo de procedimentos geoestatísticos, integrado ao sistema SPRING, tem como objetivo a análise em duas dimensões, para dados espacialmente distribuídos, no que diz respeito à inferência de superfícies geradas a partir de amostras georreferenciadas (SILVA e RIBEIRO, 2008).

Inicialmente sobre o dado de entrada, neste caso proveniente de um Plano de Informação (PI), é realizada uma análise exploratória através de estatísticas univariadas e bivariadas.

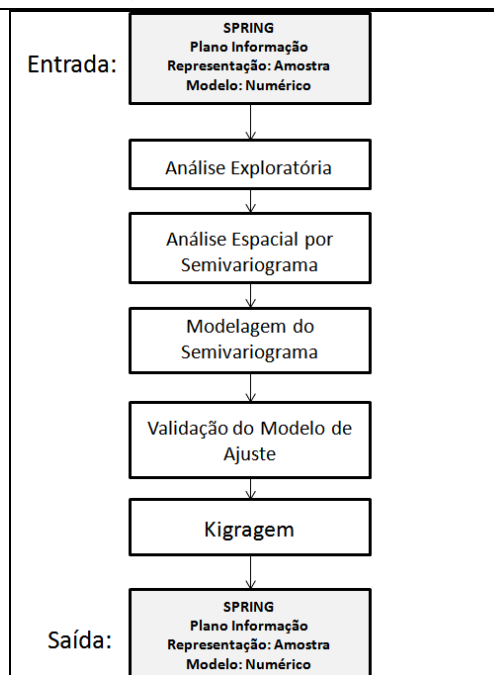


Figura 23. Organização esquemática do módulo de geoestatística do SPRING.

As estatísticas univariadas fornecem um meio de organizar e sintetizar um conjunto de valores, que se realiza principalmente através do histograma. As estatísticas bivariadas fornecem meios de descrever o relacionamento entre duas variáveis, isto é, entre dois conjuntos de dados ou de duas distribuições. Essa relação pode ser visualizada através do diagrama de dispersão. Seguindo, uma análise de continuidade espacial baseada em semivariograma é realizada. A análise completa do semivariograma compreende os seguintes passos:

Passo 1: Levantamento do semivariograma experimental;

Passo 2: Ajuste a uma família de modelos de semivariogramas;

Passo 3: Validação do modelo a ser utilizado nos procedimentos da krigagem.

Para finalizar, a inferência dos dados é realizada utilizando as técnicas de krigagem e o resultado armazenado num Plano de Informação do sistema SPRING. Os procedimentos gerais que compõem o módulo estão agrupados no menu principal do SPRING, conforme mostra a Figura 24.

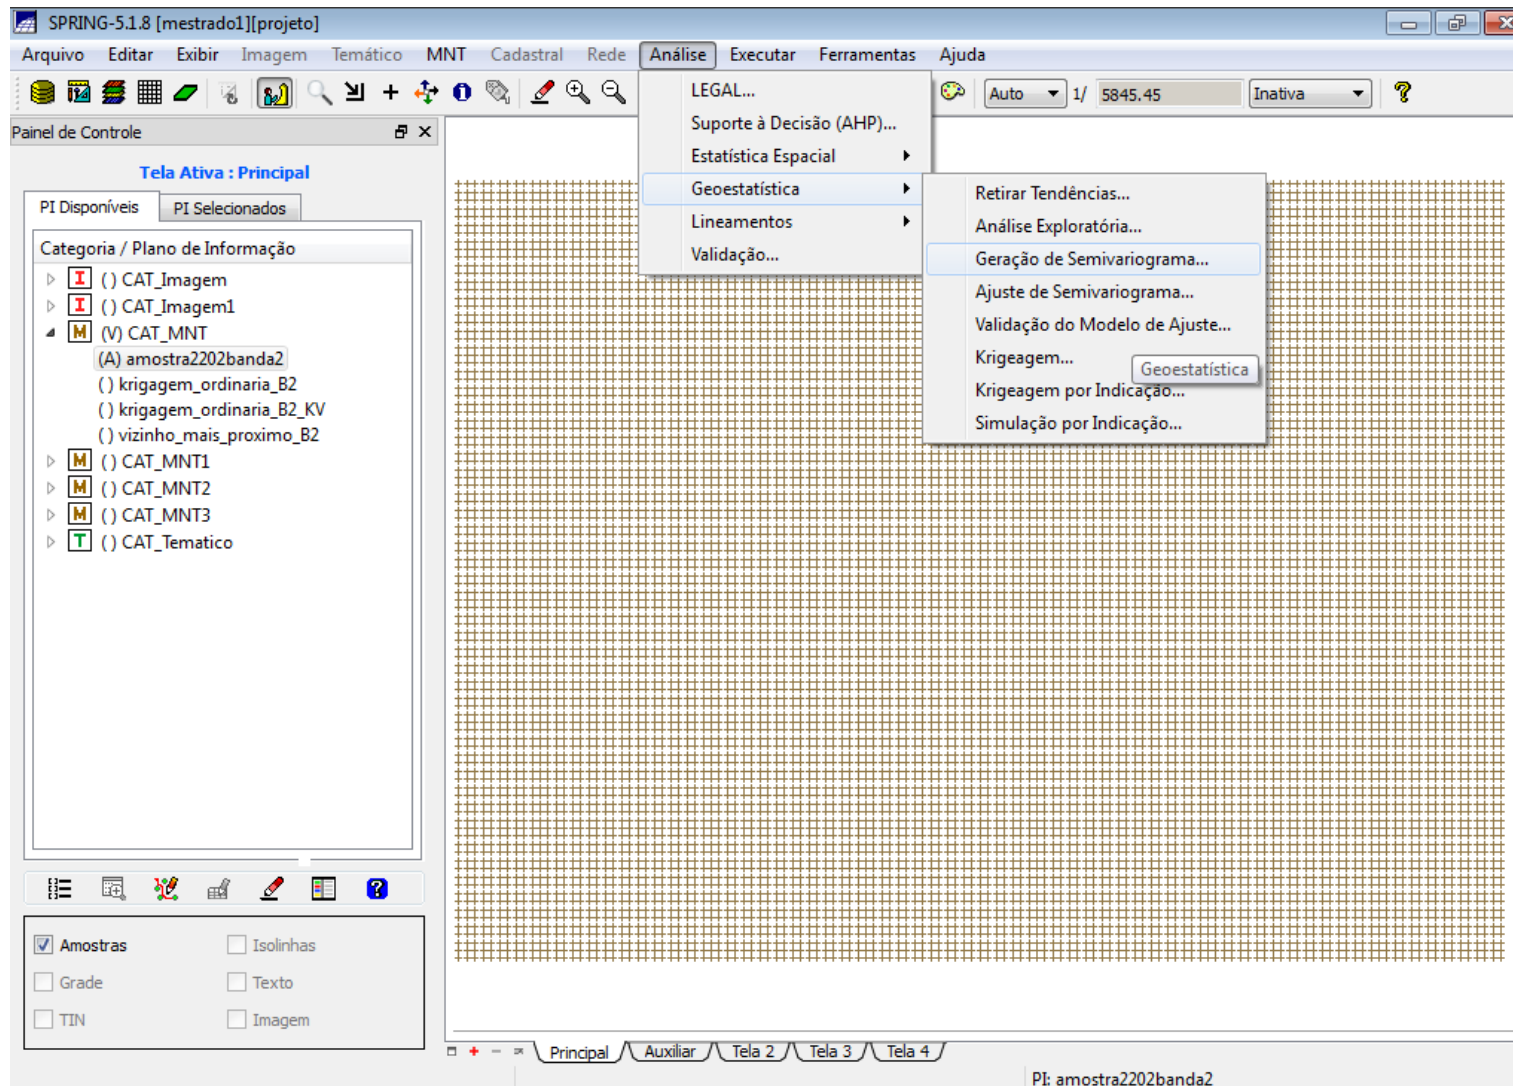


Figura 24. Tela principal do sistema SPRING, com ênfase no módulo de geoestatística. (Fonte: SPRING, 1996)

4.2.9.4 Fusão das imagens

A etapa de fusão de imagens tem por objetivo melhorar a resolução, tanto espacial quanto espectral, da imagem que será utilizada como entrada no sistema de monitoramento de risco. As Figuras 25 e 26 apresentam, respectivamente, os fluxogramas simplificados dos métodos de fusão por IHS e PCA.

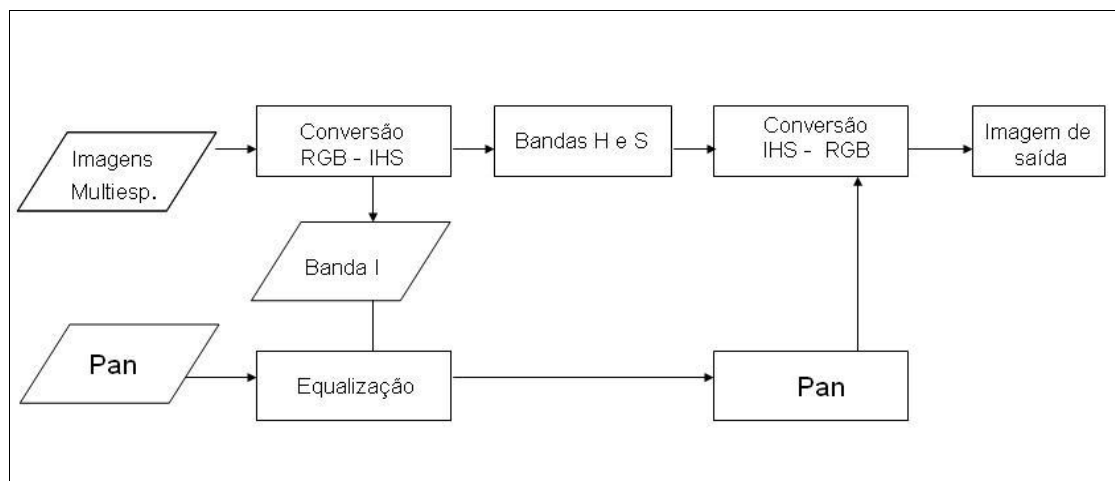


Figura 25. Fluxograma de blocos para a operação de fusão pelo método IHS.

Como ilustrado na Figura 25, para a fusão por IHS, primeiramente é realizada transformação do sistema RGB para IHS, onde a componente I é isolada e substituída pela imagem pancromática, após um processo de equalização de contraste entre as duas imagens e compatibilização do tamanho do pixel por meio da re-amostragem. Posteriormente, realiza-se a transformação inversa, do sistema IHS, com a imagem pancromática, para RGB de modo a obter o produto da fusão, contendo as características coloridas das imagens multiespectrais e a alta resolução da imagem pancromática.

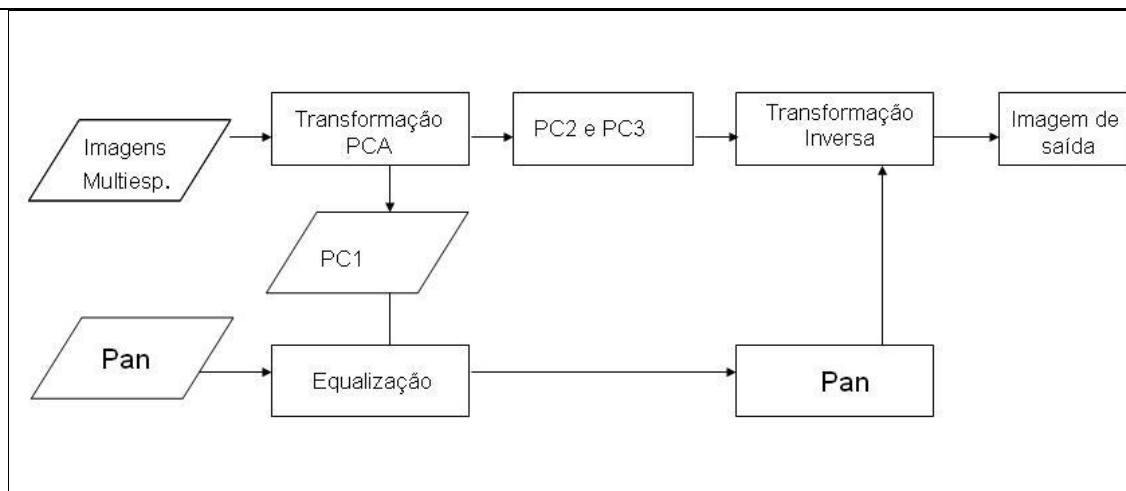


Figura 26. Fluxograma de blocos para a operação de fusão pelo método PCA.

Conforme apresentado na Figura 26 observa-se o processo de fusão PCA, que possui a mesma sequência da fusão IHS, entretanto a transformação realizada é baseada em projeções lineares, pelas Principais Componentes, sendo que a primeira componente (PC1) que será substituída pela imagem pancromática.

4.2.9.4.1 Índices de Qualidade de Imagens (IQI)

Na avaliação dos resultados da fusão de imagens, foi utilizado o índice IQI (*Image Quality Index*) (WANG e BOVIK, 2002). Com este índice é possível comparar os resultados obtidos, adotando-se como referência, as imagens resultantes das transformações IHS e PCA, que possuem as imagens HR com o histograma corrigido em relação a primeira componente principal (PC1) ou a componente intensidade (I).

Para tanto se utiliza a combinação de três fatores entre a imagem referência e as imagens a serem testadas: perda da correlação, distorção da luminosidade e distorção do contraste.

A Equação 44 ilustra o produto destes três fatores:

$$Q = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \cdot \frac{2\bar{xy}}{(\bar{x})^2 + (\bar{y})^2} \cdot \frac{2\sigma_x \sigma_y}{\sigma_x^2 \sigma_y^2} \quad (44)$$

onde:

$$\begin{cases} \bar{x} = \frac{1}{N} \sum_{i=1}^N x_i \\ \bar{y} = \frac{1}{N} \sum_{i=1}^N y_i \end{cases} \quad (45)$$

$$\begin{cases} \sigma_x^2 = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \\ \sigma_y^2 = \frac{1}{N-1} \sum_{i=1}^N (y_i - \bar{y})^2 \end{cases} \quad (46)$$

$$\sigma_{xy} = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x}) \cdot (y_i - \bar{y}) \quad (47)$$

O primeiro termo, expresso pela equação 45, representa o coeficiente de correlação linear entre x e y, sendo x a imagem gerada da transformação que passou por correção de histograma e y a imagem resultante da transformação utilizando seu histograma original. Este primeiro termo mede o grau de correlação linear entre x e y, num intervalo de -1 a 1.

O segundo termo, expresso pela equação 46, ocorre em um intervalo entre 0 e 1 e mede a proximidade da média da luminosidade entre x e y.

Finalmente o terceiro termo, expresso pela equação 47 mede a similaridade entre contrastes das duas imagens por meio de σ_x e σ_y , os quais representam o desvio padrão das medidas (WANG e BOVIK, 2002).

4.2.9.5 Recorte da área de interesse

A fim de delimitar a área de interesse para aplicação da metodologia, foi realizado um recorte da imagem, por meio de uma máscara definida pelos limites geográficos da propriedade, coletados por um GPS¹¹.

4.2.9.6 Extração de Atributos

Para extração dos atributos das imagens, foram utilizadas as imagens da banda 4, que compreendem a energia refletida no espectro do infravermelho próximo (0,75 – 0,9µm) , onde se é possível detectar alterações significativas na vegetação.

Desta forma, uma vez extraídos os valores de NC, foi realizada uma análise com regressão polinomial para os valores de NC dos pixels correspondentes a coordenada geográfica onde a doença foi monitorada e os valores de EE referentes à data de monitoramento mais próxima a data da imagem.

A variável do Estado de Evolução (EE) foi obtida a partir do método descrito por Fouré e co-autores (FOURÉ *et al.*, 1988), citado e ajustado por Moraes e colaboradores (MORAES *et al.*, 2005) onde são avaliados os sintomas iniciais da doença, em amostras de 10 plantas para cada 50 hectares. O método considera o ritmo de emissão foliar semanal (REFx) e a severidade da doença (Sev) na segunda, terceira e quarta folha, a partir da folha mais nova da planta ou folha “vela”, em dez plantas amostradas em até 50 hectares, a qual é definida pela Equação 46.

$$EE = Sev \cdot REFx \quad (46)$$

¹¹ Sistema de Posicionamento Global, GPS (*Global Positioning System*) é um sistema de navegação por satélite que fornece a um aparelho receptor móvel a posição do mesmo (Latitude e Longitude), assim como informação horária e a altitude.

Portanto, a severidade da doença foi determinada com base na qualificação e quantificação dos estádios precoces do desenvolvimento dos sintomas da doença (1. ponto; 2. traço; e 3. estria), observados na face abaxial da segunda, terceira e quarta folha das dez plantas amostradas. O estado da evolução foi expresso pelo produto do somatório da pontuação obtida com base nos coeficientes de gravidade (Quadro 1), a partir da quantificação do estágio precoce mais evoluído do desenvolvimento dos sintomas, observado nas folhas amostradas de cada planta, pelo ritmo de emissão foliar ponderado entre as dez plantas.

Quadro 1. Pontuação ou coeficiente de gravidade da Sigatoka-negra em função da folha afetada.

Estádio ¹²	Número da Folha		
	II	III	IV
-1	60	40	20
+1	80	60	40
-2	100	80	60
+2	120	100	80
-3	140	120	100
+3	160	140	120

A partir da curva ajustada, foram determinados os níveis de favorabilidade com base em uma estimativa dos valores de referência do campo, onde valores de EE até 1400 foram considerados baixos, entre 1400 e 1700, médios e acima de 1700 considerados altos.

¹² O sinal – ou + significa mais ou menos de 50 unidades do estágio mais evoluído do desenvolvimento dos sintomas da doença.

4.2.10 Mapeamento do Risco

Para geração do mapa de risco, cada valor da matriz de NC é substituído pelo valor de risco conforme estabelecido na Equação 42, referente a respectiva data.

A visualização dos mapas foram obtidas por meio do processo de fatiamento, implementado via SPRING, de forma que a cor verde representa risco baixo, a cor amarela representa risco médio e a cor vermelha representa risco alto de ocorrência da Sigatoka Negra.

Capítulo 5

RESULTADOS E CONCLUSÕES

5.1.1 Introdução

Para validação do modelo foi realizado um estudo de validação do método em condições reais, junto a uma propriedade de bananicultura, contendo uma área de 20 hectares de produção de cultivar Grand Naine. A propriedade está localizada no Bairro do Guaraú, Município de Jacupiranga, no Vale do Ribeira, Estado de São Paulo, nas coordenadas $24^{\circ} 52' 53,8''$ S e $48^{\circ} 06' 22,1''$ W. Nesta propriedade, a Sigatoka Negra foi monitorada a campo, pelo método de Fouré, de Fevereiro a Dezembro de 2005. A Figura 27 exhibe a localização da área.

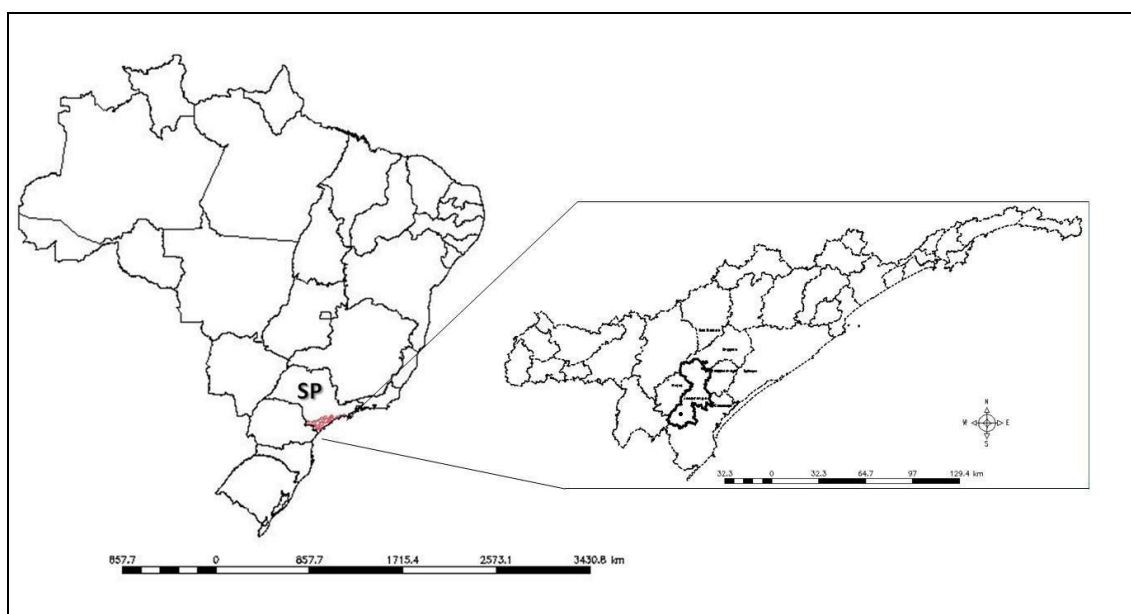


Figura 27. Localização da área utilizada para validação do método.

O monitoramento da doença fúngica foi realizado semanalmente onde foram obtidos dados de Estado de Evolução (EE). As variáveis meteorológicas utilizadas estão disponíveis na estação meteorológica do Centro Integrado de Informações Agrometeorológicas (CIIAGRO), localizada no município de Jacupiranga-SP e na estação de superfície convencional do Instituto Nacional de Meteorologia (INMET), localizada no município de Iguape-SP. As variáveis consideradas foram a temperatura máxima (T_{max}) e mínima (T_{min}), a precipitação acumulada (P_p), umidade relativa (U_r) e duração do período de molhamento foliar (DPM). Para T_{max} , T_{min} e P_p , a frequência de observação dos dados foi diária. No caso da U_r , foram obtidos dados horários, sendo que os dados ausentes, na série temporal, foram preenchidos por interpolação linear. Os dados de DPM foram calculados a partir do somatório de horas com U_r superior a 90%. Para realização deste trabalho, as séries temporais dos dados meteorológicos foram organizadas com valores médios semanais. A seguir serão apresentados resultados da análise descritiva das variáveis utilizadas no modelo.

5.1.1.1 Temperatura Máxima (T_{max})

A temperatura máxima média semanal em graus Celsius (T_{max}) é obtida pela média das temperaturas máximas diárias dos registros meteorológicos para o período de uma semana. Como pode ser visualizado na Tabela 3, entre as medidas descritivas desta variável, observou-se uma média de 28,34°C, valor mínimo de 19,13°C, valor máximo de 35,94°C e mediana de 28,26°C, o que indica que 50% dos registros apresentaram valores menores ou iguais a este valor. A Figura 28 ilustra o gráfico de caixa dos valores de T_{max} , em que se pode verificar que 25% das observações apresentam valores menores ou iguais a 25,39 °C, valores que

correspondem ao primeiro quartil. Neste caso, o modelo escolhido foi o polinomial de quinta ordem, cujos valores de R^2 e erro padrão foram respectivamente 0,8937 e 0,0730.

Tabela 3. Número de medidas N e medidas descritivas de Tmax [°C].

<i>Variável</i>	<i>Grandeza</i>
N	157
Média	28,34
Mediana	28,26
Desvio padrão	3,48
Variância	12,12
Mínimo	19,13
Máximo	35,94
Q1	25,39
Q2	28,26
Q3	30,89




Figura 28. Gráfico de caixa para os valores de Tmax.

A curva de distribuição das probabilidades com a curva do modelo polinomial ajustado e sua respectiva equação é apresentada na Figura 29. Assim, para esta variável, considera-se como *look-up-table* a Tabela 4, em que são demonstrados os intervalos das classes, as respectivas probabilidades determinadas pelo modelo escolhido renormalizadas, bem como os níveis de favorabilidade a ocorrência da Sigatoka-negra.




Figura 29. Ajuste do modelo para a função de probabilidades para a variável Tmax [°C], referente ao polinômio selecionado.

Tabela 4. Intervalos das classes, probabilidades ajustadas pelo modelo e os respectivos níveis de risco.

<i>Classes</i>	<i>Intervalo [°C]</i>	<i>Probabilidade pelo modelo ajustado</i>	<i>Risco</i>
1	19,13 - 20,81	0,3300	baixo
2	20,82 - 22,50	0,5268	médio
3	22,51 - 24,19	0,6700	médio
4	24,20 - 25,88	0,8917	alto
5	25,89 - 27,58	1,0000	alto
6	27,59 - 29,27	0,9207	alto
7	29,28 - 30,96	0,6800	alto
8	30,97 - 32,65	0,5403	médio
9	32,66 - 34,34	0,3400	médio
10	34,35 - 36,03	0,0000	baixo

5.1.1.2 Temperatura Mínima (Tmin)

A temperatura mínima média semanal foi obtida considerando a média das temperaturas mínimas diárias dos registros de uma semana durante todo o período de Fevereiro a Dezembro de 2005. Como observado na Tabela 5 entre as medidas descritivas desta variável, observou-se uma média de 17,23°C, mínimo de 7,57°C,

máximo de 22,67°C e mediana de 17,51°C, o que indica que 50% dos registros apresentaram valores menores ou iguais ao valor dado pela mediana encontrada. A Figura 30 ilustra o gráfico de caixa para os valores de T_{min}, onde se pode verificar que 25% das observações apresentam valores menores ou iguais a 15,00°C, valores que correspondem ao primeiro quartil.

Tabela 5. Número de medidas N e medidas descritivas de T_{min} [°C].

<i>Variável</i>	<i>Grandeza</i>
N	157
Média	17,23
Mediana	17,51
Desvio Padrão	3,38
Variância	11,42
Mínimo	7,57
Máximo	22,67
Q1	15,00
Q2	17,51
Q3	20,14

Foram avaliados polinômios da segunda a sexta ordem, tomando por base os respectivos coeficientes de determinação e os erros associados. O modelo selecionado com base no coeficiente de correlação e o erro padrão foi o descrito pelo polinômio de terceira ordem, cujos valores de R² e erro padrão foram de 0,9307 e 0,0221 respectivamente.




Figura 30. Gráfico de caixa para dos valores de Tmin.

A curva de distribuição das probabilidades com a curva do modelo polinomial ajustado e sua respectiva equação é apresentada na Figura 31.




Figura 31. Ajuste do modelo para a função de probabilidades para a variável Tmin [°C], referente ao polinômio selecionado.

A Tabela 6 apresenta os intervalos das classes, as respectivas probabilidades determinadas pelo modelo escolhido renormalizadas, bem como os níveis de favorabilidade a ocorrência da Sigatoka-negra.

Tabela 6. Intervalos das classes, probabilidades ajustadas pelo modelo e os respectivos níveis de risco.

<i>Classes</i>	<i>Intervalo [°C]</i>	<i>Probabilidade pelo modelo ajustado</i>	<i>Risco</i>
1	7,57 - 9,08	0,0000	baixo
2	9,09 - 10,6	0,0680	baixo
3	10,61 - 12,12	0,1840	baixo
4	12,13 - 13,64	0,3300	baixo
5	13,65 - 15,16	0,3400	médio
6	15,17 - 16,68	0,5191	médio
7	16,69 - 18,2	0,6700	médio
8	18,21 - 19,72	0,8400	alto
9	19,73 - 21,24	1,0000	alto
10	21,25 - 22,76	0,6800	alto

5.1.1.3 Precipitação acumulada (Pp)

A precipitação acumulada durante uma semana, registrada em milímetros (mm) é a quantidade de chuva por metro quadrado.

Como pode ser observado na Tabela 7, entre as medidas descritivas desta variável, observou-se uma média de 32,5 mm, sendo a medida mínima igual a 0,0 mm e a máxima de 200,9 mm, bem como mediana de 21,8 mm. Assim, 50% dos registros tiveram valores menores ou iguais ao valor obtido para a mediana.

A Figura 32 ilustra o gráfico de caixa para os valores de Pp, em que se pode verificar que 25% das observações apresentam valores menores ou iguais a 1,6 mm, as quais correspondem ao primeiro quartil.

Foram avaliados polinômios da segunda a sexta ordem, tomando por base os respectivos coeficientes de determinação e os erros associados.

O modelo selecionado com base no coeficiente de correlação e o erro padrão foi o descrito pelo polinômio de quarta ordem, cujos valores de R^2 e erro padrão foram de 0,9825 e 0,1011 respectivamente.

Tabela 7. Número de coletas e medidas para precipitação acumulada [mm].

<i>Variável</i>	<i>Grandeza</i>
N	157
Média	32,46
Mediana	21,8
Desvio padrão	38,45
Variância	1478,66
Mínimo	0,0
Máximo	200,9
Q1	1,6
Q2	21,8
Q3	47,8




Figura 32. Gráfico de caixa para os valores de Pp.

A curva de distribuição das probabilidades com a curva do modelo polinomial ajustado e sua respectiva equação é apresentada na Figura 33.

Considera-se como *look-up-table* para esta variável a Tabela 8, onde são demonstrados os intervalos das classes, as respectivas probabilidades determinadas pelo modelo escolhido renormalizadas, bem como os níveis de favorabilidade a ocorrência da Sigatoka-negra.




Figura 33. Ajuste do modelo para a função de probabilidades para a variável Pp [mm], referente ao polinômio selecionado.

Tabela 8. Intervalos das classes, probabilidades ajustadas pelo modelo e os respectivos níveis de risco.

<i>Classes</i>	<i>Intervalo (mm)</i>	<i>Probabilidade pelo modelo ajustado</i>	<i>Risco</i>
1	0,00 - 20,09	0,3300	baixo
2	20,10 - 40,19	0,0000	baixo
3	40,20 - 60,29	0,6700	médio
4	60,30 - 80,39	0,6238	médio
5	80,40 - 100,49	0,6014	médio
6	100,50 - 120,59	1,0000	alto
7	120,60 - 140,69	0,9272	alto
8	140,70 - 160,79	0,8171	alto
9	160,80 - 180,89	0,6800	alto
10	180,90 - 200,99	0,3400	médio

5.1.1.4 Umidade Relativa (UR)

A umidade relativa média semanal, dada em porcentagem, é obtida pela média dos valores diários registrados durante uma semana. Como observado na Tabela 9, entre as medidas descritivas desta variável, observou-se uma média de 86,82%, mínimo de 77,51%, máximo de 92,44% e mediana de 87,65%, indicando que 50% dos registros realizados foram menores ou iguais ao valor da mediana.

A Figura 34 ilustra o gráfico de caixa para esta variável e permite observar que 25% das observações apresentam valores menores ou iguais a 84,53%, o que corresponde ao primeiro quartil.

Foram avaliados polinômios da segunda a sexta ordem, tomando por base os respectivos coeficientes de determinação e os erros associados. O modelo selecionado com base no coeficiente de correlação e o erro padrão foi o descrito pelo polinômio de quinta ordem, cujos valores de R^2 e erro padrão foram de 0,6847 e 0,0458 respectivamente.

Tabela 9. Número de registros e medidas descritivas de UR [%].

<i>Variável</i>	<i>Grandeza</i>
N	48
Média	86,82
Mediana	87,65
Desvio padrão	3,93
Variância	15,48
Mínimo	77,51
Máximo	92,44
Q1	84,53
Q2	87,65
Q3	89,71




Figura 34. Gráfico de caixa para os valores de UR.

A curva de distribuição das probabilidades com a curva do modelo polinomial ajustado e sua respectiva equação é apresentada na Figura 35. Assim, para esta variável, considera-se como *look-up-table* a Tabela 10, onde são demonstrados os intervalos das classes, as respectivas probabilidades determinadas pelo modelo escolhido renormalizadas, bem como os níveis de favorabilidade a ocorrência da Sigatoka-negra.




Figura 35. Ajuste do modelo para a função de probabilidades para a variável Ur [%], referente ao polinômio selecionado.

Tabela 10. Intervalos das classes, probabilidades ajustadas pelo modelo e os respectivos níveis de risco.

Classes	Intervalo	Probabilidade pelo modelo ajustado	Risco
1	77,51 - 79,00	0,0000	baixo
2	79,01 - 80,49	0,3300	baixo
3	80,50 - 81,99	0,6700	médio
4	82,00 - 83,48	0,3400	médio
5	83,49 - 84,98	0,6503	médio
6	84,99 - 86,47	0,7040	alto
7	86,48 - 87,96	0,7497	alto
8	87,97 - 89,46	0,8149	alto
9	89,47 - 90,95	0,8977	alto
10	90,96 - 92,44	1,0000	alto

5.1.1.5 Duração do Período de Molhamento Foliar (DPM)

O período de molhamento foliar é atribuído pelo período de tempo em que a superfície das folhas se apresenta coberta pelo orvalho. Esta variável foi estabelecida considerando a soma do número de horas em que ocorreu umidade relativa superior a 90%, também para o período de uma semana. Observou-se, conforme ilustra a Tabela 11, que para 48 medidas houve uma média de 87h28min, um mínimo de 33h00min, máximo de 133h00min e mediana de 90h30min. A Figura 36 ilustra o gráfico de caixa para a variável e permite determinar que 25% das observações apresentam valores menores ou iguais a 67h45min. Foram avaliados polinômios da segunda a sexta ordem, tomando por base os respectivos coeficientes de determinação e os erros associados. O modelo selecionado com base no coeficiente de correlação e o erro padrão foi o descrito pelo polinômio de sexta ordem, cujos valores de R^2 e erro padrão foram de 0,7397 e 0,9474 respectivamente.

Tabela 11. Número de registros e medidas descritivas de DPM [h].

<i>Variável</i>	<i>Grandeza</i> ¹³
N	48
Média	87h28min
Mediana	90h30min
Desvio padrão	25h34min
Variância	654h04min
Mínimo	33h00min
Máximo	133h00min
Q1	67h45min
Q2	90h30min
Q3	87h28min

¹³ Os intervalos de tempo atribuídos para a definição das dez classes para a série temporal de dados de DPM foram deixados conforme divisão de tempo em horas e minutos respectivamente.




Figura 36. Gráfico de caixa para os valores de DPM.

A curva de distribuição das probabilidades com a curva do modelo polinomial ajustado e sua respectiva equação é apresentada na Figura 37.

Assim, para esta variável, considera-se a Tabela 12 onde são demonstrados os intervalos das classes, as respectivas probabilidades determinadas pelo modelo escolhido, bem como os níveis de favorabilidade a ocorrência da Sigatoka-negra.




Figura 37. Ajuste do modelo para a função de probabilidades para a variável DPM [h], referente ao polinômio selecionado.

Tabela 12 - Intervalos das classes, probabilidades ajustadas pelo modelo e os respectivos níveis de risco.

<i>Classes</i>	<i>Intervalo</i>	<i>Probabilidade pelo modelo ajustado</i>	<i>Risco</i>
1	33h - 43h	0,0000	baixo
2	44h - 53h	0,6700	médio
3	54h - 63h	0,3400	médio
4	64h - 73h	0,6373	alto
5	74h - 83h	0,6537	alto
6	84h - 93h	0,6800	alto
7	94h - 103h	0,7149	alto
8	104h - 113h	0,7640	alto
9	114h - 123h	0,8462	alto
10	124h - 133h	1,0000	alto

5.1.2 Processamento de Imagens

Foram adquiridas, mediante a disponibilidade, 6 cenas do sensor TM do satélite Landsat 5, com resolução espacial de 30 metros e referentes às órbitas-ponto 220/77, entre fevereiro e dezembro de 2005. As imagens estão disponíveis no catálogo de imagens de satélite do Instituto Nacional de Pesquisas Espaciais (INPE) (<http://www.dgi.inpe.br>).

Cada cena do sensor TM é composta por 7 imagens, referentes as 7 bandas multiespectrais do sensor TM, do Landsat 5. Neste estudo foram utilizadas as imagens de 3 bandas, sendo elas a banda 2 (0,52 – 0,6 μ m), 3 (0,63 – 0,69 μ m) e 4 (0,75 – 0,9 μ m), totalizando 18 imagens.

5.1.2.1 Registro de Imagens

A Figura 38 ilustra a tela de registro do software SPRING, com a visualização e seleção dos pontos de controle utilizados para ajuste da função de transformação espacial.

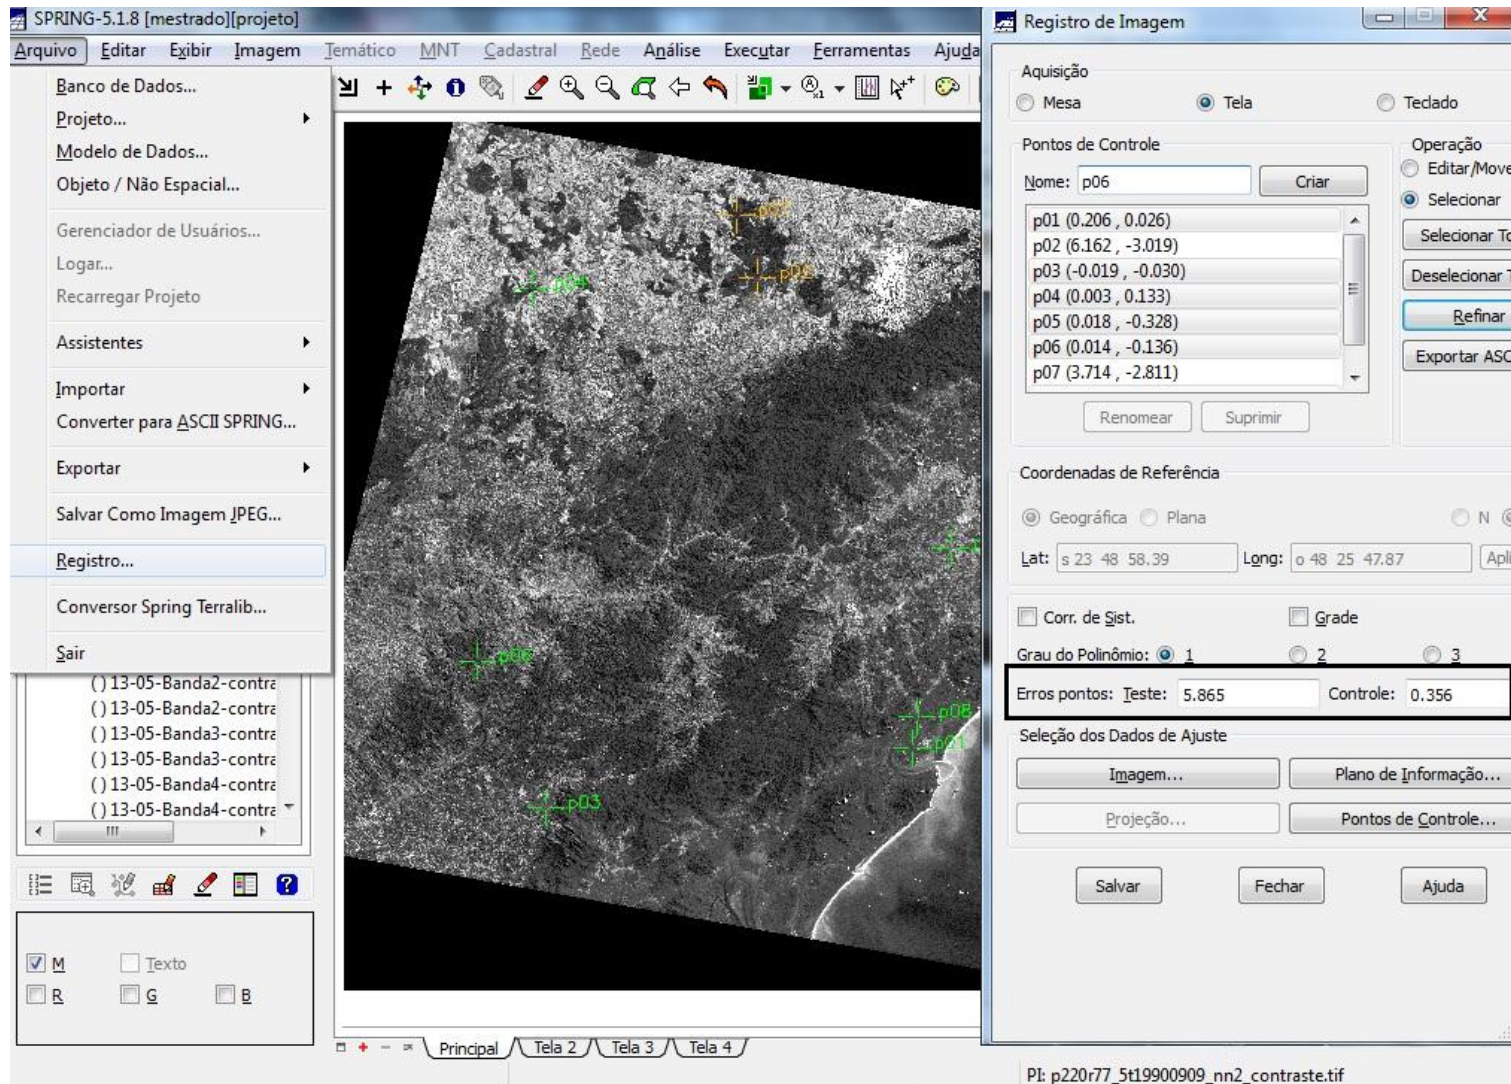


Figura 38. Tela do SPRING para execução do registro de imagens.

Procedeu-se o registro das imagens pelo método imagem-imagem (Tela), utilizando como referência uma imagem ortorretificada na projeção UTM e Datum WGS-84.

Foram distribuídos, globalmente, 6 pontos de controle nas imagens. O erro obtido pelo método foi de 0,356 pixels (Figura 38). Como as imagens possuíam 30 metros de resolução, tal erro equivale a 10,68 metros, o que é considerável aceitável para a aplicação do estudo de caso, baseado no fato de que esta variação não reflete em diferenças significativas, uma vez que o método de monitoramento do EE possui amostragem de 50 ha.

5.1.2.2 Re-amostragem

O processo de re-amostragem foi implementado nas 18 imagens, com os métodos vizinho-mais-próximo, bilinear e krigagem ordinária. Para o método por krigagem, na elaboração do semivariograma experimental, foram analisados diferentes ângulos de direção, sendo selecionada a melhor direção, de acordo com um critério visual, com base na estrutura padrão de uma semivariograma ideal.

Para validação do método foi utilizado um conjunto de 18 imagens. Para efeito de demonstração dos resultados produzidos será apresentado uma das análises com base em uma imagem referente à Banda 4, que foi obtida em 30 de junho de 2005.

A Tabela 13 ilustra as estatísticas descritivas da análise exploratória dos dados e a Figura 39 exibe o gráfico de histograma dos dados obtidos com base na imagem referente à banda 4, que foi obtida em 30 de junho de 2005.

Tabela 13. Estatísticas Descritivas da Análise Exploratória.

<i>Variável</i>	<i>Medida</i>
Número de Pontos	12384
Média	121,0408
Variância	2203,8238
Desvio Padrão	46,9445
Coefficiente de Variação	0,3879
Coefficiente de Assimetria	-0,0303
Coefficiente de Curtose	2,8980
Valor Mínimo	0,0000
Quartil Inferior	91,0000
Mediana	122,0000
Quartil Superior	151,0000
Valor Máximo	254,0000




Figura 39. Gráfico de histograma dos dados.

A Figura 40 exibe o gráfico dos semivariogramas experimentais, com amostragem regular e unidirecional, considerando direcionamentos com angulações de 0° , 45° , 90° e 135° .




Figura 40. Semivariogramas experimentais para diferentes direções. A cor preta representa a direção em 0° , a cor vermelho representa 45° , em azul, 90° e verde, 135° .

O semivariograma experimental, com direção a 90° , foi selecionado com base em análise qualitativa visual. Observa-se um alcance próximo a 100 metros e patamar (900) próximo à variância amostral, o que é considerado desejável na análise.

Para seleção do modelo de semivariograma, foram testados os modelos esférico, exponencial e gaussiano. As equações 48, 49 e 50 apresentam respectivamente, os parâmetros dos modelos analisados.

$$\gamma(h) = -79,413 + 1031,379 \left[\frac{3}{2} \left(\frac{|h|}{111,983} \right) - \frac{1}{2} \left(\frac{|h|}{111,983} \right)^3 \right] \quad , 0 \leq |h| \leq a \quad (48)$$

$$\gamma(h) = -98,752 + 1684,570 \left(1 - e^{\frac{-h}{307,496}} \right) \quad (49)$$

$$\gamma(h) = 28,73 + 892,638 \left(1 - e^{\frac{-h^2}{85,14^2}} \right) \quad , 0 \leq |h| \leq a \quad (50)$$

Os semivariogramas ajustados para os diferentes modelos estão ilustrados na Figura 41.

Uma vez definido o modelo que descreve a continuidade espacial de NC para essa imagem, torna-se necessário realizar o processo de validação do modelo proposto. Esta é uma etapa que precede a krigagem e seu principal objetivo é avaliar a adequação do modelo sugerido no processo que envolve a re-estimação dos valores amostrais conhecidos.

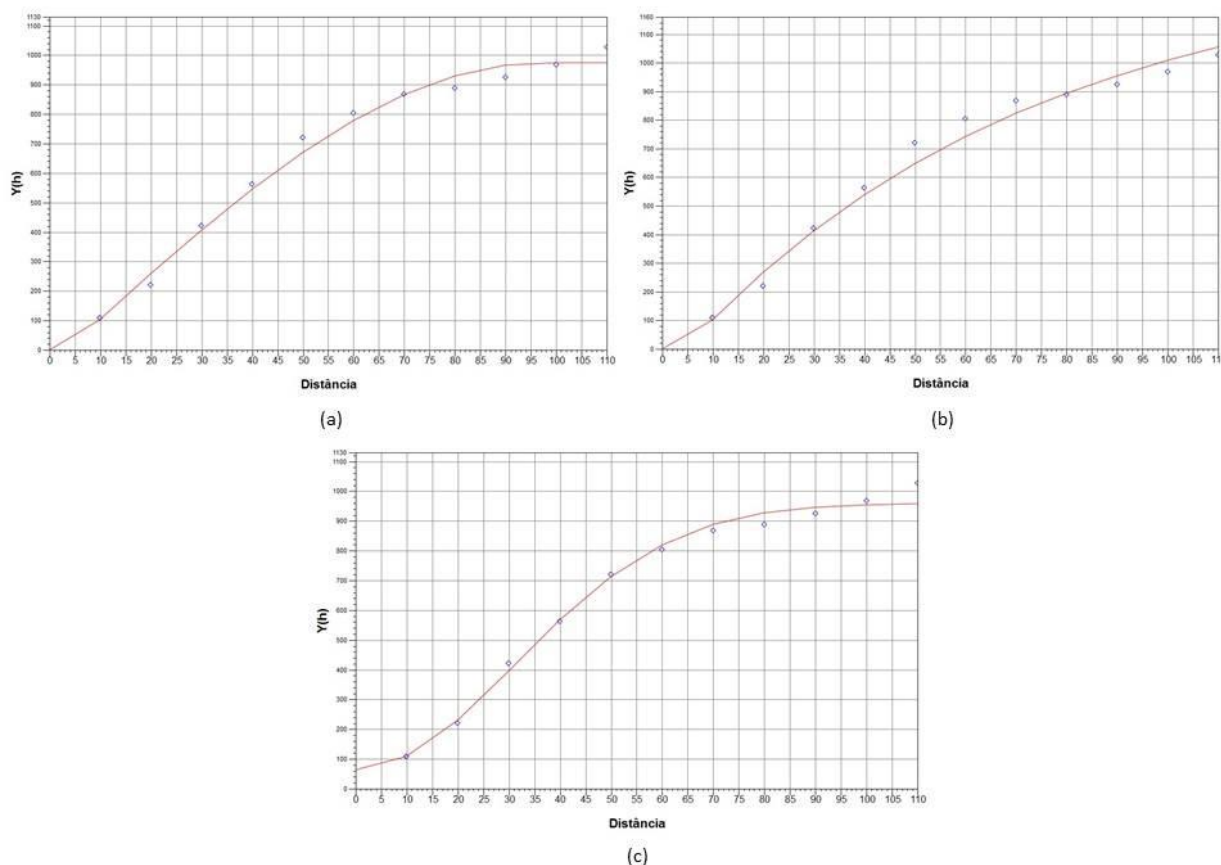


Figura 41. Semivariogramas ajustados para os modelos: (a) esférico, (b) exponencial e (c) gaussiano.

Os resultados obtidos da validação, como estatísticas e histograma do erro, diagrama espacial do erro e gráfico de valores verdadeiros *versus* estimados, foram analisados e o modelo proposto na Equação 49 se mostrou viável no conjunto de análise.

A Tabela 14 exibe as estatísticas de erro, observados durante a análise e a Figura 42 ilustra o seu histograma.

Tabela 14. Estatísticas do erro associado à execução da re-amostragem por krigagem ordinária.

Número de amostras	10000
Média	-0,0013
Variância	71,3970
Desvio Padrão	8,4500
Coefficiente de Variação	650,0140
Coefficiente de Assimetria	0,3230
Coefficiente de Curtose	7,6000
Valor Mínimo	-35,7350
Valor Máximo	120,5150




Figura 42. Histograma do erro associado à execução da re-amostragem por krigagem ordinária.

Observa-se na Tabela 14, em relação a Tabela 13, que a quantidade de número de amostras foi reduzida de 12384 para 10000, pois é o limite do módulo estatístico da versão do SPRING utilizada. No entanto a análise foi considerada devido ao fato destes pontos que foram eliminados não abrangiam a área de interesse. A Figura 43 exibe o resultado da re-amostragem pelos métodos analisados.




Figura 43. (a) Imagem original. (b) Imagem reamostrada pelo método do vizinho-mais-próximo. (c) Imagem reamostrada pelo método bilinear. (d) Imagem reamostrada pelo método de krigagem ordinária.

Observa-se na Figura 43, que a imagem resultante do método de re-amostragem por krigagem, sofreu uma leve redução nas informações de alta frequência, porém, apresentou uma suavização maior em relação aos demais métodos.

5.1.2.3 Realce de Imagens

Assim, realizou-se uma ampliação linear de contraste para todas as imagens, como pode ser observado na Figura 44, onde são ilustradas as imagens antes e depois do ajuste e seus respectivos histogramas.

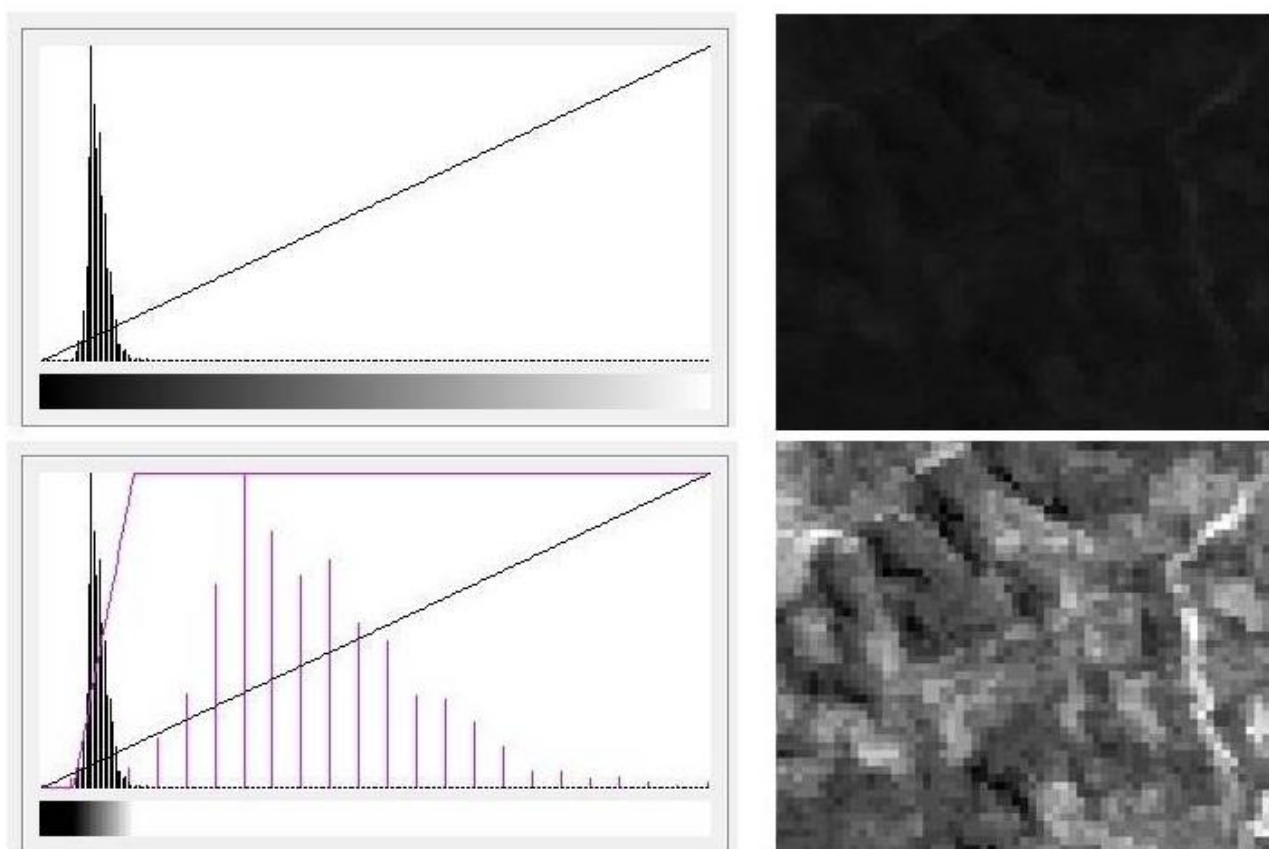


Figura 44. Resultado do realce de imagens, de acordo com o histograma da imagem HR.

5.1.2.4 Fusão

A avaliação dos resultados foi efetuada com base na comparação estatística e na análise visual. Na análise visual, a qualidade percebida da imagem é fortemente dependente do observador e da aplicação temática, por isso, foi também utilizada uma medida quantitativa.

O coeficiente de correlação (r) fornece um indicativo de similaridade estatística entre dois conjuntos de dados. A correlação entre a imagem HR e a banda a ser substituída no processo de fusão deve ser alta. Além disso, uma boa técnica de fusão deve proporcionar bandas híbridas que mantenham as correlações das bandas originais com a imagem HR e a similaridade das correlações entre si das bandas híbridas com aquelas existentes entre as bandas originais.

Na tabela 15 são apresentados os coeficientes de correlação entre a imagem HR e as bandas originais reamostradas e entre a imagem HR e as correspondentes bandas híbridas, para os diferentes métodos de fusão. Também, são apresentadas as correlações entre si entre as bandas originais e híbridas.

Tabela 15. Coeficientes de correlação entre as bandas originais reamostradas, a imagem HR e os produtos híbridos gerados pelos diferentes métodos.

<i>Bandas</i>	<i>Original</i>	<i>IHS</i>	<i>PCA</i>
HR-B2	-0,0738	0,9584	0,7033
HR-B3	-0,0405	0,943	0,9762
HR-B4	-0,1204	0,9276	0,891
B2-B3	0,8529	0,8834	0,8644
B2-B4	0,7311	0,843	0,8838
B3-B4	0,3213	0,5228	0,9122

Verifica-se que a correlação entre a banda HR e as bandas originais é muito baixa. Porém, no método IHS, a substituição da componente I pela banda HR produziu bandas híbridas mais correlacionadas com a imagem HR e com maior correlação entre si. A fusão com o método PCA produziu bandas híbridas um pouco menos correlacionadas com a imagem HR, mas também aumentou as correlações entre si. A Tabela 16 apresenta os produtos dos índices de qualidade de imagens (IQI) das imagens originais reamostradas em relação às imagens híbridas produzidas pelos diferentes métodos.

Tabela 16. Produtos dos Índices de Qualidade de Imagens (IQI) entre as bandas originais reamostradas e as imagens híbridas para os métodos IHS e PCA.

<i>Bandas</i>	<i>IHS</i>	<i>PCA</i>
B2	0,0303	0,0099
B3	0,0815	-0,1228
B4	0,0506	-0,5042

A tabela 17 apresenta os coeficientes de correlação entre as bandas originais reamostradas e as respectivas bandas híbridas.

Tabela 17. Coeficientes de correlação entre as bandas originais reamostradas e as imagens híbridas para os métodos IHS e PCA.

<i>Bandas</i>	<i>IHS</i>	<i>PCA</i>
B2	0,2318	0,0052
B3	0,0304	-0,1138
B4	0,1800	-0,5056

Verifica-se que o método PCA produz bandas híbridas com baixa semelhança espectral com as bandas originais, resultando em coeficientes de correlação negativos.

O método IHS apresentou coeficientes de correlação positivos e, embora ainda sejam considerados muito baixos, ligeiramente mais altos em relação à PCA, com exceção da banda 4. No entanto, a imagem HR abrange a faixa de 0,48 a 0,71 μ m, que compreende faixas não imageadas pelas 3 bandas MS, fazendo com que as bandas híbridas obtidas pelo método IHS não sejam espectralmente iguais às bandas originais.

Para análise visual dos resultados da fusão, considera-se a resolução espacial importante para extração de informação em áreas agrícolas, por exemplo, detectar, distinguir entre e/ou identificar o uso e a ocupação do solo, identificar talhões de cultivos diferentes, estradas e cursos d'água. Naturalmente, deve haver

suficiente contraste espacial entre os objetos de interesse e o fundo (JENSEN e COWEN, 1999).

A Figura 45 mostra as composições BGR, das bandas B2, B3 e B4 originais reamostradas em (a), onde se pode observar que a vegetação é clara, por apresentar maior reflectância no infravermelho próximo, enquanto as áreas de construção e com ausência de vegetação, possuem uma coloração azulada, em (b) é visto a composição BGR das bandas B2, B3 e B4 híbridas geradas pelo método IHS. Observa-se que vegetação teve sua cor alterada, passando a ficar com uma cor azulada, formando manchas. Porém, houve melhor possibilidade de distinguir entre estradas, áreas de construção e a área agrícola. Observa-se a presença de nuvens, no canto superior direito da imagem HR, que refletiu no produto da fusão, no entanto, não afetou a área do estudo.




Figura 45. (a) Composição BGR das bandas 2, 3 e 4 originais reamostradas.
(b) Composição BGR das bandas híbridas 2, 3 e 4, obtidas pelo método IHS.

A Figura 46 exhibe novamente em (a), a composição BGR das bandas B2, B3

e B4 originais reamostradas, em (b) mostra a composição BGR das bandas B1, B2 e B3 obtidas pelo método PCA. Visualmente, observa-se grande semelhança com a imagem HR. A composição colorida destas bandas possibilita boa percepção dos diferentes tipos de vegetação e áreas de cultivo agrícola e de vegetação de mata, neste caso, Mata Atlântica¹⁴.




Figura 46. (a) Composição BGR das bandas 2, 3 e 4 originais reamostradas.
(b) Composição BGR das bandas híbridas 2, 3 e 4, obtidas pelo método PCA.

5.1.2.5 Recorte da Área de Interesse

Figura 47 mostra o recorte da área de estudo nas imagens feito com as coordenadas UTM obtidas no campo.

¹⁴ Vegetação nativa típica da região.

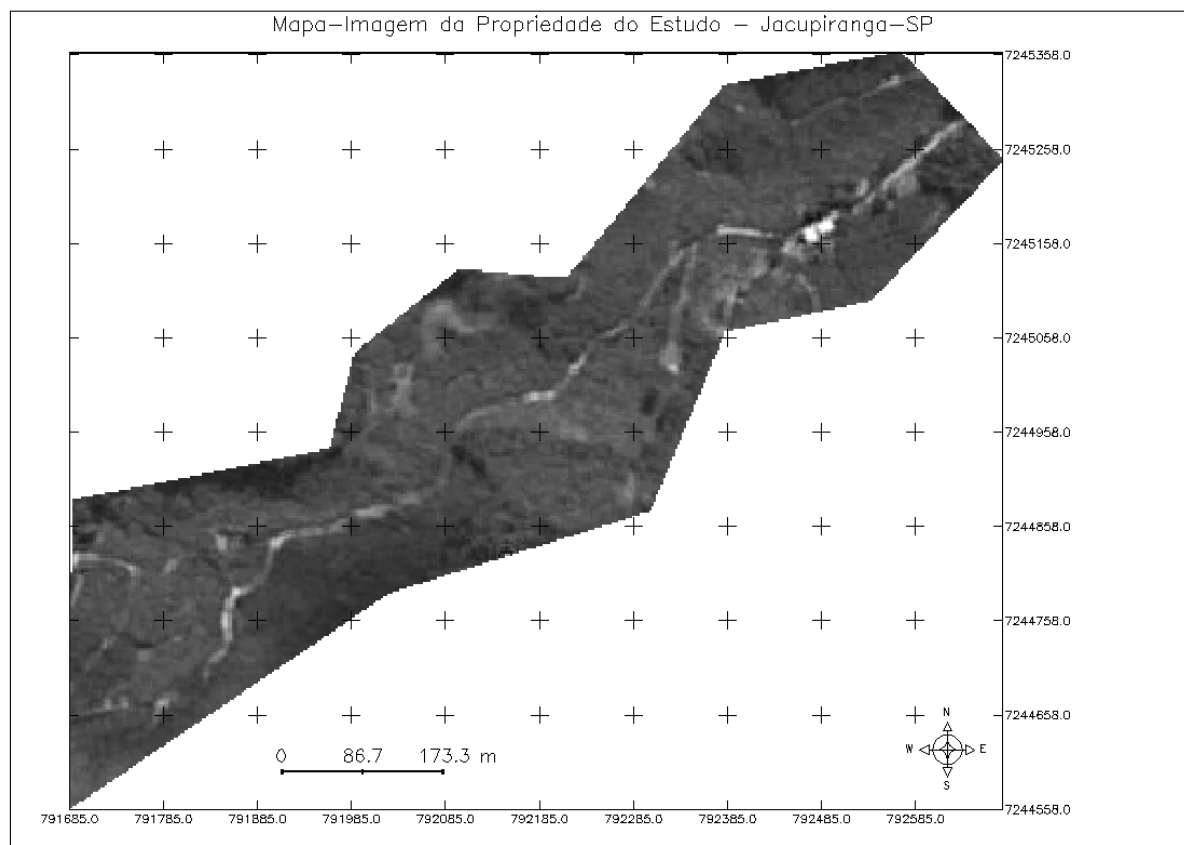


Figura 47. Recorte da área de estudo.

5.1.2.6 Extração de Atributos

Para o estudo dos valores de NC, primeiramente foi realizada uma análise dos valores de níveis de cinza dos pixels da banda 4 da imagem Landsat 5 (TM) e os valores do EE. Como resultado, foi obtido o modelo polinomial de terceira ordem, o qual descreve o valor do nível de cinza em função do EE. O polinômio de terceira ordem foi selecionado por apresentar coeficiente de determinação igual a $R^2 = 0,986$ e erro padrão 6,5598, o que ocorreu devido à baixa resolução temporal.

Assim, considerando a disponibilidade de imagens do catálogo do INPE e de acordo com o modelo selecionado, conforme ilustra a Figura 48, tem-se que a partir dos valores de EE igual a 1370,1 o NC tende a aumentar, até valores próximos de 126, quando se apresenta constante até 1873 e novamente volta a apresentar tendência a aumentar.




Figura 48. Modelo polinomial que estabelece a relação entre as variáveis Estado da Evolução (EE) e Nível de Cinza (NC) da Banda 4 da imagem Landsat 5-TM.

A Tabela 18 apresenta as medidas descritivas da variável, onde se observou uma média igual a 75,2, mínimo de 10,0, máximo de 254,0 e mediana de 74,0 indicando que 50% dos registros assumiram valores menores ou iguais a este valor.

A figura 49 ilustra o gráfico de caixa para a variável NC e permite determinar que 25% das observações apresentam valores menores ou iguais a 52,0 as quais correspondem ao primeiro quartil.

Foram avaliados polinômios da segunda a sexta ordem, tomando por base os respectivos coeficientes de determinação e os erros associados.

O modelo selecionado com base no coeficiente de correlação e o erro padrão foi o descrito pelo polinômio de quarta ordem, cujos valores de R^2 e erro padrão foram de 0,8065 e 0,0918 respectivamente.

A curva de distribuição das probabilidades com a curva do modelo polinomial ajustado e sua respectiva equação é apresentada na Figura 50.

Tabela 18. Número de registros e medidas descritivas de NC.

<i>Variável</i>	<i>Grandeza</i>
N	892059
Média	114,3
Mediana	112
Desvio padrão	50,1871
Variância	2518,7470
Mínimo	12
Máximo	254
Q1	83
Q2	112
Q3	135

Assim, para esta variável, considera-se a Tabela 19, como *look-up-table* para esta variável, onde estão apresentados os níveis de favorabilidade determinados a partir da análise da curva de regressão, bem como os intervalos das classes e as respectivas probabilidades determinadas pelo modelo escolhido.




Figura 49. Gráfico de caixa para os valores de NC.




Figura 50. Ajuste do modelo para a função de probabilidades para a variável NC, referente ao polinômio selecionado.

Tabela 19 - Classes, intervalos e probabilidades ajustadas pelo modelo e os respectivos níveis de risco.

<i>Classes</i>	<i>Intervalo</i>	<i>Probabilidade pelo modelo ajustado</i>	<i>Risco</i>
1	12 – 36,2	0,1126	baixo
2	36,3 – 60,5	0,0787	baixo
3	60,6 – 84,8	0,1888	baixo
4	84,9 – 109,1	0,2137	alto
5	109,2 – 133,4	0,0850	médio
6	133,5 – 157,7	-0,1769	médio
7	157,8 – 182,0	-0,5348	médio
8	182,1 – 206,5	-1,0067	alto
9	206,4 – 230,6	-1,7378	alto
10	230,7 – 254	-3,0725	alto

5.1.2.7 Geração dos Mapas de Risco

Para geração dos mapas, foram avaliados cenários de diferentes épocas do ano. A Figura 51 ilustra as figuras de méritos para as datas avaliadas. No caso da variável NC, como em todas as situações ocorriam diferentes valores para tal,

utilizou-se o valor máximo de probabilidade na área de estudo para representação das figuras.




Figura 51. Figuras de méritos para as diferentes datas.

A tabela 20 apresenta as funções de distribuições de probabilidades selecionadas para cada variável do sistema, bem como seus respectivos valores de erro padrão e coeficiente de determinação.

Tabela 20. Funções de distribuições ajustadas pelo modelo polinomial, para as diferentes variáveis.

Variável	Função	Erro-padrão	R ²
Tmax	$T_{max}(t) = -5E-05t^5 + 0,0016t^4 - 0,0192t^3 + 0,0940t^2 - 0,1415t + 0,0675$	0,0730	0,8937
Tmin	$T_{min}(t) = -0,0006t^3 + 0,0084t^2 - 0,0074t + 0,0130$	0,0221	0,9307
Pp	$Pp(t) = 0,0005t^4 - 0,0139t^3 + 0,1326t^2 - 0,5570t + 0,9204$	0,1011	0,9825
DPM	$DPM(t) = 5E-05t^6 - 0,0018t^5 + 0,0257t^4 - 0,1833t^3 + 0,6633t^2 - 1,071t + 0,5882$	0,0667	0,9228
NC	$NC(t) = 0,001t^4 - 0,0202t^3 + 0,1172t^2 - 0,1772t + 0,085$	0,0918	0,8065
UR	$UR(t) = 9E-05t^5 - 0,0019t^4 + 0,0112t^3 - 0,0091t^2 - 0,042t + 0,1007$	0,0408	0,9269

A utilização de modelos polinomiais, em abordagem probabilística, descreve melhor o fenômeno estudado, uma vez que os dados variam de forma não-linear em um sistema dinâmico e complexo, tal como é a natureza. Este fato pode ser verificado pelos altos valores dos coeficientes de determinação, superiores a 0,8.

5.1.2.8 Visualização dos Mapas

As Figuras 52, 53, 54, 55, 56 e 57 ilustram os mapas de risco de ocorrência da Sigatoka Negra, obtidos para as datas consideradas, de 22 de fevereiro a 17 de agosto de 2005. As tabelas 21, 22, 23, 24, 25 e 26, apresentam as medidas de área para cada classe de risco, para os respectivos mapas.

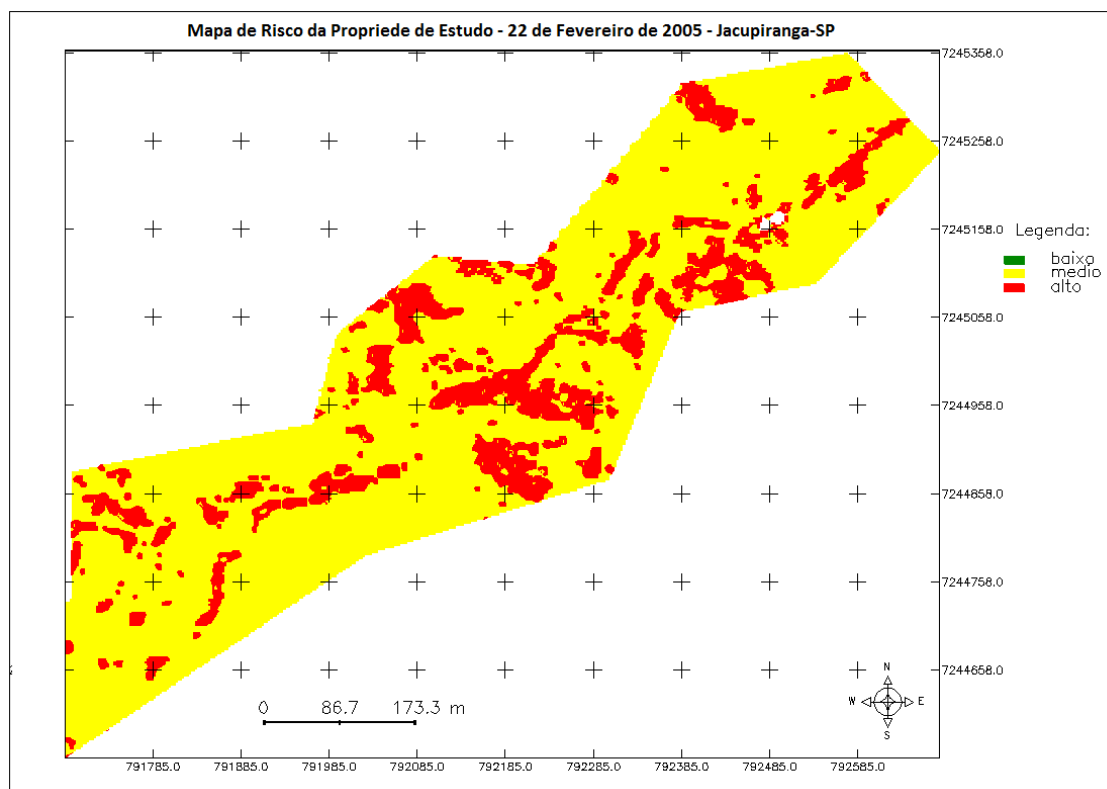


Figura 52. Mapas de risco de ocorrência da Sigatoka Negra na propriedade do estudo, para a data de 22 de fevereiro de 2005.

Tabela 21. Cálculo das áreas (ha) para cada classe de risco, para a data de 22/fev/2005.

Classe	Área (ha)
Alto	4,3181
Médio	20,9725
Baixo	0,0000
Área total	25,2906

Como pode ser observada na Tabela 21, para o cenário correspondente a 22 de fevereiro de 2005, a área classificada com alto risco de ocorrência da Sigatoka-negra foi de 4,3181 ha, o que corresponde a 17,0739% da área total. Enquanto que a área classificada como risco médio, foi de 82,9261%. Não houve áreas classificadas com risco baixo de ocorrência. Na Figura 52, correspondente ao mapa de risco para tal data, observa-se que as áreas de alto risco estão distribuídas formando regiões homogêneas, nas margens da estrada principal, das divisas da propriedade e especialmente na região centro-sudeste.

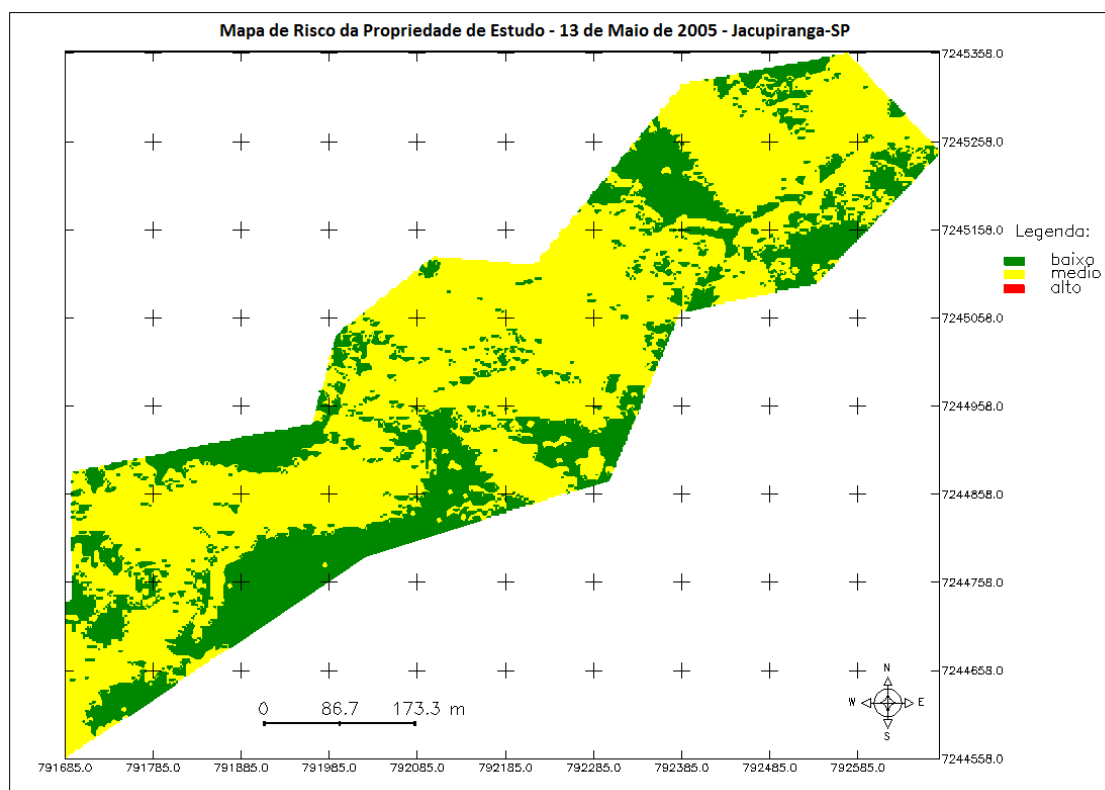


Figura 53. Mapas de risco de ocorrência da Sigatoka Negra na propriedade do estudo, para a data de 13 de maio de 2005.

Tabela 22. Cálculo das áreas (ha) para cada classe de risco para a data de 13/mai/2005.

Classe	Área (ha)
Alto	0,0000
Médio	17,5694
Baixo	7,7581
Área total	25,3275

Conforme a Tabela 22, para o cenário de 13 de maio de 2005, a área classificada com baixo risco de ocorrência da Sigatoka-negra foi de 7,7581 ha, o que corresponde a 30,6272% da área total. A área classificada como risco médio, foi de 17,5694 ha, ou seja, 69,3729% da propriedade. Não houve áreas classificadas com risco alto de ocorrência. Na Figura 53, correspondente ao mapa de risco para tal data, observa-se que as áreas de baixo risco estão mais desuniformes, embora sejam observadas grandes áreas homogêneas, concentradas nas regiões sudoeste e nordeste, nas proximidades com as áreas de mata nativa.

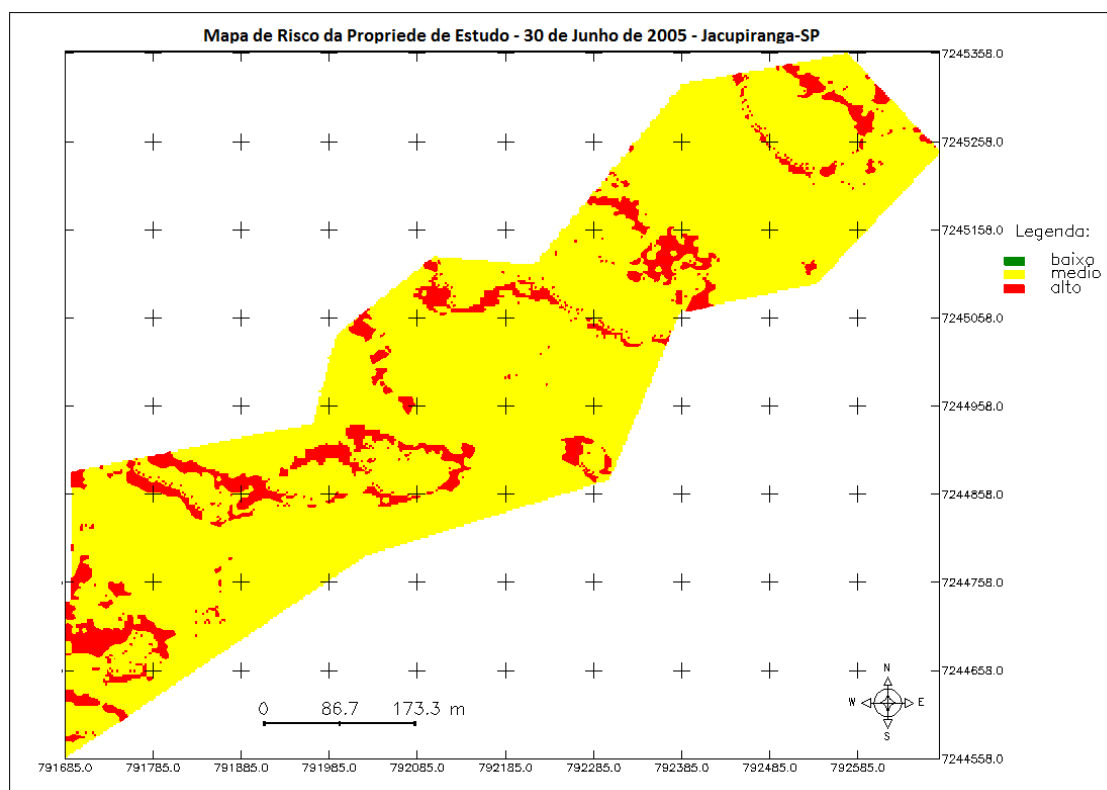


Figura 54. Mapas de risco de ocorrência da Sigatoka Negra na propriedade de estudo, para a data de 30 de junho de 2005.

Tabela 23. Cálculo das áreas (ha) para cada classe de risco para 30/jun/2005.

Classe	Área (ha)
Alto	2,4581
Médio	22,8694
Baixo	0,0000
Área total	25,3275

Como pode ser observada na Tabela 23, a área classificada com alto risco de ocorrência da Sigatoka-negra foi de 2,4581 ha, o que corresponde a 14,3968% da área total. Enquanto que a área classificada como risco médio, foi de 22,8694 ha, ou seja, 85,6032% em relação à área total. Não houve áreas classificadas com risco baixo de ocorrência. Na Figura 54, correspondente ao mapa de risco para tal data, observa-se que as áreas de alto risco estão distribuídas de forma bem heterogênea, formando corredores, de uma extremidade da propriedade a outra, no sentido latitudinal.

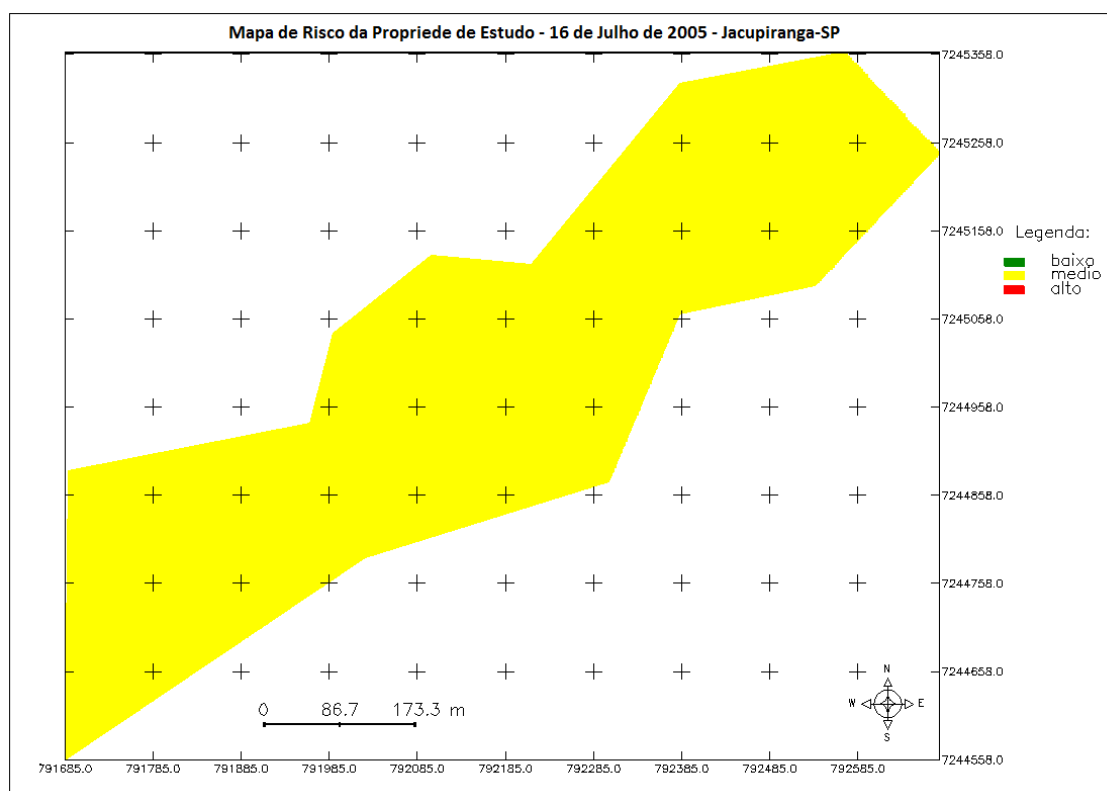


Figura 55. Mapas de risco de ocorrência da Sigatoka Negra na propriedade de estudo, para a data de 16 de julho de 2005.

Tabela 24. Cálculo das áreas (ha) para cada classe de risco para 16/jul/2005.

Classe	Área (ha)
Alto	0,0000
Médio	25,3275
Baixo	0,0000
Área total	25,3275

Como pode ser observada na Tabela 24, a área classificada com alto risco de ocorrência da Sigatoka-negra foi de 25,3275 ha, o que corresponde a 100,0000% da área total. Na Figura 55, correspondente ao mapa de risco para tal data, observa-se que a área da propriedade está na sua totalidade classificada no nível médio de risco.

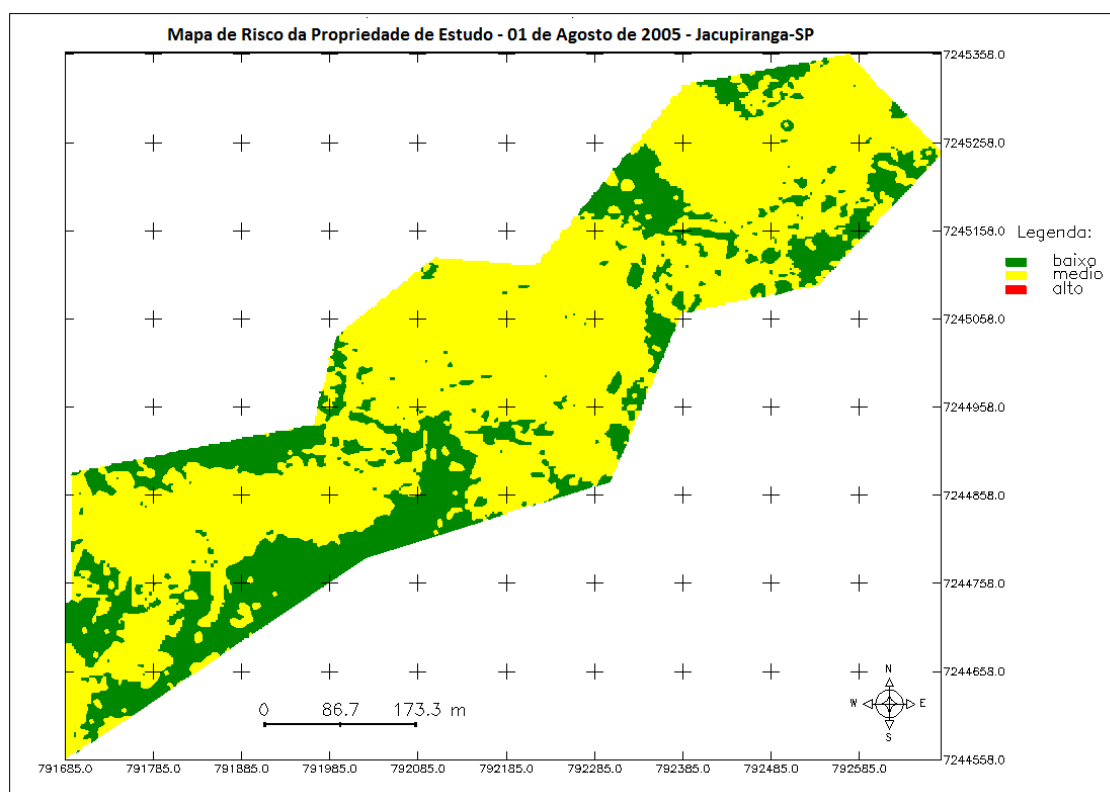


Figura 56. Mapas de risco de ocorrência da Sigatoka Negra na propriedade de estudo, para a data de 1 de agosto de 2005.

Tabela 25. Cálculo das áreas (ha) para cada classe de risco, para 01/ago/2005.

Classe	Área (ha)
Alto	0,0000
Médio	18,7069
Baixo	6,6206
Área total	25,3275

Como podem ser observadas nas Tabelas 25 e 26, referentes ao mês de agosto de 2005, as áreas classificadas com alto risco de ocorrência da Sigatoka-negra foram 6,6206 ha e 7,2244, o que corresponde respectivamente a 26,1400% e 28,5239% da área total. As áreas classificadas como risco médio foram de 18,7069 ha e 18,1031 ha, ou seja, 73,8600% e 71,4761% em relação à área total. Nas Figuras 56 e 57, observa-se que as áreas de baixo risco estão distribuídas de forma semelhante ao cenário de 13 de maio de 2005 (Figura 53), no entanto, com regiões mais uniformes.

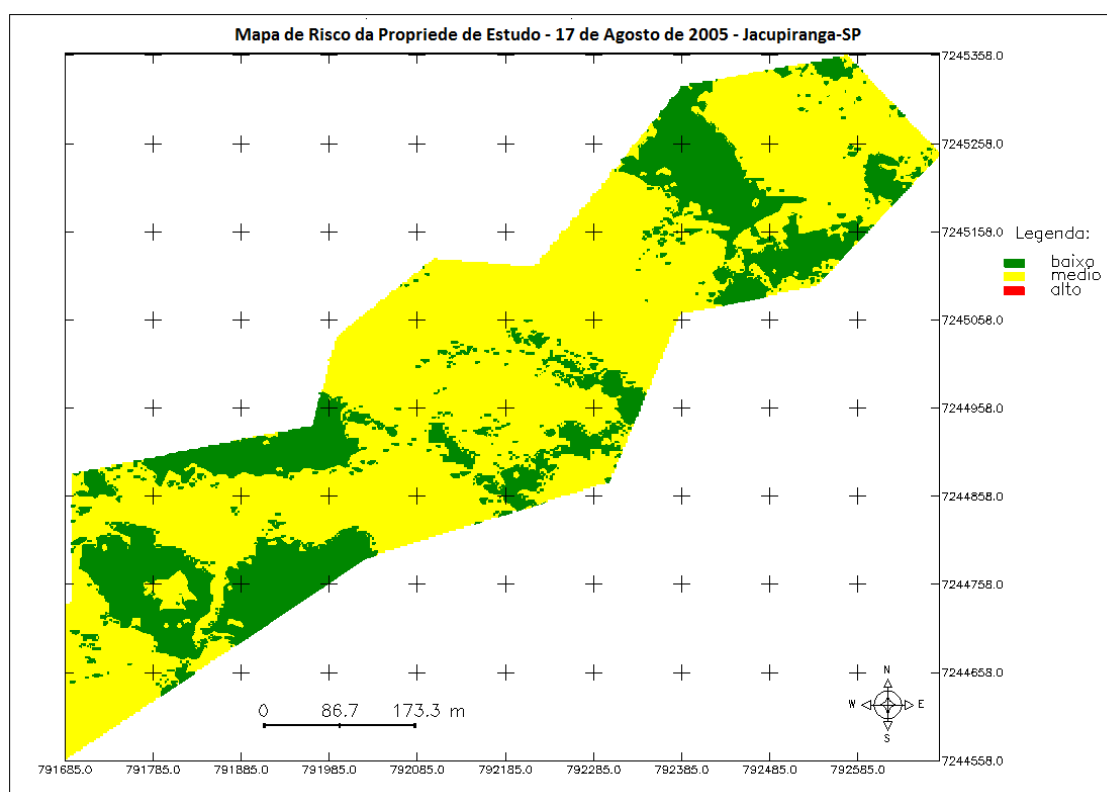


Figura 57. Mapas de risco para a data de 17 de agosto de 2005.

Tabela 26. Cálculo das áreas (ha) para cada classe de risco, para 17/ago/2005.

<i>Classe</i>	<i>Área (ha)</i>
Alto	0,0000
Médio	18,1031
Baixo	7,2244
Área total	25,3275

5.2 Publicações relevantes

Entre as publicações derivadas do desenvolvimento deste trabalho podem ser citadas:

1. BENDINI, H. N., MORAES, W. S., MODENESE-GORLA DA SILVA, S. H. ERIKA S. TEZUKA, CRUVINEL, P. E. Análise de risco da ocorrência de Sigatoka-negra baseada em modelos polinomiais: Um estudo de caso. **Tropical Plant Pathology**. (Submetido em Agosto de 2011).
2. BENDINI, H. N.; CRUVINEL, P. E.; MORAES, W. S.; MODENESE-GORLA DA SILVA, S. H. Risk Assessment of Black Sigatoka based on probability models of climatic data adjusted with spline functions. **ISHS/ProMusa Symposium Bananas and Plantains: Toward sustainable global production and improved uses**. Salvador, Bahia, Brazil, 2011. Pg. 52. (Submetido para a Revista Acta Horticulturae)
3. BENDINI, H. N.; MODENESE-GORLA DA SILVA, S. H.; MORAES, W. da S. Modelo para Análise de risco de ocorrência da Sigatoka Negra em bananais do Vale do Ribeira-SP, baseado no uso de classificação de dados organizados em distribuições polinomiais. **IX Congresso Latinoamericano y del Caribe de Ingeniería Agrícola - CLIA 2010 XXXIX Congresso Brasileiro de Engenharia Agrícola - CONBEA 2010 Vitória - ES, Brasil, 2010**.
4. CRUVINEL, P. E.; MORAES, W. S.; BENDINI, H. N.; MODENESE-GORLA DA SILVA, S. H. ERIKA S. TEZUKA. Avaliação de Modelos para Estabelecimento de Figura de Risco de Ocorrência da Sigatoka-Negra em Bananais. (**Embrapa Instrumentação Documentos/Embrapa Instrumentação**, ISSN 1518-7179; 55). Dezembro, 2011. 28p.

5.3 Trabalhos Futuros

Sugere-se como trabalhos futuros, o desenvolvimento de um estudo de validação dos mapas, considerando o que está ocorrendo no campo em cada pixel.

Indica-se também, a importância da elaboração de testes, considerando a utilização de modelagem splines, para ajuste das curvas de distribuição de probabilidades, bem como na re-amostragem, buscando aperfeiçoar a precisão do método.

5.4 Conclusões

A seleção de modelos polinomiais demonstrou-se viável e promissora no que diz respeito à preparação de séries temporais de dados para modelos de risco em ambiente. O método de krigagem ordinária para re-amostragem dos níveis de cinza das imagens, apresentou bons resultados para o modelo de semivariograma gaussiano.

Os métodos de fusão por IHS e PCA apresentaram valores de correlação esperados para a aplicação em modelos de risco de ocorrência da Sigatoka Negra.

Os baixos valores de correlação ocorreram principalmente devido ao fato de que as imagens HR obtidas no *Google Earth*, não possuem radiometria calibrada de acordo com o sensor original, no caso, do satélite SPOT 5. Entretanto, o uso da referida base auxiliou na validação do método de fusão, o que se caracterizou como parte principal da pesquisa desenvolvida.

A metodologia desenvolvida com base no processamento digital de imagens auxiliou na validação da abordagem desenvolvida para a definição de uma figura de risco integrado com a geração de mapas, o que colabora com mais um passo para no auxílio ao processo de tomada de decisão em ambiente agrícola em escala de propriedade. Adicionalmente, a metodologia de geração de mapas estabelecida, pode encontrar uso em programas de controle da Sigatoka-negra, de forma a minimizar o uso de energia e a redução da utilização de fungicidas químicos, o que poderá auxiliar o produtor tanto para o ganho econômico como para o ganho ambiental e social.

REFERÊNCIAS BIBLIOGRÁFICAS

ACRE. Secretaria de Estado de Ciência, Tecnologia e Meio Ambiente. Programa Estadual de Zoneamento Ecológico-Econômico do Estado do Acre. **Zoneamento ecológico-econômico do Estado do Acre: recursos naturais e meio ambiente**, documento final, 1ª fase. Rio Branco: SECTMA, 2000.

ADAMI, M.; MOREIRA, M. A.; RUDORRF, B. F. T.; FREITAS, C. C.; FARA, R. T. Expansão direta na estimativa de culturas agrícolas por meio de segmentos regulares. **Revista Brasileira de Cartografia**, Presidente Prudente, v. 1. n.57, p.22, 2005.

AGUENA, M. L. S. Fusão de imagens multiespectrais utilizando técnicas POCS. 93 p. **Dissertação (Mestrado)** – Universidade Federal de São Carlos – UFSCar, São Carlos, 2002.

ALCÂNTARA, E. H.; FREITAS, R. M.; NOVO, E. M. L. M.; LORENZZETTI, J. A.; ASSIREU, A. T.; STECH, J. L.; SOUZA, A. F. O canal termal do sensor IRMSSCBERS-2: Avaliação do potencial para estimar a temperatura de superfície. In: **SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO**, 14. (SBSR), 2009, Natal. Anais... São José dos Campos: INPE, 2009. p. 1919-1926.

ALLEBACHJ, P. Image scanning, sampling, and interpolation. Handbook of image and Video Processing, 2nd Ed. A. Bovik, Ed., **Academic Press**, San Diego, Calif. 2005.

ALVES, A. DE L. Cartografia Temporal e Análise Geoambiental da Dinâmica da Foz do Rio Piranhas-Açu, Região de Macau-RN, com base em imagens Landsat 5-TM. **Dissertação (Mestrado)**. Universidade Federal do Rio Grande do Norte. Natal - RN, 2001.

ASSOCIATION FOR COMPUTING MACHINERY (ACM), 1979. Status Report of the Graphics Standards Planning Committee, **Computer Graphics**, Vol. 13, N. 3.

AWAD, M. CHEHDI, K., NASRI, A.. Multicomponent Image Segmentation Using a Genetic Algorithm and Artificial Neural Network, **IEEE Geoscience and Remote Sensing Letters**, vol. 4, no. 4, October 2007.

AWAD, M., An Unsupervised Artificial Neural Network Method for Satellite Image Segmentation, **The International Arab Journal of Information Technology**, Vol. 7, No. 2, April 2010.

AYDIN, T.; YEMEZ, Y.; ANARIM, E.; SANKUR, B. Multidirectional and multiscale edge detection via m-band wavelet transform. **IEEE Transactions on Image Processing**, v. 5, n. 9, p. 1370, 1996.

BENDINI, H. N.; MODENESE-GORLA DA SILVA, S. H.; MORAES, W. da S. Modelo para Análise de risco de ocorrência da Sigatoka Negra em bananais do Vale do Ribeira-SP, baseado no uso de classificação de dados organizados em distribuições polinomiais. **IX Congresso Latinoamericano y del Caribe de Ingeniería Agrícola - CLIA 2010 XXXIX Congresso Brasileiro de Engenharia Agrícola - CONBEA 2010**. Vitória - ES, Brasil, 2010.

BENEDKTSOHN, J. A. PALMASON, SVEINSSON, J. R., Classification of hyperspectral data from urban areas based on extended morphological profiles, **IEEE Trans. Geosci. Remote Sens.**, vol. 43, no. 3, pp. 480–491, Mar. 2005.

BESIRIS, D.; TSAGARIS, V.; FRAGOULIS, N.; THEOHARATOS, C., An FPGA-Based Hardware Implementation of Configurable Pixel-Level Color Image Fusion, **IEEE Transactions on Geoscience and Remote Sensing**, vol.50, no.2, p.362-373, 2012

BUENO, J. M. Suporte à Recuperação de Imagens Médicas Baseada em Conteúdo através de Histogramas Métricos. **Tese (Doutorado)**. Universidade de São Paulo. São Carlos, 2001.

BURROUGH, P. A. Principles of geographical information systems for land resources assessment. **Oxford, Clarendon Press**, 1987. 193p.

BURROUGH, P. A.; VAREKAMP C.; SKIDMORE, A.K. Using Public Domain Geostatistical and GIS Software for Spatial Interpolation. **Photogrammetric Engineering & Remote Sensing**, 62 (7): 845-854, 1996

BARNEA, D. I., AND H. F. SILVERMAN. A class of algorithms for fast digital image registration, **IEEE Trans. Comput.** p. 179 – 186, 1972.

BERGAMIN FILHO, A.; AMORIM, L. **Doenças de plantas tropicais: epidemiologia e controle econômico**. São Paulo: Ceres, 1996. 289p.

BERGER, R. D. Description and application of some general models for plant disease epidemics. In: LEONARD, K. J.; FRY, W. E. (Ed.). **Plant disease epidemiology: genetics, resistance, and management**. New York: Macmillan, 1989. v. 2, p. 15-149.

BROWN, L. G., A survey of image registration techniques, **Computing Surveys**, 24 (4): 325 – 376. 1992.

BRYN, L. M. Página Dinâmica para Aprendizado do Sensoriamento Remoto. 2008. 172 p. **Dissertação (Mestrado)** – Universidade Federal do Rio Grande do Sul Centro de Pesquisa em Sensoriamento Remoto e Meteorologia, Porta Alegre, RS, 2008.

BYRNE, G. F. CRAPPER, P. F. and MAYO, K. K., Monitoring land-cover change by principal component analysis of multitemporal Landsat data, **Remote Sensing Environment**, 1, 1980, 887-888.

BURROUGH, P. A. **Principles Of Geographical Information Systems For Land Resources Assessment**. Oxford, Clarendon Press, 1987. 193p.

BURROUGH, P. A.; VAREKAMP C.; SKIDMORE, A.K. Using Public Domain Geostatistical And Gis Software For Spatial Interpolation. **Photogrammetric Engineering & Remote Sensing**, 62 (7): 845-854, 1996.

CAMARA, G.; MEDEIROS, J.S. Principios basicos em geoprocessamento. In: ASSAD, E.D.; SANO, E.E. Sistema de Informações Geográficas: Aplicacoes na agricultura. Planaltina, GO: **Empresa Brasileira de Pesquisa Agropecuária / CPAC**, 1993. p.03-11.

CÂMARA, G.; SOUZA, R.C.M.; FREITAS, U.M.; GARRIDO, J.C.P. SPRING: Integrating Remote Sensing and GIS with Object-Oriented Data Modelling. **Computers and Graphics**, vol.15, n.6, July 1996, pp.13-22.

CANDEIAS, A . L. B., 1992, The use of Bayesian estimation theory on satellite data fusion. **MSc Thesis** (INPE-5457-TDI/499), INPE, São José dos Campos, S.P. Brasil (in Portuguese).

CANNY, J. F., A computational approach to edge detection, **IEEE Trans. On Pattern Anal. And Machine Intell.** 1986, p. 679 – 698.

CAO, W.; LI, B.; ZHANG, Y. A remote sensing image fusion method based on pca transform and wavelet packet transform. In: **IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS AND SIGNAL PROCESSING**, 2003, Nanjing, China. Proceedings... Nanjing: IEEE, 2003. v. 2, p. 976 – 981, 2003.

CARAMORI, P. H., ANDROCIOLI FILHO, A., LIBERAL, E.G. (Eds.). **Simpósio Internacional sobre café adensado 1994**. Londrina: IAPAR, 1994. 312p.

CARPER, W.; LILLESAND, T.; KIEFER, R. The use of intensity-hue-saturation transformations for merging spot panchromatic and multispectral image data. **Photogrammetric Engineering and Remote Sensing**, v. 56, p. 459 – 467, 1990.

CARTER, D. B. Analysis of Multiresolution Data Fusion Techniques. 1998. 120p. **Thesis (Master of Science in Geography)** – Virginia Polytechnic Institute an Sate University, Blacksburg, 1998.

CHAVEZ, P. S.; KWARTENG, A. Y. Extracting spectral contrast in Landsat Thematic Mapper image data using selective principal component analysis. **Photogrammetric Engineering and Remote Sensing**, v. 55, p. 339 – 348, 1989.

CHAVEZ Jr., P. S., SIDES, S.C., ANDERSON, J. A. Comparison of three difference methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic. **Photogramm. Eng. Remote Sensing** 57 (1991) 295 – 303.

CHIBANI, Y.; HOUACINE, A. On the use of the redundant wavelet transform for multisensor image fusion. In: **IEEE INTERNATIONAL CONFERENCE ON ELECTRONICS, CIRCUITS AND SYSTEMS**, 7., 2000, Jounieh, Lebanon. Proceedings... Jounieh: IEEE, 2000. v. 1, p. 442 – 445.

CHUI, C. An introduction to Wavelets, (C. Chui, editor), **Academic Press**, New York., 1992.

CRONSHAW , D. K. Monitoring of Sigatoka disease (*Mycosphaerella musicola*) in the Windward Islands for tolerance to fungicides. **Tropical Pest Management**. p. 225-229. 1984.

CREPANI, E.; MEDEIROS, J.S. Imagens fotográficas derivadas de MNT do Projeto SRTM para fotointerpretação na geologia, geomorfologia e pedologia. Sao Jose dos Campos: **Instituto Nacional de Pesquisas Espaciais**, 2004. 39 p.

CREPANI, E.; MEDEIROS, J.S.; FILHO, P.H.; FLORENZANO, T.G.; DUARTE, V.; BARBOSA, C.C.F. Sensoriamento remoto e geoprocessamento aplicados ao zoneamento ecológico econômico e ao ordenamento territorial. Sao Jose dos Campos: **Instituto Nacional de Pesquisas Espaciais**, 2001. 101 p.

CROSTA, A.P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: UNICAMP, 1992. 170 p.

CRUVINEL, P. E.. Eletronic as an important tool for modern agriculture and the experience of the nucleus of research and development of agricultural instrumentation. CNPDIA, (EMBRAPA). In: **II Escuela Latino americana de Física de Suelos**, Buenos Aires, Argentina, 1992.

CRUVINEL, P. E.; MINATEL, E.R.; MUCHERONI, M.L.; VIEIRA, S.R.; CRESTANA, S. An automatic method base don image processing for measurements of drop size distribution from agricultural sprinklers: In: **Simpósio Brasileiro de Computação Gráfica e Processamento de Imagens**, 9., Caxambu, MG, Anais...Caxambu, MG: SBC; Belo Horizonte: UFMG, 1996, p. 3946.

CRUVINEL, P. E.; SUZUMURA FILHO, Y.; MANTOVANI, E. C. Análise da qualidade da aplicação georeferenciada de chuva artificial em área de plantio com visão computacional e rede neural. In: **CONGRESSO BRASILEIRO DE ENGENHARIA AGRÍCOLA - CONBEA**, 35., 2006, João Pessoa. Agroenergia e desenvolvimento tecnológico. Anais... João Pessoa: SBEA, 2006. 1 CD-ROM.

DARCH, J. P. A study of moisture conditions in the Pantanal of Brazil using satellite imagery. **Remote Sensing of Environment**, v. 8, n. 4, p. 331-348, 1979.

DARWISH, A. M., BEDAIR, M. S., SHAHEEN, S. I., Adaptive resampling algorithm for image zooming, **IEEE Proc. Vision Image Signal Process**. 1444, 207–212 1997.

DAVID, M. Geostatistical ore reserve estimation. New York, **Elsevier Scientific**, 1977. 364p.

DEBIASI, P.; ECKHARDT, R. R.; CASTOLLDI, G.; MADRUGA, R.; COUTINHO, A. Fusão de imagens MODIS com NDVI do Landsat para a classificação de áreas de cultivo de soja. **Anais do XIII Simpósio de Sensoriamento Remoto**, Florianópolis, 2007. p. 5707 – 5714.

DODGSON, N. A. Image Resampling, Tech. Rep. 261, **Comput. Lab.**, Univ. Cambridge, Cambridge, U.K, Aug, 1992.

DUTRA, L. V., MENEZES, P. R. and PARADELLA, W. R., Color enhancement of remote sensing imagery using HIS transformations and decorrelation stretch methods. **International Society for Photogrammetry and Remote Sensing, Commission II**, International Archives of Photogrammetry and Remote Sensing (Kyoto, ISPRS), 27, 1988, part B10, pp. 312-320.

DUCAN, J. S.; AYACHE, N. Medical Image Analysis: Progress over Two Decades and the Challenges Ahead. **IEEE Trans. on Pattern Analysis and Machine Intelligence**. 22(1):85-106, Janeiro, 2000.

EPIPHANIO, J.C.N.; GLERIANI, J.M.; FORMAGGIO, A.R.; RUDORFF, B.F.T. Índices de vegetação no sensoriamento remoto da cultura do feijão. **Pesquisa Agropecuária Brasileira, Brasília**, v.31, n.6, p.445-454, jun. 1996.

EPIPHANIO, J.C.N.; LUIZ, A.J.B.; FORMAGGIO, A.R. Estimativas de áreas agrícolas municipais, utilizando sistema de amostragem simples sobre imagens de satélite. **Bragantia**, Campinas, v.61, n.2, p.187-197, 2002.

FEDOROV, D. Sistema semi-automático de registro e mosaico de imagens. 2003. 150 p. **Dissertação (Mestrado)** – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003.

FELGUEIRAS, C.A.; ERTHAL, G.J. Aplicações de modelos numéricos de elevação e integração com imagens digitais. Sao Jose dos Campos: **Instituto Nacional de Pesquisas Espaciais**, 1988.

FERNANDES, J. M. Manejo de pragas e doenças e a superestrada da informação: situação atual e perspectivas. In: **Seminário sul-brasileiro de informática na agricultura**, 1, 1996, Passo Fundo. Anais... Passo Fundo: EMBRAPA-CNPT, p. 24-29, 1996.

FLORENZANO, T. G. Imagens TM-Landsat e HRV-Spot na elaboração de cartas geomorfológicas de uma região do Rio Taquari, MS. **Pesquisa Agropecuária Brasileira**, v. 33, n. especial, p. 1721-1727, 1998.

FONSECA, L. M. G., Prasad, G. S. S. D., Mascarenhas, N. D. A. Combined Interpolation-Restoration of Landsat Images through FIR Filter Design Techniques. **International Journal of Remote Sensing**, vol. 14, no. 13, pp. 2547 – 2561, 1993.

FONSECA, L. M. G; MANJUNATH, B. S. Registration techniques for multisensory remotely sensed imagery. **PE&RS**, v. 62, n. 9, Sept. 1996, p. 1049-1056, 1996.

FRY, W. E. Epidemiology: dynamics of interacting pathogen and host populations. In: FRY, W. E. (Ed.). **Principles of plant management**. New York: Academic Press. 1982. p. 43-65.

GARGUET-DUPOUR, B.; GIREL, J.; CHASSERY, J. M.; PAUTOU, G. The use of multiresolution analysis and wavelets transform for merging SPOT panchromatic and multispectral image data. **Photogrammetric engineering and remote sensing**, American Society for Photogrammetry and Remote Sensing, v. 62, n. 9, p. 1057

GASPAROTTO, L. Epidemiologia do mal das folhas (*Mycrocyclus ulei*) da seringueira (*Hevea* spp). **Tese (Doutorado em Epidemiologia)** – Centro de Ciências Agrárias, Universidade Federal de Viçosa, Viçosa. 1988. 124 f.

GIRALDO, D.; JUAREZ, H.; PÉREZ, W.; TREBEJO, I.; YZARRA, W.; FORBES, G. Severidad del tizón tardío de la papa (*Phytophthora infestans*) en zonas agrícolas del Perú asociado con el cambio climático. **Revista Peruana Geo-Atmosférica RPGA** (2), 56-67, 2010.

GÖÇERI, E.; LOMÉNIE, N. Interpolation approaches and spline based resampling for MR images, **Health Informatics and Bioinformatics (HIBIT)**, 2010 5th International Symposium on, vol., no., pp.137-143, 20-22 April 2001

GOMES, J; VELHO, L. **Computação Gráfica: Imagem**. Rio de Janeiro: IMPA/SBM, 1994.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. 3 ed. São Paulo: Edgard Blucher, 2000; 509p.

GONZALEZ R. C., WOODS, R. E. Digital Image Processing. Second Edition, Prentice-Hall, 2001.

GONZALEZ-AUDICANA, M.; OTAZU, X.; FORS, O.; SECO, A. Comparison between Mallat's and the a trous discrete wavelet transform based algorithms for the fusion of multispectral and panchromatic images. **International Journal of Remote Sensing**, Taylor & Francis, v. 26, n. 3, p. 595

GONZALEZ-AUDICANA, M.; SALETA, J.; CATALAN, R.; GARCIA, R. Fusion of multispectral and panchromatic images using improved ihs and pca mergers based on wavelet decomposition. **IEEE Transactions on Geoscience and Remote Sensing**, v. 42, n. 6, p. 1291.

GHINI, R.; HAMADA, E.; GONÇALVES, R.R.V.; GASPAROTTO, L.; PEREIRA, J.C.R. Análise de risco das mudanças climáticas globais sobre a sigatoka-negra da bananeira no Brasil. **Fitopatologia Brasileira**, v. 32, p. 197-204, 2007.

HAYDAN, R.; DALKE, G.; HENKEL, J.; BARE, J. Applications of the HIS colour transform to the processing of multisensor data and image enhancement. In: **International Symposium on Remote Sensing Of Arid And Semiarid Lands**, 1., 1982, Cairo, Egypt. Proceedings... Cairo: ERIM, 1982. v. 1, p. 599

HAYDN, R. G. W. DALKE, and J. HENKEL. Application of the HIS color transform to the processing of multisensor data and image enhancement: Proceedings, **International Symposium on Remote Sensing of Arid and Semi-arid Lands**, Cairo, Egypt, pp. 599 – 616, 1982

HILL, J. DIEMER, O., STOVER, ULDELHOVEN, TH., A local correlation approach for the fusion of remote sensing data with different spatial resolutions in forestry application, **International Archives of Photogrammetry and Remote Sensing**, Vol. 32, Part 7-4-3 W6, Valldolid, Spain, 3-4, 1999.

HOU, H. S.; ANDREWS, C., Cubic splines for image interpolation and digital filtering, **IEEE Trans. Acoust., Speech, Signal Processing**, vol. ASSP-26, pp. 508–517, Dec, 1978.

HSITMG, C., LIN, C. M., CHANG, F. J., Pseudocoloring with Histogram Interpolation Ninth **International Conference on Hybrid Intelligent Systems** 2009.

HWANG, J. W., LEE, H. S., Adaptive image interpolation based on local gradient features, **IEEE Signal Process. Lett.** 113, 359–362 2004.

INPE – **Apostila Teórica do curso de Processamento Digital de Imagens**. Divisão de Processamento de Imagens – INPE, São José dos Campos, 2008.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Departamento de Processamento de Imagens. (INPE/DPI). Sistema de Processamento de Informações Georreferenciadas (SPRING). <http://www.inpe.br/spring>. Março, 1977.

ISAAKS, E. H.; SRIVASTAVA R. M. An Introduction to Applied Geostatistics. New York, **Oxford University Press**, 1989. 560p.

JENSEN, J. R. Introductory digital image processing: a remote sensing perspective. New Jersey: **Prentice-Hall**. 1986. p 379.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução da 2 ed. por (pesquisadores do INPE): José Carlos N. Epiphany (Coordenador); Antonio R. Formaggio; Athos R. Santos; Bernardo F. T. Rudorff; Cláudia M. Almeida; Lênio S. Galvão. São José dos Campos: Parêntese. 2009. 672 p.

JOLLIFFE, I. T. Principal component analysis. John wiley & sons. New York, USA: Springer, 2002. 32

JONHSON, K. B. The role of predictive systems in disease management. In: TENG, P. S. Crop loss assesment and pest management. **American Phytopathological Society**, St. y Paul, MN, USA. 1987. 176-90 p.

JOURNEL, A.G. Fundamentals of geostatistics in five lessons. California, Stanford Center for Reservoir Forecasting Applied Earth Sciences Department, 1988.

KIM, M. MADDEN, AND T. A. WARNER, Forest type mapping using object-specific texture measures from multispectral IKONOS imagery: Segmentation quality and image classification issues, **Photogramm. Eng. Remote Sens.**, vol. 75, no. 7, pp. 819–829, Jul. 2009.

KRAUSE, R. A.; MASSIE, L. B.; HYRE, R. A. BLITECAST: A computerized forecast of potato late blight. **Plant Disease Reporter**, Washington, US, v. 59, n. 2, p. 95-98, 1975.

KRIGE, D.G. A statistical approach to some basic mine evaluation problems on the Witwatersrand. **Johanesburg Chemistry Metallurgy Mining Society South African**, 52 (6): 119-139, 1951.

LEHMANN, T. M., GONNER, C., SPITZER, K.. Addendum: B-spline interpolation in medical image processing. **IEEE Trans Med Imag** 20:660–665. 2001

LEONARDI, S. S.; ORTIZ, J. O.; FONSECA, L. M. Comparação de técnicas de fusão de imagens para diferentes sensores orbitais. **Anais do XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, 2005. p. 4111 – 4113.

LI, H.; MANJUNATH, B.; MITRA, S. Multi-sensor image fusion using the wavelet transform. In: **IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING**, 1., 1994, Austin, USA. Proceedings... Austin: IEEE, 1994. v. 1, p.

LILLESAND, T.M.; KIEFER, R.W. **Remote Sensing and Image Interpretation**. 2a Edition. New York. John Wiley & Sons. 2000. 721p. Forestry, Lake Buena Vista, Florida, 10-12 January 2000.

LILLO-SAAVEDRA, M.; GONZALO, C. Spectral or spatial quality for fused satellite imagery a trade of solution using the wavelet à trous algorithm. **International Journal of Remote Sensing**, Taylor & Francis, v. 27, n. 7, p. 1453

MAFFIA, L.A.; MIZUBUTI, E.S.G.; ALFENAS, A.C.; MAFIA, R.G. Quantificação de doenças de plantas. In: ALFENAS, A.C.; MÁFIA, R.G. **Métodos em Fitopatologia**, UFV, Viçosa, p. 161-172. 2007

MAHYARI, A.G.; YAZDI, M. Panchromatic and Multispectral Image Fusion Based on Maximization of Both Spectral and Spatial Similarities, **IEEE Transactions on Geoscience and Remote Sensing**, vol.49, no.6, pp.1976-1985, June 2011

MALLAT, S. G., 1989. Multifrequency channel decomposition of images and wavelet models, **IEEE Transactions on Acoustics, Speech, and Signal Processing**, p.2091 – 2110.

MARR, D., and E. HILDRETH, 1980. Theory of edge detection. **Proceedings of Royal Society of London**, B207: 187 – 217.

MASCARENHAS, N. D. A., BANON, G. J. F., and FONSECA, L. M. G., 1991, Simulation of a panchromatic band by spectral linear combination of multispectral bands. **Proceedings of the International Geoscience and Remote Sensing Symposium**, Espoo, Finland, June 1991 (New York. IEEE), pp. 407 – 414.

MASCARENHAS, N. D. A., VELASCO, F. R. D. **Processamento Digital de Imagens**. EBAI, Kapelusz: Buenos Aires, 1984.

MERIAUDEAU, F., TRUCHETET, F., GREVEY, D., VANNES, A. B. Laser cladding process and image processing. **Journal of Lasers in Engineering**, vol.6, pp. 161-187, 1997

MODENESE, S. H. **Processamento Digital de Imagens para Identificação da Sigatoka Negra em bananais utilizando Análise de Componentes Principais e Redes Neurais Artificiais**. 2008. 83 p. **Tese (Doutorado)** - Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas, Botucatu, 2008.

MORAES, W. da S.; FUKUDA, E.; MENDONÇA, J. C. de.; SILVA, C. M. da.; SILVA, S. H. M. da Behaviour of black Sigatoka in banana plantations of the Ribeira Valley, Sant Paul, Brazil. In: **Anais da XVII Reunião Internacional da Associação para a Cooperação em Pesquisas sobre Banana no Caribe e América Tropical – ACORBAT**, 17., Joinvile, SC, 2006. Anais... Joinvile, SC: IFAC, 2006. p. 656-661.

MORAES, W. da S.; MENDONÇA, J. C.; FUKUDA, E.; MENDES, C. das.; LIMA, J. D.; SANTOS, A. J. dos. Dominância da Sigatoka-negra em bananais do Vale do Ribeira. **Fitopatologia Brasileira**, Brasília, DF, v. 30, n. 3, p. 193, 2005. Suplementos.

NAPOLEÃO, M.C.; LINGNAU, C.; ANTUNES, A. F. B. **A Influência dos Métodos de Reamostragem na Fusão de Imagens Landsat-5 TM e SPOT Pancromática**. Universidade Federal do Paraná – UFPR, 2001.

NASCIMENTO, R. F. F.; ALCÂNTARA, E. H.; KAMPEL, M.; STECH, J. L.; NOVO, E. M. L. M.; FONSECA, L. M. G. O algoritmo Support Vector Machines (SVM): Avaliação da separação ótima de classes em imagens CCD-CBERS-2. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 14. (SBSR), 2009, Natal. Anais... São José dos Campos: INPE, 2009. p. 2079-2086.

NAUE, C. R., MARQUES, M. W., LIMA, N. B, GALVÍNCIO, J. D. Sensoriamento remoto como ferramenta aos estudos de doenças de plantas agrícolas: uma revisão. **Revista Brasileira de Geografia Física** 03 (2010) 190-195.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. Editora Edgar Blücher Ltda. São José dos Campos, 1989. 308p.

OTAZU, X.; GONZALEZ-AUDICANA, M.; FORS, O.; NUNEZ, J. Introduction of sensor spectral response into image fusion methods. application to wavelet-based methods. **IEEE Transactions on Geoscience and Remote Sensing**, v. 43, n. 10, p. 2376 – 2385, Oct. 2005.

PAPA, J. P. Restauração das imagens do satélite CBERS-1 utilizando POCS. 2005. 81p. **Dissertação (Mestrado em Ciência da Computação)** - Universidade Federal de São Carlos - UFSCar, São Carlos, 2005.

PARKER, J. A., KENYON, R. V., TROXEL, D. E. Comparison of interpolation methods for image resampling, **IEEE Trans. Med. Imag.**, vol. 2, Mar, 1983, pp. 31–39.

PINHO, C. M. D.; RENNÓ, C. D.; KUX, H. J. H. Avaliação de técnicas de fusão aplicadas à imagem Quickbird. In: **Simpósio Brasileiro de Sensoriamento Remoto**. 12, 2005, Goiânia. Anais... São José dos Campos: INPE, 2005. 42254232p. CD-ROM.

POHL, C.; GENDEREN, J. L. V. Multisensor image fusion in remote sensing: concepts, methods and applications. **International Journal of Remote Sensing**, Taylor & Francis, v. 19, n. 5, p. 823-854, 1998. 29

PONZONI, F.J. Dados TM/Landsat na identificação do ataque da Vespa-da-madeira em plantios de *Pinus* sp. In: **Simpósio Brasileiro De Sensoriamento Remoto**, 8, 1996, Salvador, BA.

PRATT, W. K.. **Digital Image Processing**, second ed., Wiley, New York, 1991.

PUGSLEY, L., CRUVINEL, P. E., CARAMORI, P. H. New agroclimatic digital images classification system and risk zone mapping. In: **Brazilian Symposium on Computer Graphics and Image Processing**, 14., 2001, Florianópolis. Proceedings... Los Alamitos: IEEE Computer Society, 2001. p. 237-244.

R. M. HARALICK, L. G. SHAPIRO, *Computer and Robot Vision*, AddisonWesley. Reading, MA. 1992.

ROSENFEDL, A. AND KAK, A. C. **Digital Picture Processing**. Vol. I and II. Academic Press, Orlando, Fla., 1982.

RISTIC, D. M., PAVLOCI, M., RELJIN, R. Image Segmentation Method Based on SelfOrganizing Maps and K-Means Algorithm”, **9th symposium of Neural Network Applications in Electrical Engineering**, NEUREL-2008.

RSI (Research Systems, Inc). **ENVI User´s Guide**. ENVI Version 4.0 September, 2003.

RUDORFF, B. F. T.; MELLO, M. P.; SHIMABUKURO, Y. E. Imagens de satélites de sensoriamento remoto no Brasil. In: **Simpósio de Geotecnologias no Pantanal (GEPANTANAL)**, 2., 2009, Corumbá, MS. Anais... Campinas / São José dos Campos, SP: EMBRAPA Informática Agropecuária / INPE, 2009. p. 1077-1083.

RUDORFF, B. F. T.; SHIMABUKURO, Y. E.; CEBALLOS, J. C., (Eds.). **O sensor MODIS e suas aplicações ambientais no Brasil**. São José dos Campos-SP: Editora Parêntese, 2007a. 423 p.

RUDORFF, B. F. T.; SUGAWARA, L. M. Mapeamento da cana-de-açúcar na região Centro-Sul via imagens de satélites. **Informe Agropecuário**, v. 28, n. 241, p. 79-86, 2007b.

SAITO E. A. Mapeamento de cana-de-açúcar em áreas de assentamento de reforma agrária no município de Mirante do Paranapanema-SP utilizando imagens CCD/CBERS-2B. In: **Simpósio Brasileiro de Sensoriamento Remoto, 14. (SBSR)**, 2009, Natal. Anais... São José dos Campos: INPE, 2009. p. 419-426.

SCHOWENGERDT, R. A. Techniques for image processing and classification in remote sensing. **Academic Press**, 1983. 249.

SHIMABUKURO, Y. E.; RUDORFF, B. F. T. Dados do sensor MODIS para o mapeamento e monitoramento da cobertura vegetal e uso da terra. In: **Simpósio de Geotecnologias no Pantanal (GEPANTANAL)**, 1., 2006, Campo Grande. Anais... Campinas: Embrapa Informática Agropecuária; São José dos Campos: INPE, 2006. p. 929-938.

SHOWENGERDT, R; A. Remote Sensing models and methods for image processing. New York: **Academic Press**, 1997. 552p.

SIEGAL, B. S., GILLESPIE, A. R. **Remote Sensing in Geology**, Wiley, New York, 702 p., 1980.

SILVA, F. C. DA. Implementação e Avaliação de Métodos de Fusão para Geração de Imagens Coloridas de Alta Resolução. 2009. 83 p. **Dissertação (Mestrado)** – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003.

SILVA, F. C.; DUTRA, L. V.; FONSECA, L. M. G.; KORTING, T. S. Remote sensing image fusion using generalized ihs transformation. In: **Ursi Commission F Triennial Open Symposium on Radio Wave Propagation And Remote Sensing, 11.**, 2007, Rio de Janeiro, Brasil. Proceedings... Rio de Janeiro: URSI, 2007.

SILVA, F. F.; SERVELLO, E. L.; FONSECA, L. M. G.; SANTOS, J. R.; KUPLICH, T. M. Análise da distribuição de copas de Araucária (*Araucaria angustifolia* Bert. O. Ktz.) a partir da fusão de imagens HRC-CCD/CBERS-2B. In: **Simpósio Brasileiro de Sensoriamento Remoto, 14.** (SBSR), 2009, Natal. Anais... São José dos Campos: INPE, 2009. p. 2217-2223.

SILVA, R. K., RIBEIRO, S. R. A. Importância da alteração do histograma de imagem de alta-resolução (PAN) para fusão de imagens digitais pelo método de componentes principais. **Ambiência**. Guarapuava, PR v.5 n.1 p. 27 – 36.

SIMARD, M. S. GRANDI, G., The use of decision tree and multiscale texture for classification of JERS-1 SAR data over tropical forest, **IEEE Trans. Geosci. Remote Sens.**, vol. 38, no. 5, pp. 2310–2321, Sep. 2000.

SMITH, A. R. Color Gamut Transform Pairs, **Computer Graphics**, August, pp. 12 – 18. 1978

SMITH, J. O. Gram-Schmidt Orthogonalization in: Mathematics of discrete Fourier transforms (DTF), http://wwwccrma.stanford.edu/~jos/mdtf/Gram_Schmidt_Orthogonalization.html

SONKA M, HLAVAE V, BOYLE, R. Image processing, analysis and machine vision. **Chapman & Hall Computing**, Cambridge, pp 222-224, 227-8, 1995.

STARK, H. Theory of Convex Projection and Its Application to Image Restoration. **IEEE International Symposium on Circuits and Systems**, Vol. 1, pp. 963-964, 1988.

STARK, H., YANG, Y. Vector Space Projections. **Wiley**, 1998.

TOMLIN, C.D. Technical Issues. In: Maguire, D.J.; Goodchild, M.F.; Rhind, D.W. (eds.). **Geographical information systems: principles and applications**. Harlow: Longman Scientific and Technical, 1991. v. 1, n.23, p. 361-375.

TRABAQUINI, K. MIGLIORANZA, E.; FRANCA, V.; PEREIRA NETO, O. C. Uso da geotecnologia para caracterizar os cafezais no município de Londrina-PR, em relação à

altimetria, declividade e tipo de solo. **Eng. Agríc.**, Jaboticabal, v. 30, n. 6, 2010.

TRAINA Jr. C.; TRAINA, A. J. M.; RIBEIRO, R. A.; SENZAKO, E. Y.. Content-based Medical Images Retrieval in Object Oriented Database. Proceedings of 10th **IEEE Symposium on Computer-Based Medical System**, vol. II. pp. 67-72. Maribor- Slovenia, 1997.

TU, T.-M.; HUANG, P.; HUNG, C.-L.; CHANG, C.-P. A fast intensity-huesaturation fusion technique with spectral adjustment for IKONOS imagery. **IEEE Geoscience and Remote Sensing Letters**, v. 1, n. 4, p. 309, 2004.

TU, T.-M.; SU, S.-C.; SHYU, H.-C.; HUANG, P. S. A new look at IHS-like image fusion methods. **Information Fusion 2** (2001) 177 – 186.

VENTURA, F. N. Fusão de imagens de sensoriamento remoto utilizando a transformada Wavelet. **Tese (Doutorado)**, INPE, 2002.

VENTURIERI, A. Utilização da segmentação de imagens e lógica nebulosa para treinamento de uma rede neural artificial na caracterização de classes de uso da terra na região de Tucuruí - PA. 1999. 111p. **Dissertação (Mestrado em Sensoriamento Remoto)** - Instituto Nacional de Pesquisas Espaciais, Sao Jose dos Campos, 1999.

VRABEL, J. DORAISWAMY, P., and STERN, A. Application of Hyperspectral Imagery Resolution Improvement for Site-Specific Farming, **ASPRS 2002 Conference Proceedings**. 2002b.

VRABEL, J. DORAISWAMY, P., MCMURTREY, J. AND STERN, A. Demonstration of the Accuracy of Improved Resolution Hyperspectral Imagery. In: **SPIE Symposium, 2002a. Proceedings...** SPIE Vol. 4725, p. 556. – 567. Algorithms and Technologies for Multispectral, Hyperspectral and Ultraspectral Imagery VIII, Sylvia S. Shen; Paul E. Lewis; Eds.

VRABEL, J. Multispectral imagery band sharpening study. **Photogrammetric Engineering & Remote Sensing**, v. 62, n. 9, p. 1075 – 1083., 1996.

WALD, L. Some terms of reference in data fusion. **IEEE Transaction on Geoscience and Remote Sensing**, v. 37, n. 3, p. 1190 – 1193, 1999.

WANG, C. CHEN,T., QU, Z., A Novel Improved Median Filter for Salt-and-Pepper Noise from Highly Corrupted Images, pp. 718-722, **IEEE**, 2010.

WANG, Z.; BOVIK, A. C. A. Universal Quality Index. **IEEE Signal Processing Letters**, v.10, 2002.

WELCH, R.; EHLERS, M. Merging multiresolution spot hrv and landsat tm data. **Photogrammetric Engineering and Remote Sensing**, v. 51, p. 301 – 303, 1987.

WITTE, JOHN S.; WITTE, ROBERT S. **Estatística**. LTC. 7a edição 2005. 506.

WMO. Agrometeorological aspects of operational crop protection. Genebra: WMO, 1988. 185 p. **Technical note**, 192.

XU, M., CHEN H., VARSHNEY, P.K. An Image Fusion Approach Based on Markov Random Fields, **IEEE Transactions on Geoscience and Remote Sensing**, vol.49, no.12, pp.5116-5127, Dec. 2011

ZEILHOFER, P. Soil mapping in the Pantanal of Mato Grosso, Brazil, using multitemporal Landsat TM data. **Wetlands Ecology and Management**, v. 14, n. 5, p. 445-461, 2006.

ZHANG, YUN. Understanding Image Fusion. **Photogrammetric Engineering & Remote Sensing**. p. 657, 2004.

ZHAO, X., LEE, M. E., KIM, S. H. Improved Image Segmentation Method based on Optimized Threshold using Genetic Algorithm, **IEEE** 2008.

ZIMBACK. C.R.L. **Mapa de solos da bacia do Rio Pardo (SP)**. Botucatu: Universidade Estadual Paulista, 1997. 55 p.

ZITOVA, B.; FLUSSER, J. Image registration methods: a survey. **Image and Vision Computing**, Elsevier, v. 21, n. 11, p. 977, 2003.