

UNIVERSIDADE ESTADUAL DO CENTRO-OESTE, UNICENTRO-PR

**CLASSIFICAÇÃO ORIENTADA AO OBJETO DE
IMAGEM QUICKBIRD-2 PARA A IDENTIFICAÇÃO
DA ARAUCÁRIA**

DISSERTAÇÃO DE MESTRADO

VAGNER ALEX PESCK

IRATI-PR

2011

VAGNER ALEX PESCK

**CLASSIFICAÇÃO ORIENTADA AO OBJETO DE IMAGEM QUICKBIRD-2 PARA A
IDENTIFICAÇÃO DA ARAUCÁRIA**

Dissertação apresentada à Universidade Estadual do Centro-Oeste, como parte das exigências do Programa de Pós-Graduação em Ciências Florestais, área de concentração em Manejo Florestal, para a obtenção do título de Mestre.

Prof. Dr. Attilio Antonio Disperati
Orientador

Prof. Dr. João Roberto dos Santos
Co-Orientador

Prof^ª. Dr^ª. Deise Lazzarotto
Co-Orientadora

IRATI-PR

2011

UNIVERSIDADE ESTADUAL DO CENTRO OESTE
UNICENTRO
PR 153 - Km 07
Fone (0xx) 42 3421-3000
Home page: <http://www.unicentro.br>
CEP: 84.500-000 - Caixa Postal 21
Irati - Paraná - Brasil

Catálogo na Fonte
Biblioteca da UNICENTRO
Campus de Irati - PR.

P473c PESCK, Vagner Alex.
Classificação orientada ao objeto de imagem Quickbird-2 para a identificação da Araucária / Vagner Alex Pesck. – Irati, PR : UNICENTRO, 2011.

76f.
ISBN
Dissertação (Mestrado em Ciências Florestais) - Universidade Estadual do Centro-Oeste, PR
Orientador : Professor Dr. Attilio Antonio Disperati
Co-Orientador : Professor Dr. João Roberto dos Santos
Co-Orientador : Professora Dra. Deise Lazzarotto

1. Engenharia Florestal – dissertação. 2. Floresta Ombrófila Mista. 3. Fusão de Imagens. 4. Algoritmo K Nearest Neighbor, 5. Lógica fuzzy. I. Santos, João Roberto dos. II. Lazzarotto, Deise. III. Título.

CDD 634.9



Universidade Estadual do Centro-Oeste

Reconhecida pelo Decreto Estadual nº 3.444, de 6 de agosto de 1997

PROGRAMA DE PÓS-GRADUAÇÃO *STRICTO SENSU* EM CIÊNCIAS FLORESTAIS

PARECER

Defesa Nº 18

A Banca Examinadora instituída pelo Colegiado do Programa de Pós-Graduação *Stricto Sensu* em Ciências Florestais, do Setor de Ciências Agrárias e Ambientais, da Universidade Estadual do Centro-Oeste, *Campus* de Irati, após arguir o mestrando **Vagner Alex Pesck** em relação ao seu trabalho de dissertação intitulado "CLASSIFICAÇÃO ORIENTADA AO OBJETO DE IMAGEM QUICKBIRD-2 PARA A IDENTIFICAÇÃO DA ARAUCÁRIA", é de parecer favorável à **APROVAÇÃO** do estudante, habilitando-o ao título de **Mestre em Ciências Florestais**, Área de Concentração em Manejo Sustentável de Recursos Florestais.

Irati-PR, 10 de fevereiro de 2011.

Dr.ª Christel Lingnau

Universidade Federal do Paraná
Primeira Examinadora

Dr. João Roberto dos Santos

Instituto Nacional de Pesquisas Espaciais
Segundo Examinador

Dr. Atílio Antonio Disperati

Universidade Estadual do Centro-Oeste
Orientador e Presidente da Banca Examinadora

Home Page: <http://www.unicentro.br>

Campus Santa Cruz: Rua Pres. Zacarias 875 – Cx. Postal 3010 – Fone: (42) 3621-1000 – FAX: (42) 3621-1090 – CEP 85.015-430 – GUARAPUAVA – PR
Campus CEDETEG: Rua Simeão Camargo Varela de Sá, 03 – Fone/FAX: (42) 3629-8100 – CEP 85.040-080 – GUARAPUAVA – PR
Campus de Irati: PR 153 – Km 07 – Rincinho – Cx. Postal, 21 – Fone: (42) 3421-3000 – FAX: (42) 3421-3067 – CEP 84.500-000 – IRATI – PR

*Aos meus pais Arno Christiano Pesck e
Maria Anice Scheidt Pesck, á minha irmã
Vanessa Alessandra Pesck, ao meu orientador
Attilio Antonio Disperati, aos meus amigos e a
Edicélis Rodrigues de Oliveira.*

DEDICO

AGRADECIMENTOS

Primeiramente agradeço a DEUS, por ter me dado força e capacidade para desenvolver este trabalho.

Em especial ao meu orientador Attilio Antonio Disperati por todos os esforços desde o início do mestrado.

Aos co-orientadores Deise Lazzarotto e ao João Roberto dos Santos pelo conhecimento repassado, pela simpatia e amizade.

Agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de estudos durante parte da mestrado.

Aos meus amigos Engenheiros Florestais, Thiago Floriani Stepka, Gerson dos Santos Lisboa e Ademar Luiz Chiqueto pela companhia e ajuda no trabalho de campo.

A acadêmica de Engenharia Florestal, Alynne Rudek pela ajuda no processamento dos dados.

Aos professores da pós graduação, em especial ao Dr. Afonso Figueiredo Filho, Dr. Attilio Antonio Disperati, Dr. Paulo Costa de Oliveira Filho, Dr^a. Andréa Nogueira Dias, Dr. Luciano Farinha Watzlawick, Dr^a. Christel Lingnau, que foram docentes no cumprimento dos créditos.

Ao suporte técnico da SULSOFT em especial ao Eng. Cartógrafo Hilário Bráz de Medeiros, e ao Físico Juliano Schirmbeck.

Ao programa de Mestrado pelo auxílio financeiro e por ter dado oportunidade de realizar este trabalho.

Ao Prof. Afonso Figueiredo Filho pela disponibilidade da imagem de satélite Quickbird-2, usada no trabalho.

À Fundação Araucária pelo apoio financeiro à pesquisa, na fase de trabalho de campo, “Fotografias aéreas versus imagens satelitárias de altíssima resolução no delineamento de copas de Araucária, na qual está inserida a presente dissertação.

Cada pessoa que passa em nossa vida passa sozinha, é porque cada pessoa é única e nenhuma substitui a outra! Cada pessoa que passa em nossa vida passa sozinha e não nos deixa só porque deixa um pouco de si e leva um pouquinho de nós. Essa é a mais bela responsabilidade da vida e a prova de que as pessoas não se encontram por acaso.

Charles Chaplin

SUMÁRIO

LISTA DE SIMBOLOS E ABREVIATURAS.....	ix
LISTA DE FIGURAS.....	x
LISTA DE TABELAS.....	xi
RESUMO.....	xii
ABSTRACT	xiii
1. INTRODUÇÃO	1
2. OBJETIVOS	5
3. REFERENCIAL TEÓRICO.....	6
3.1 Floresta Ombrófila Mista	6
3.4 Fusão de Imagens	8
3.4.1 Modelos Algébricos.....	8
3.4.1.1 Brovey	8
3.4.2 Modelos de Domínio Espectral.....	8
3.4.2.1 HSV	9
3.4.2.2 Principais Componentes (PC)	9
3.4.2.3 Gram – Schmidt (GS).....	10
3.5 Correção Geométrica.....	10
3.5.1 Ortorretificação	12
3.5.2 GCP e GPS em Modo Diferencial	13
3.6 Segmentação.....	14
3.7 Lógica Fuzzy	16
3.8 Classificação Orientada ao Objeto	20
4. MATERIAIS E MÉTODOS	24
4.1 Localização	24
4.2 Clima.....	25
4.3 Solos.....	25
4.4 Vegetação.....	26
4.5 Área de pesquisa	27
4.6 Dados de sensoriamento remoto	27
4.7 Dados Cartográficos	28
4.8 <i>Softwares</i> e Aplicativos	28
4.9 Equipamentos.....	29
4.10 Metodologia.....	29
4.10.1 Definição da Área de Estudo	30

4.10.2 Fusão de imagens.....	31
4.10.3 Trabalho de campo.....	32
4.10.4 Correção Geométrica	34
4.10.4.1 Modelo Digital do Terreno.....	35
4.10.4.2 Ortorretificação	35
4.10.5 Classificação Orientada a Objetos	36
4.10.5.1 Preparação dos Dados e Definição das Classes.	37
4.10.5.2 Segmentação	39
4.10.5.3 Construção das regras	42
4.10.5.4 Classificação Supervisionada e por Regras.....	43
4.10.5.5 Avaliação da Classificação	44
5. RESULTADOS E DISCUSSÃO	47
5.1 Fusão de Imagens	47
5.1.2 Avaliação Qualitativa.....	47
5.1.3 Avaliação Quantitativa	47
5.2 Correção Geométrica.....	50
5.2.1 Ortorretificação	51
5.3 Interpretação Visual da Imagem Quickbird	53
5.4 Segmentação.....	55
5.5 Classificação Orientada ao Objeto	56
5.5.1 Supervisionada.....	56
5.5.2 Classificação por regras	58
5.5.3 Comparação entre classificação supervisionada e por regras.....	61
6. CONCLUSÕES E RECOMENDAÇÕES	64
7. REFERÊNCIAS BIBLIOGRÁFICAS	65
APÊNDICE	75

LISTA DE SIMBOLOS E ABREVIATURAS

B – *Blue*

CONAMA – Conselho Nacional do Meio Ambiente

DAP – Diâmetro à Altura do Peito

DN – Número Digital

ENVI – *Environment for Visualizing Images*

FLONA – Floresta Nacional

FOM – Floresta Ombrófila Mista

FX – *Feature Extraction*

G – *Green*

GCP – *Ground Control Points*

GIS – Sistema de Informação Geográfica

GPS – *Global Positioning System*

GS – *Gram – Schmidt*

HSV – *Hue, Saturation e Value*

IBGE – Instituto Brasileiro de Geografia e Estatística

MDT – Modelo Digital do Terreno

NDVI - *Normalized Difference Vegetation Index*

NIR – Infravermelho Próximo

PAN – Pancromático

PC – Principais Componentes

R – *Red*

REM – Radiação Solar/Eletromagnética

RMS – Erro Médio Quadrático

RPC – *Rational Polynomial Coefficients*

RSI - *Research Systems Inc*

SAD 69 – *South American Datum of 1969*

UTM – *Universal Transverse Mercator*

UV – Ultra violeta

LISTA DE FIGURAS

Figura 1: Função de pertinência de um conjunto <i>fuzzy</i>	18
Figura 2: Função de pertinência <i>fuzzy</i> e função abrupta.....	18
Figura 3: Função de pertinência sigmoidal.....	19
Figura 4: Mapa de localização da FLONA de Irati.....	24
Figura 5: Mapa das classes de solos na FLONA de Irati - PR.....	26
Figura 6: Área das parcelas permanentes.....	27
Figura 7: Aparelho DGPS <i>Leica</i> (a) e GPS de caminhada Garmin (b), utilizados no trabalho de campo.....	29
Figura 8: Fluxograma referente às etapas realizadas neste presente trabalho.....	30
Figura 9: Imagem Quickbird (a), e composição falsa cor da imagem Quickbird (Bandas R4,G3 e B2), referente a área de estudo, com experimento de 25 ha (b).....	31
Figura 10: Coleta de um ponto de controle com GPS.....	33
Figura 11: Levantamento de campo, referente à situação das copas.....	34
Figura 12: Etapas para realização da classificação da imagem.....	36
Figura 13: Mosaico de fotografias aéreas 1:2000 utilizado como base para identificação das classes.....	37
Figura 14: Interface do <i>ArcView</i> mostrando os valores de intensidade dos objetos.....	42
Figura 15: Comparação entre a imagem multiespectral Original (a) e as técnicas de fusão testadas.....	49
Figura 16: Histogramas comparando a imagem multiespectral original (a) e as técnicas de fusão testadas.....	50
Figura 17: Pontos-testes distribuídos sobre a imagem ortorretificada.....	51
Figura 18: Modelo digital do terreno utilizando a rotina Envi MDT.....	52
Figura 19: Valores de escala testados.....	55
Figura 20: Resultado da classificação supervisionada.....	58
Figura 21: Imagem classificada por regras.....	60

LISTA DE TABELAS

Tabela 1: Especificações da Imagem Quickbird.....	28
Tabela 2: Classes selecionadas para o estudo.....	38
Tabela 3: Escalas de segmentação testadas para a imagem Quickbird-2.....	41
Tabela 4: Regras utilizadas para classificar a imagem Quickbird-2.....	44
Tabela 5: Comparação entre os parâmetros estatísticos da imagem multiespectral original e da sintética simulada.....	48
Tabela 6: Chave de interpretação das classes de estudo.....	54
Tabela 7: Regras utilizadas para cada classe.....	59
Tabela 8: Resultado referente à classificação da imagem Quickbird.....	61
Tabela 9: Matriz de confusão para a classificação supervisionada.....	61
Tabela 10: Acurácia do produtor e do usuário para a classificação por regras e supervisionada.....	62
Tabela 11: Matriz de confusão para a classificação por regras.....	63

RESUMO

Vagner Alex Pesck. Classificação orientada ao objeto de imagem Quickbird-2 para a identificação da Araucária.

O objetivo do presente estudo foi mapear as copas de *Araucaria angustifolia* em uma imagem Quickbird-2 através da classificação orientada ao objeto. A área de estudos está inserida em um fragmento de Floresta Ombrófila Mista localizada na Floresta Nacional de Irati – PR. Baseado em fotografias aéreas em escala 1:2.000, foi realizado o trabalho de campo em uma área de 10 hectares, coletando informações sobre as copas isoladas e agrupadas das Araucárias. Na imagem Quickbird-2 foram realizados diversos processamentos como: fusão, correção geométrica, segmentação e classificação orientada ao objeto. Testaram-se quatro métodos de fusão de imagens, e através de avaliação qualitativa e quantitativa, os métodos de Gram-Schmidt e Principais Componentes se mostraram superiores aos demais, com coeficientes de correlação de 0,93 e 0,95 respectivamente. A correção geométrica foi feita sobre a imagem fusionada, pelo método de Principais Componentes, e foram obtidos erros abaixo de um pixel, aceitáveis para a presente pesquisa. Na segmentação foram utilizados os seguintes valores de escala: 80 para a segmentação, e 90 para a fusão dos segmentos. Na classificação orientada ao objeto, utilizando a composição 4R3G2B, testaram-se o algoritmo *K Nearest Neighbor* na classificação supervisionada e a lógica *fuzzy* na classificação baseada em regras. Para as duas classes temáticas de maior interesse, *Araucaria angustifolia* e Folhasas, foram destacadas os valores mínimos e máximos da banda infravermelho próximo, NDVI (razão de bandas) e o atributo espacial “área”. Para a classe temática “sombra” destacou-se os valores mínimos e máximos da banda verde e intensidade (razão de bandas). O índice *Kappa* resultou os valores de 0,83 e 0,82 para as classificações supervisionada e por regras respectivamente, considerados como excelentes. A imagem Quickbird-2 se mostrou eficiente para a identificação da espécie *Araucaria angustifolia* nas duas classificações testadas.

Palavras-Chave: Floresta Ombrófila Mista, Fusão de Imagens, algoritmo *K Nearest Neighbor*, lógica *fuzzy*.

ABSTRACT

Vagner Alex Pesck. Object-oriented classification of Quickbird-2 image for the identification of Araucaria.

The objective of this study was to map the crowns of *Araucaria angustifolia* from a Quickbird-2 image using the object-oriented classification. The study area is located into a fragment of Mixed Ombrophilous Forest located on National Forest Irati – Paraná, Brazil. Based on aerial photographs at 1:2.000 scale, it was carried out fieldwork in an area of 10 hectares, collecting informations about the isolated and clusterings of Araucaria crowns. In the image Quickbird-2 was carried out some processing, such as: fusion, geometric correction, segmentation and object-oriented classification. It was tested four methods of image fusion, and through qualitative and quantitative analysis, Gram-Schmidt and Principal Components methods were superior to the others, with correlation coefficients of 0.93 and 0.95, respectively. Geometric correction was made on the fused image, resulted from the Principal Components method, which resulted errors below one pixel, acceptable for the study. In the segmentation process were used the following scale values: 80 for segmentation, and 90 for the merge segments. In the object-oriented classification, using the composition 4R3G2B, it was tested the supervised classification processed by the K Nearest Neighbor algorithm and the classification based on logic fuzzy rules. For the two thematic classes of interest, *Araucaria angustifolia* and hardwoods, it was highlighted by the minimum and maximum values of the near infrared band, NDVI (band ratio) and the attribute space "area." For the thematic class "shadow" stood out the minima and maximum values of green band and the intensity (band ratio). The resulting Kappa value of 0.83 and 0.82, for the supervised classification and by rule-based classification respectively, was considered as excellent. The Quickbird-2 image was efficient for the crown mapping of *Araucaria angustifolia* in both tested classifications.

Keywords: Araucaria Forest, Fusion Imaging, K Nearest Neighbor algorithm, logic fuzzy.

1. INTRODUÇÃO

A Floresta Ombrófila Mista (FOM), sempre despertou o interesse de muitos devido à sua beleza e exuberância e, também, por se tratar de uma fonte de matéria-prima e riqueza para o desenvolvimento econômico da região sul do Brasil (DLUGOZ, 2005).

Por sua natureza, a cobertura vegetal constitui o recurso natural mais susceptível à devastação e extermínio, posto que todas as formas de vida dependam do vegetal, sem esquecer que atende também à inúmeras necessidades humanas. Na Região Sul, dois terços da cobertura original constituía-se de florestas que, atualmente, estão reduzidas a cerca de 50 mil km², sendo preservados a altos custos, compreendendo na maioria, Parques e Reservas quase sempre em terrenos de difícil acesso (LEITE, 1994). Com relação ao ecossistema FOM, LEITE e KLEIN (1990) comentam que dos 177.600 km² de cobertura original, restavam apenas 20.000 km². Atualmente, a cobertura com esse ecossistema encontra-se ainda mais reduzida, mas não se têm informações sobre a real área remanescente.

A exploração desordenada que ocorreu de forma seletiva onde os indivíduos de maior porte das espécies mais valiosas eram abatidos conduziu a um processo de deterioração genética das espécies das florestas nativas. A alta qualidade da madeira da *Araucaria angustifolia* (Bert.) O. Ktze, principal espécie explorada e sua grande disponibilidade nos pinheirais do Sul do Brasil foram fatores importantes que contribuíram para a destruição quase que completa das Florestas com Araucária. Todavia, conforme SANQUETA e TETTO (2000), não foram à extração da madeira a principal causa da devastação iniciada no final do século XIX, e intensificada a partir de meados do século XX, mas sim, o desmatamento para finalidades agrícolas e pecuárias o motivo mais forte da redução da cobertura florestal nos estados do sul do Brasil.

Nos últimos dez anos, tem ocorrido uma crescente disponibilidade de imagens digitais, aéreas e orbitais, sobretudo de alta resolução espacial inferior a um metro. A acentuada definição espacial, nas áreas florestais dessas imagens, permite observar a parte superior das árvores em detalhes, incluindo suas copas, galhos, partes sombreadas entre os galhos, sombras periféricas entre as copas, etc. Com tais imagens, segundo Gougeon (1999), deve-se pensar em árvores individuais ao invés de talhão florestal, sendo factível o traçado ou delineamento das respectivas copas.

Diversas técnicas digitais foram desenvolvidas visando delinear automaticamente as copas de árvores (GOUGEON, 1995, BRANDTBERG, 1997, etc) e seus resultados, em

algumas delas, foram usadas posteriormente para estimar a cobertura de copas, a densidade de árvores e a composição das espécies de árvores que ocorrem nas áreas consideradas. A maioria desses trabalhos foi conduzida em talhões de coníferas. O formato cônico das copas de muitas coníferas favorece a delimitação automática das copas, visto, que nas imagens de alta resolução, apresentam copas com bordas bem distintas e com um ponto de reflectância máxima, que geralmente é o topo da árvore (“local maximum”).

WARNER et al. (1999) comentaram que as copas de árvores de folhosas são muito menos simples (tipicamente com múltiplos pontos de máxima e com bordas menos distintas) do que as coníferas e por isso são mais difíceis de serem delimitadas automaticamente usando os procedimentos existentes.

Baseando-se nessas considerações, a arquitetura da copa da árvore considerada, sua posição nos estratos superiores da floresta, além de como aparecem nas imagens digitais de alta resolução são aspectos importantes que determinam a possibilidade ou não de delimitação automática de suas copas, via processamento digital, sendo este conduzido por *softwares* ou rotinas computacionais específicas.

A espécie florestal considerada no presente estudo é a *Araucaria angustifolia*, uma das duas coníferas que ocorrem na Floresta Ombrófila Mista (FOM). Quando no estágio adulto, a espécie apresenta uma copa circular e dominante nos estratos da floresta e seu diâmetro da copa pode atingir valor acima de 20 m. Sua copa quando vista de posição aérea é inconfundível visto a presença de galhos radiais e os tufos na suas extremidades. Estudos detalhados do mapeamento de copas de Araucária em imagens digitais de alta resolução foram conduzidos recentemente por VENANCIO (2009) e LISBOA (2009). A intensa exploração da espécie, devido ao alto valor associado a sua madeira, colocou a araucária na lista de espécies ameaçadas de extinção, sendo seu corte proibido pela Resolução CONAMA 278 de 2001 (CONAMA, 2001).

DISPERATI e OLIVEIRA FILHO (2005), utilizando a técnica considerada por Warner et al. (1999), não conseguiram delimitar individualmente as copas de *Araucaria angustifolia* e de *Ocotea* spp apenas pelas suas sombras periféricas em fotografia aérea em escala 1:1.000 escaneada com 300 dpi e resultando tamanho do pixel de aproximadamente 8 cm. O estudo foi conduzido em uma floresta natural de araucária, preservada nos últimos sessenta anos. Os resultados mostrados nas imagens binárias não ratificaram com fidelidade o padrão característica radial das copas de araucária. Em relação às copas de imbuías, não ficou evidenciada uma forma típica de suas copas, porém, em comparação com as copas de

Araucária, a quantidade de sombras internas foi bem menor.

Em se tratando de processamento digital de imagens de alta resolução ocorre a preferência da classificação orientada a objeto em substituição da classificação a pixel. A classificação baseada na metodologia de dados orientados a objeto baseia-se no princípio de analisar não apenas um pixel isoladamente, mas dividir a imagem em pequenos segmentos, considerados objetos na imagem, os quais são extraídos da imagem original por meio de técnicas de segmentação. Tais objetos são posteriormente analisados como unidades, sendo possível levar-se em conta fatores de forma, textura e outras variáveis espaciais que não podem ser consideradas numa análise pixel a pixel (CENTENO, 2002).

Alguns estudos florestais nacionais enfocaram a delimitação de copas de árvores via classificação orientada a objeto em imagens de alta resolução. GOMES et al. (2006) utilizaram segmentação multi-resolução em uma imagem Quickbird-2, resolução espacial de 61 cm, para o mapeamento de duas espécies arbóreas *Sclerolobium puniceum* e *Mabea fistulifera* presentes em uma área de cerrado no estado de São Paulo. Ambas as espécies, usadas para recuperação de áreas degradadas, ocorrem, no local estudado, em áreas de fácil acesso e na maior parte das vezes de forma agrupada e a identificação das espécies na imagem e sua confirmação no campo foram realizadas com relativa facilidade. O resultado da classificação foi comparado com dados de campo, sendo sua acurácia avaliada através do coeficiente Kappa, tendo este último valor final superior a 80%.

DLUGOZ (2005) avaliou a possibilidade de se identificar e discriminar tipologias florestais presentes em um fragmento de Floresta Ombrófila Mista, visando desenvolver uma metodologia para o mapeamento dos remanescentes deste ecossistema de forma rápida, com baixo custo e precisão aceitável. Foi utilizada uma imagem IKONOS 2, testando-se algoritmos de segmentação e classificação orientada a regiões como ferramentas para a descrição do estado atual da floresta. A classificação digital supervisionada apresentou-se eficiente para discriminar a tipologia “Predominância de Araucária”. Para as demais tipologias florestais o classificador *Bhattacharyya* não demonstrou um desempenho adequado, fato que influenciou os baixos valores de acuracidade geral (51,73%) e o índice *kappa* (0,43).

LISBOA (2009) em sua pesquisa analisou a cobertura de copas de *Araucaria angustifolia* num fragmento natural de Floresta Ombrófila Mista, através de fotografias aéreas 70 mm colorida normal em três escalas (1:4.000, 1:2.000 e 1:1.000) e de uma imagem digital de satélite de alta resolução IKONOS-2. Neste trabalho foi utilizado o *software Spring*, e

foram testados pares de limiares (segmentação por crescimento de regiões) para analisar a cobertura florestal. Verificou-se que os polígonos interpretados na imagem IKONOS-2 foram em média 47% maior em área do que nas fotografias aéreas 1:4.000.

DISPERATI et al (2009) verificaram o uso potencial da banda do infravermelho próximo, fusionada com a imagem pancromática, do satélite Quickbird-2 para o mapeamento de copas de araucária em floresta natural. A interpretação visual de fotografias aéreas coloridas em escala 1:2.000 foi comparada com a classificação. Apesar da matriz de confusão apresentar coeficiente *Kappa* de 0,79, a quantificação referente a cobertura das copas de araucária excedeu em 54,2% da fotointerpretação.

O presente trabalho faz o uso da técnica de classificação orientada ao objeto utilizando o algoritmo *K Nearest Neighbor* para a classificação supervisionada, e baseada em regras utilizando a lógica *fuzzy* para mapear a espécie *Araucaria angustifolia* num fragmento de Floresta Ombrofila Mista (FOM).

Com o desenvolvimento desta pesquisa pretende-se contribuir no planejamento e manejo e monitoramento de florestas protegidas, utilizando técnicas de sensoriamento remoto, e surge como hipótese deste trabalho a possibilidade de identificação das copas de *Araucaria angustifolia* através da classificação orientada ao objeto utilizando imagens digitais de alta resolução Quickbird-2.

2. OBJETIVOS

Este presente trabalho tem como objetivo identificar as copas da espécie *Araucaria angustifolia* em um fragmento da FOM através da classificação orientada ao objeto utilizando imagem Quickbird-2.

2.1 Objetivos Específicos

- a) Realizar testes de fusão HSV, Gram-Schmidt, Principais Componentes e *Brovey*, para melhoria da qualidade visual e espectral da imagem Quickbird-2;
- b) Testar o uso de um segmentador para definir/delimitar a espécie *Araucaria angustifolia*;
- c) Comparar técnicas de classificação (supervisionada e por regras), para o mapeamento de copas de *Araucaria angustifolia*;
- d) Elaborar o mapa de copas de *Araucaria angustifolia* para a área de estudos.

3. REFERENCIAL TEÓRICO

3.1 Floresta Ombrófila Mista

Floresta Ombrófila Mista é um ecossistema florestal típico da região sul do Brasil, tendo como principal característica a presença da espécie conífera *Araucaria angustifolia*, esta tipologia florestal também é conhecida empiricamente como Floresta com Araucária, Mata dos pinhais. O termo Floresta Ombrófila Mista foi inicialmente utilizado por VELOSO e GOÉS FILHO (1982) e adotado pelo IBGE (1992) na classificação fisionômico-ecológica da vegetação brasileira.

Segundo RODERJAN *et al.* (2002), a FOM é uma unidade fitoecológica onde contempla-se a coexistência de representantes das floras tropical (afro-brasileira) e temperada (austro-brasileira), em marcada relevância fisionômica de elementos Coniferales e Laurales, onde domina *Araucaria angustifolia* (Bertol.) Kuntze (Araucariaceae), espécie gregária de alto valor econômico e paisagístico. Compreende as formações florestais típicas e exclusivas dos planaltos da região Sul do Brasil, com disjunções na região Sudeste e em países vizinhos (Paraguai e Argentina). Encontra-se predominantemente entre as altitudes de 800 e 1200 m, podendo eventualmente ocorrer acima desses limites.

Segundo CARVALHO (1994), a floresta com araucária ocorre da latitude 19°15'S (Conselheiro Pena - MG, no alto rio Doce) a 31°30`S (Canguçu - RS). Com referência à longitude, estende-se desde 41°30`W até 54°30`L. Ocorre principalmente no Brasil e em pequenas manchas na Argentina (extremo nordeste, na província de Misiones) e no Paraguai (leste, no Departamento de Alto Paraná). No Brasil a área original foi de cerca de 200.000 km², de formato irregular, ocorrendo principalmente nos Estados do Paraná (40% de sua superfície), Santa Catarina (31 %) e Rio Grande do Sul (25%) e com manchas esparsas no sul de São Paulo (3%), internando-se até o sul de Minas Gerais e Rio de Janeiro em áreas de altitude elevadas (1 %).

Para FÄHSER (1981)¹, citado por LAMPRECHT (1990), as coníferas presentes nas florestas em clímax apresentam melhores chances na competição do que pioneiras heliófilas, sendo que a *Araucaria angustifolia* possui a característica dominante de umbrela plana, característico do estrato superior desta tipologia florestal e, nos estratos inferiores

¹ FÄHSER, L., Die Bewirtschaftung der letzten Brasil-Kiefer-Naturwälder, eine entwicklungs-politische Augabe. 1981.

desenvolvem-se povoamentos mistos de 50 a 60 espécies de folhosas, dentre elas mirtáceas e lauráceas. Já para CARVALHO (1994), a floresta conhecida como “mata-de-araucária” ou “pinheiral”, ocorre em associação da espécie *Araucaria angustifolia* principalmente os gêneros *Ilex*, *Ocotea* e *Podocarpus*, componentes do estrato logo abaixo das copas dos pinheiros (segundo estrato).

Para SANQUETTA (2005) a floresta de araucária não abriga apenas a sua espécie típica, mas muitas outras que formam comunidades interativas e diferenciadas em florística, estrutura e organização ecológica. Existe muita riqueza na floresta de araucária, seja nos seus componentes arbóreos, no sub-dossel ou nas copas que formam dosséis irregulares. Ali a biodiversidade atinge níveis elevados, apesar de sua aparente simplicidade estrutural.

MAACK (1968) considerou como espécies importantes da Floresta Ombrófila Mista, a imbuia (*Ocotea porosa*) e a erva-mate (*Ilex paraguariensis*). Além destas, esse autor destacou as diversas espécies que se associam regularmente à Araucária, como: as canelas (dos gêneros *Nectandra* e *Ocotea*), as leguminosas (dos gêneros *Dalbergia* e *Machaerium*), as meliáceas (principalmente *Cedrela fissilis*), as mirtáceas (como *Campomanesia xanthocarpa*), *Podocarpus lambertii* (podocarpus ou pinheiro-bravo) e *Syagrus romanzoffiana* (jerivá).

Para RODERJAN *et al.* (2002), na Floresta Ombrófila Mista Montana (600 a 1200 m de altitude), a *Araucaria angustifolia* forma um estrato dominante e contínuo acima de 30 metros de altura, podendo ocorrer indivíduos emergentes acima de 40 metros. Diferentes espécies ocorrem associadas, onde são comuns *Ocotea porosa* (Nees & C. Mart.) Barroso, *O. puberula* (Rich.) Nees, *O. pulchella* (Lauraceae), *Capsicodendron dinisii* (Schwacke) Occhioni (Canellaceae), *Gochnatia polymorpha* (Less.) Cabrera (Asteraceae), *Podocarpus lambertii* Klotzsch ex Ichler (Podocarpaceae), *Ilex paraguariensis*, *Cedrela fissilis*, *Campomanesia xanthocarpa* Berg (Myrtaceae), *Matayba elaeagnoides* Radlk. (Sapindaceae), *Sloanea lasiocoma* K. Schum. (Elaeocarpaceae), *Luehea divaricata* Mart. (Tiliaceae), *Mimosa scabrella* Benth. (Mimosaceae), *Dalbergia brasiliensis* Vogel (Fabaceae), *Jacaranda puberula* Cham. E *Tabebuia alba* (Cham.) Sandwith (Bignoniaceae). Nos estratos inferiores são comuns inúmeros representantes de Myrtaceae, notadamente dos gêneros *Myrcia*, *Eugenia*, *Calyptanthus* e *Gomidesia*, acompanhados de Flacourtiaceae (*Casearia* e *Xylosma*), Sapindaceae (*Allophylus* e *Cupania*), Rutaceae, Symplocaceae e Aquifoliaceae. Fetos arbórescentes (*Dicksonia* e *Cyathea*) e gramíneas cespitosas (*Chusquea* e *Merostachys*) são frequentes.

3.4 Fusão de Imagens

A maioria das imagens de sensoriamento remoto possui a vantagem de gerar novas imagens a partir de transformações radiométricas (PONZONI e SHIMABUKURO, 2007). Estas transformações podem realçar informações que não são muito visíveis nas imagens originais ou podem preservar o conteúdo das informações em um número reduzido de bandas transformadas (PONZONI e SHIMABUKURO, 2007). A transformação de dados de sensores remotos é uma maneira de reduzir o volume de dados, através de técnicas estatísticas e operações entre bandas. Muitas vezes o uso de dados espectrais transformados pode ser mais conveniente para uma classificação de imagens do que a utilização dos dados originais (MOREIRA, 2001).

3.4.1 Modelos Algébricos

Técnicas que empregam modelos algébricos operam funções aritméticas pixel a pixel, como por exemplo, a técnica *Brovey* (PINHO et al. 2005).

3.4.1.1 Brovey

O método “*Color Normalized (Brovey)*” é uma técnica de fusão que usa uma combinação matemática de imagens coloridas e dados de alta resolução. Cada banda da imagem colorida é multiplicada pela razão da imagem pancromática dividida pela soma das bandas da imagem colorida. A função automaticamente reamostra as três bandas coloridas para um tamanho de pixel de alta resolução utilizando técnicas de vizinho mais próximo, bilinear ou convolução cúbica. As imagens de saída RGB terão o tamanho do pixel da imagem de alta resolução (RSI, 2009).

3.4.2 Modelos de Domínio Espectral

As técnicas de domínio espectral utilizam transformações nos dados, gerando um novo conjunto de bandas, sendo que uma delas é altamente correlacionada com a imagem pancromática. Exemplos dessas técnicas são Componentes Principais, IHS, HSV, Gram-Schmidt (PINHO et al. 2005).

3.4.2.1 HSV

HSV é a sigla para: *hue*, *saturation* e *value*, que significam, respectivamente, matiz, saturação e brilho. É um espaço de cor mais uniforme que o espaço RGB e que separa a cromaticidade da luminância. Matiz é a cor pura dominante percebida pelo observador. Saturação é o quanto a cor pura dominante (matiz) é diluída pela luz branca. Brilho (ou valor) é a quantidade de luz refletida (claro/escuro), ou a quantidade de luz branca na cor (NUÑEZ, 2006).

A transformação RGB-HSV separa a informação acromática (valor) e cromática (matiz e saturação) de uma imagem RGB (SCHNEIDER et al. 2003). No método de fusão pela transformada HSV, três bandas espectrais de baixa resolução espacial são transformadas do espaço RGB de cores para o espaço HSV. A componente V é substituída pela imagem PAN, e é efetuada a operação inversa, retornando para o espaço RGB (SCHNEIDER et al. 2003).

3.4.2.2 Principais Componentes (PC)

A Análise por Componentes Principais (ACP), também chamada de transformação por Componentes Principais ou transformada de Karhunen-Loeve, é uma das funções de processamento de imagens mais poderosas na manipulação de dados multiespectrais. A principal tarefa da ACP é analisar as correlações entre N imagens brutas e produzir um novo conjunto de N novas imagens com nenhuma correlação entre si. A primeira Componente Principal (PC) irá conter a informação que é comum a todas as N bandas originais. A segunda irá conter a feição espectral mais significativa do conjunto e assim sucessivamente. As últimas PCs irão conter menos informações do que as suas predecessoras, o que não significa que essa informação seja qualitativamente menos importante, mas apenas que em termos quantitativos o conteúdo em informação decresce para as últimas CPs. A 1ª PC é uma imagem muito semelhante a uma vista “pancromática” da cena (CROSTA, 1992).

No processo de fusão por esse método, uma transformação de componentes principais é executada nos dados multiespectrais. A banda referente à primeira componente principal é substituída pela banda de alta resolução espacial, cuja resolução é reamostrada para ajustar-se à primeira componente principal, de forma a evitar as distorções na informação espectral. Então uma transformação inversa é executada. O dado multiespectral é automaticamente

reamostrado para o tamanho de pixel de alta resolução utilizando técnicas de vizinho mais próximo, bilinear e convolução cúbica (RSI, 2009).

3.4.2.3 Gram – Schmidt (GS)

A transformação *Gram-Schmidt* é baseada em rotações e translações do conjunto original de atributos. Ela é executada através da simulação de uma banda de alta resolução, obtida a partir de um conjunto de baixa resolução. Este procedimento é realizado através da obtenção de um grupo de vetores ortogonais independentes, com variância quadrática das imagens espectrais, obtidos entre duas bandas de baixa resolução, gerando uma banda de alta resolução com o menor desvio padrão da média (OLIVEIRA, 2004). Primeiramente, uma banda pancromática é simulada para a baixa resolução espacial das bandas multiespectrais. Em seguida uma transformação *Gram-Schmidt* é executada nas bandas pancromática e multiespectrais, onde a banda pancromática simulada é empregada como a primeira banda. Na seqüência a primeira banda *Gram-Schmidt* é substituída pela banda pancromática de alta resolução espacial. Finalmente, a transformação inversa *Gram-Schmidt* é aplicada para formar a banda espectral fusionada (*pansharpened*) (RSI, 2009).

3.5 Correção Geométrica

Imagens geradas por sensores remotos sejam elas fotografias aéreas ou imagens de satélite, estão sujeitas a uma série de distorções espaciais, não possuindo, portanto, precisão cartográfica no posicionamento dos objetos, superfícies ou fenômenos nelas representados. As principais fontes de distorções geométricas que ocorrem em imagens de sensores remotos orbitais, citadas por MATHER (1999); LILLESAND e KIEFER (1994), são os erros instrumentais, rotação e curvatura da terra, refração atmosférica, taxa de varredura finita de alguns sensores, instabilidade na plataforma (altitude e velocidade) e distorções panorâmicas referentes à geometria de aquisição.

Para que a precisão cartográfica seja introduzida, faz-se necessário que as imagens sejam corrigidas segundo um sistema de coordenadas, de modo que ela assuma as propriedades de escala e projeção de um mapa (CRÓSTA, 1992). A Correção Geométrica ou Georreferenciamento de uma imagem compreende uma transformação geométrica que relacionam coordenadas de imagem (linha, coluna) com coordenadas de um sistema de

referência (SPRING, 1998), feitos em algoritmos específicos que reorganizam os pixels da imagem em relação a determinado sistema de projeção cartográfica (NOVO, 1992).

A relação entre dois sistemas de coordenadas (mapa e imagem) pode ser calculada através do conhecimento exato dos parâmetros geométricos da órbita do satélite (modelo de geometria orbital) ou através da definição de pontos de controle (PC's) no terreno, que necessitam ser reconhecíveis tanto no mapa como na imagem. A transformação relativa ao modelo de geometria orbital apresenta baixo grau de precisão, sendo o erro médio estimado para esse método na ordem de 2% (CRÓSTA, 1992). A transformação por pontos de controle utiliza informações geográficas adquiridas em mapas planimétricos, plani-altimétricos, vetores ou ainda informações coletadas com a técnica do Global Positioning System (GPS). Os valores dos pontos de controle são, então, submetidos a uma análise de regressão para determinar os coeficientes de duas equações de transformação de coordenadas que podem ser usadas para inter-relacionar as coordenadas geometricamente corrigidas (mapa) e as coordenadas da imagem (LILLESAND e KIEFER, 1994).

Como as coordenadas medidas nos pontos de controle estão sujeitas a erros, convém usar um número de pontos maior que o mínimo. Nesse caso, trabalha-se com um sistema de equações sobre-determinado, que possui mais equações que incógnitas e permite tratar e distribuir os erros de medição dos pontos de controle. A distribuição dos pontos de controle na área a ser registrada também é importante, pois as transformações polinomiais tendem a se comportar adequadamente apenas na região onde se encontram os pontos de controle (SPRING, 1998).

Conforme ENVI (2009), avaliação da acurácia do georreferenciamento é visualizada pelo valor do erro médio quadrático (RMS), que é uma medida do desvio dos valores calculados em relação aos valores originais. O erro RMS é estimado tomando-se uma amostra dos valores calculados e comparando-a com seus valores reais, sendo dado pela equação:

$$RMS = \sqrt{(X_1 - X_{orig})^2 + (Y_1 - Y_{orig})^2}$$

em que:

X_1 – Coordenada de linha calculada na imagem não-registrada

Y_1 – Coordenada de coluna calculada na imagem não-registrada

X_{orig} : Coordenada original de linha do GCP (*Ground control points*) na imagem

Y_{orig} : Coordenada original de coluna do GCP na imagem

O processo de correção por pontos de controle resulta na produção de uma nova imagem, onde seus pixels não correspondem espacialmente aos pixels da imagem original (CRÓSTA, 1992). As células vazias devem ser preenchidas com o nível de cinza do(s) pixel(s) correspondente(s) da imagem original (LILLESAND e KIEFER, 1994). Para determinar o valor dos pixels no grid corrigido, utiliza-se a reamostragem pelo método de interpolação de valores de níveis de cinza (DN's). CRÓSTA (1992) comenta serem três os métodos mais comuns de interpolação, a saber:

a) Vizinho mais próximo (*nearest-neighbor*) – usa o valor do pixel mais próximo para atribuir o valor do pixel de saída;

b) Interpolação bilinear (*bilinear interpolation*) – toma por base os níveis de cinza dos quatro vizinhos mais próximos ao centro do novo pixel, calculando a média ponderada das distâncias dos centros dos quatro vizinhos;

c) Convolução cúbica (*cubic convolution*) – o valor do novo pixel baseia-se no ajuste por polinomial de terceiro grau, utilizando o valor médio dos 16 pixels vizinhos mais próximos.

Segundo CRÓSTA (1992), CAMPBELL (1996) e MATHER (1999), o método do vizinho mais próximo é um método simples que proporciona rápido processamento e que preserva o número digital original da imagem. A escolha do método de reamostragem depende do objetivo para o qual será usada a imagem. No caso de imagens que serão classificadas automaticamente, não são desejáveis alterações nos valores dos níveis de cinza.

Muitas vezes a análise comparativa de imagens multitemporais ou a combinação entre imagens de diferentes sensores sobre uma mesma área, ou ainda a justaposição de imagens se faz necessária; nesse caso é preciso assegurar que os pixels das imagens a serem trabalhadas sejam referentes à mesma área no terreno. Para tanto se realiza a operação de registro, onde, ao invés de se registrar as coordenadas em pixel/linha de uma imagem às coordenadas geográficas, registra-se coordenadas do tipo pixel/linha entre si, utilizando o algoritmo “imagem para imagem”, disponível nos software de processamento de imagens. As etapas seguintes são realizadas da mesma forma que para o georreferenciamento (CRÓSTA, 1992).

3.5.1 Ortorectificação

Para corrigir todas as distorções geométricas das imagens de alta resolução é necessário o uso de um modelo ou função matemática (Toutin, 2004), seja através de modelos

empíricos 2D/3D (como os polinomiais 2D/3D ou funções racionais 3D) ou de modelos físicos e determinísticos 2D/3D.

Segundo CHENG et al. (2003), dentre os diversos métodos tridimensionais de correção geométrica, três deles podem ser utilizados em imagens Quickbird: o racional polinomial com os parâmetros matemáticos introduzidos pelo usuário, o racional polinomial com parâmetros fornecidos pelos metadados da imagem e o rigoroso. O primeiro, realizado por TOUTIN e CHENG (2002), computa os *Rational Polynomial Coefficients* ou *Rapid Positioning Coordinates* (RPC) usando pontos de controle terrestres (*Ground Control Points - GCP*) adquiridos pelo usuário. O segundo método, desenvolvido pela empresa *DigitalGlobe* (DigitalGlobe, 2004), usa um modelo empírico e estatístico que aproxima o modelo físico do sensor. Este método, que foi utilizado ocasionalmente durante a década de oitenta, ganhou atenção redobrada a partir do funcionamento do satélite Ikonos (CHENG et al., 2003). Estudos como o de GRODECKI (2003), demonstram como este método funciona e quais são suas características e possibilidades. Este método permite a ortorretificação com ou sem GCP e de maneira direta. O terceiro método é considerado o mais tradicional de todos, sendo aplicado desde a década de sessenta. Ele modela matematicamente todos os componentes físicos da geometria da visada (satélite, sensor e terreno).

3.5.2 GCP e GPS em Modo Diferencial

Todos os trabalhos que procuram bons resultados para a produção de ortoimagens utilizam pontos de controle terrestres para auxiliar neste processo. CHMIEL et al. (2004), indicam a grande influência de dados auxiliares como GCP e Modelo Digital de Terreno (MDT) no processo de correção geométrica e seus resultados.

Os GCP devem ser feições bem definidas, geralmente de grande contraste espectral em relação aos seus arredores na imagem, facilmente reconhecíveis e que podem ser precisamente localizados tanto no mapa quanto na imagem (Crósta, 1999). Segundo PEDRO (2005), tais feições podem ser encontradas em interseções de retas, linhas suficientemente longas ou centros de gravidade de feições circulares. Estes pontos devem ser bem distribuídos na imagem, sendo dispostos nas bordas e no centro da área de interesse. Devem também, preferencialmente, cobrir toda a variação altimétrica do terreno, desde as cotas mais baixas até as mais altas (TOUTIN, 2004).

TOUTIN (2004) fornece uma revisão de todo o procedimento de correção geométrica

de imagens Quickbird. Dentre os assuntos abordados, dá atenção especial a etapa de coleta de pontos de controle e teste. Seus resultados concordam com aqueles encontrados por WOLNIEWICZ (2004) e JACOBSEN (2003), quanto à necessidade de poucos pontos de controle para a geração das ortoimagens. Cerca de seis a nove pontos são necessários (para o modelo rigoroso) dependendo dos dados disponíveis, da qualidade dos GCP e do tamanho da área estudada.

Para saber com maior exatidão o número necessário de pontos a serem coletados deve-se conhecer a área, as imagens, o receptor de GPS a ser utilizado e a precisão pretendida. Se estas informações não forem reunidas *a priori*, cerca de 50% dos pontos podem ser inutilizados e caso tenham sido analisados este valor cai para cerca de 20-30% (TOUTIN, 2004).

A limitação geométrica das imagens ortorretificadas depende muito frequentemente da qualidade dos pontos de controle adquiridos para uma determinada imagem (WOLNIEWICZ, 2004), sendo estes pontos responsáveis pela propagação de erros e pelo erro final do processo de correção (TOUTIN, 2004).

Estes fatores indicam a necessidade de se realizar uma boa coleta de coordenadas (geográficas ou UTM), para serem usadas como pontos de controle e teste. MONICO (2000) descreve a necessidade de planejamento, reconhecimento e manutenção dos equipamentos em estudos práticos com o uso de GPS. O uso do GPS em modo diferencial (*Differential Global Positioning System - DGPS*) tem sido utilizado como base para a coleta de coordenadas em estudos que demandam alta precisão de resultados, como o estudo de CHENG et al. (2003). O DGPS é uma técnica que não só melhora a exatidão, mas também a integridade do GPS (MONICO, 2000). No método DGPS se a localização de um receptor for conhecida, podem-se comparar os valores obtidos com os valores teóricos e deste modo calcular os erros para corrigir as medições naquele ponto. Estes erros poderão ser usados também na correção das medições dos outros receptores que estão em pontos desconhecidos (BERNARDI et al, 2002).

3.6 Segmentação

Os processos de segmentação simulam o comportamento do fotointérprete ao reconhecer áreas homogêneas na imagem, baseando-se em suas propriedades espectrais e espaciais (SPRING, 1998).

Segundo VENTURIERI e SANTOS (1998), o processo de segmentação consiste em

agrupar *pixels* com características similares em termos tonais e textura, formando regiões homogêneas. Desta forma, a imagem é particionada em um conjunto de regiões correspondentes às feições da superfície terrestre, que irão servir de base para a análise e cartografia temática.

Para COUTINHO (1997), a definição de valores para os limiares na segmentação de imagens depende, principalmente, do conhecimento dos padrões de repartição espacial dos objetos de cada área e da definição da generalização cartográfica ideal, em função da escala cartográfica da abordagem realizada. Contempla uma etapa que exige maior atenção devido à inexistência de valores padronizados para as variáveis do algoritmo e, também, pode influenciar diretamente na acurácia dos resultados da segmentação. ANTUNES (2003) comenta que não existe um modelo formal para a segmentação, sendo este processo essencialmente empírico e, em geral ajustável aos diferentes tipos de imagens, com limiares definidos face à complexidade dos alvos investigados.

Geralmente, a segmentação é o primeiro passo em análise de imagens, passo este que pode determinar o eventual sucesso ou fracasso de uma análise. Consiste em uma operação que subdivide uma imagem em suas partes ou objetos constituintes devendo cessar quando os objetos de interesse na aplicação tiverem sido isolados (GONZALES e WOODS, 2000).

A segmentação consiste na simplificação da imagem de modo à particioná-la em um conjunto finito de áreas homogêneas, com o objetivo de extrair informações úteis através da agregação de objetos por classes. A segmentação precede a classificação, sendo, portanto, uma fase crítica, onde a obtenção de resultados satisfatórios depende basicamente da eficiência do algoritmo utilizado. Erros nessa fase podem influenciar as etapas de classificação que se seguem, interferindo na interpretação. Não existem algoritmos de segmentação apropriados a todos os tipos de imagem, sendo necessária a adaptação a tipos particulares de aplicação, tornando a escolha do método de segmentação extremamente importante para a escolha de um algoritmo eficiente (SPINDOLA, 2005).

O limiar de similaridade é o limiar mínimo, ou seja, define a diferença mínima entre o valor de um pixel e o valor médio da região contígua a ele, para que este pixel possa ser agrupado a essa região. Se a diferença entre o valor do pixel e a média da região vizinha for maior que o valor de similaridade definida pelo usuário, o pixel não irá pertencer àquela região. O segundo limiar, de área, significa o menor valor de área (em pixel) para que uma região seja separada de outra (BARBOSA *et al.*, 2000).

A segmentação em geral baseia-se nas características de descontinuidade e de

similaridade dos tons de cinza de uma imagem. O método que avalia a descontinuidade baseia-se na mudança abrupta de valores de cinza e o método por similaridade fundamenta-se na agregação de *pixels* em função da sua semelhança com os *pixels* vizinhos (GONZALES e WINTZ, 1987).

De acordo com MOIGNE e TILTON (1995), na segmentação os *pixels* da imagem são agrupados em compartimentos em consonância com propriedades, tais como níveis de cinza, contraste, valores espectrais ou textura, a qual incorpora atributos espaciais e de contexto.

3.7 Lógica Fuzzy

A melhora na resolução espacial de uma imagem demanda uma análise que considere o conhecimento do intérprete humano de forma a refletir melhor a subjetividade na informação (ANTUNES, 2003).

Desta forma, a lógica fuzzy parece ser mais adequada quando se pretende representar o conhecimento no processo de classificação digital. O conceito de conjuntos difusos, nebulosos ou fuzzy, proposto por ZADEH (1965), é uma generalização do conceito da teoria clássica dos conjuntos. De acordo com BURROUGH & McDONELL (1998) o conjunto fuzzy refere-se a conceitos inexatos para uma metodologia de caracterização de classes, que por várias razões não se tem ou não se pode definir limites rígidos (bordas) entre classes. A utilização de um conjunto fuzzy é em geral aplicada sempre que se tiver que lidar com ambigüidade, abstração e ambivalência em modelos matemáticos.

Seja X um espaço de objetos (*pixels* ou segmentos) e x um elemento qualquer de X . Um conjunto clássico A , $A \subseteq X$, é definido como uma coleção de elementos ou objetos $x \in X$. Nesta relação, cada x pode pertencer ou não ao conjunto. É possível definir uma função que caracterize o grau de pertinência de cada elemento x em X . Pode-se representar o conjunto A por um conjunto de pares ordenados $(x, 0)$ ou $(x, 1)$, os quais indicam se $x \in A$ ou $x \notin A$, denominado Booleano.

O conjunto fuzzy expressa o grau para o qual um elemento pertence a um conjunto utilizando uma função de pertinência. Então, esta função característica de um conjunto fuzzy apresenta valores variáveis entre 0 e 1, os quais denotam o grau de pertinência de um elemento em um dado conjunto (ZADEH, 1965; LEE & ZHU, 1995; METTERNICHT, 1999;

VICENTE et al. 1999; AZEVEDO et. al 2000). Se X é uma coleção de objetos de x elementos, então um conjunto fuzzy A em X , é um conjunto de pares ordenados, tal que:

$$X = \{x\} \quad (1)$$

$$A = \{x, f_A(x)\}; x \in X \quad (2)$$

Onde:

A = Conjunto Fuzzy;

X = Espaço dos Objetos;

$f_A(x)$ = Função de Pertinência.

Nas expressões (1) e (2) o conjunto fuzzy A em X é caracterizado por uma função de pertinência $f_A(x)$ que associa cada ponto em X a um número real no intervalo [0, 1]. O valor de $f_A(x)$ representa o grau de pertinência de x em A. Desta forma, pontos podem pertencer a um conjunto fuzzy num grau maior ou menor (WANG,1990a; AZEVEDO et al, 2000).

Um conjunto fuzzy é unicamente especificado por sua função de pertinência. Expressa por $f_A(x)$, definido o grau de pertinência de x em A. A cardinalidade do conjunto fuzzy para o espaço dos objetos X discreto é expressa por:

$$|A| = \sum_{x \in X} f_A(x),$$

e no caso de X contínuo por: $|A| = \int f_A(x) \quad (3)$

O core do conjunto A é dado pelo conjunto de pontos x em X tal que $f_A(x)=1$ ou

$$\text{Core}(A) = \{x | f_A(x) = 1\} \quad (4)$$

Os pontos de cruzamento ou *crossover* é dado por $f_A(x)=0,5$ ou

$$\text{Cross}(A) = \{x | f_A(x) = 0,5\}; \quad (5)$$

Amplitude ou suporte da função de pontos x em X é dado por $f_A(x)>0$,

$$\text{Suporte}(A) = \{x | f_A(x) > 0\} \quad (6)$$

A função de pertinência $f_A(x)$ pode ser delineada de acordo com os parâmetros de cardinalidade, *crossover* e suporte -expressões (3),(5) e (6). No caso de processamento digital de imagens, a aplicação da representação fuzzy se refere a classes que podem ser definidas como conjunto fuzzy e os pixels como elementos. Um pixel pode pertencer a uma determinada classe com um grau de pertinência (Figura 1), e uma outra classe com outro grau de pertinência.

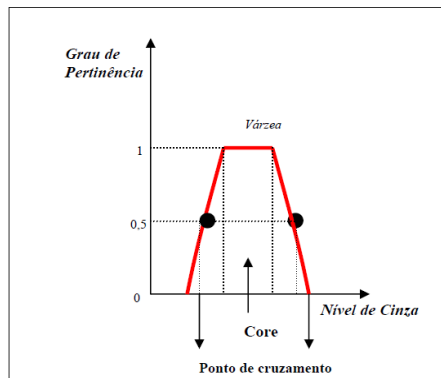


Figura 1: Função de pertinência de um conjunto *fuzzy*.
 Fonte: ANTUNES, 2003.

Seja z o valor do atributo ex.: várzea (classe) de acordo com o gráfico da Figura 1 tem-se:

$$fa(z) = 1 \text{ se } a \leq z \leq b;$$

$$fa(z) = 0 \text{ se } z < a \text{ ou } z > b.$$

Os valores a e b definem os limites do conjunto A . Dependendo do valor do nível de cinza do eixo x da função, tem-se para z um valor variável em 0 e 1, no eixo y . Em geral é comum que o core da função seja ampliado de um valor para um intervalo $(d_1; d_2)$ como o observado na Figura 1. Assim, a zona de pertinência é ampliada. Observa-se a sobreposição da função de pertinência e pertinência abrupta (Booleana). A Figura 2 mostra as discrepâncias entre as duas funções, onde uma observação dentro da zona Booleana (em cinza) pode não estar dentro do core da função fuzzy, em amarelo. Percebe-se que os limites da função Booleana possuem um grau de pertinência $fa(z) = 0,5$, logo uma observação dentro da função abrupta seria associada a uma classe, enquanto na função de pertinência $fa(z)$ existirá apenas um grau de possibilidade (0,5) de pertencer à classe várzea (ZADEH, 1965; LEE & ZHU, 1995; METTERNICHT, 1999; VICENTE et al. 1999; AZEVEDO et. al 2000).




Figura 2: Função de pertinência *fuzzy* e função abrupta.
 Fonte: ANTUNES, 2003.

Um importante passo na análise fuzzy é a determinação da função de pertinência. BURROUGH & McDONNELL (1998) denominam de importação semântica a determinação de funções de pertinência baseadas no bom conhecimento do usuário em relação ao comportamento do dado. A função de pertinência deve assegurar o grau de pertinência 1, no centro do conjunto e este valor decresce até zero para o limite externo do conjunto. Há vários tipos de distribuição de probabilidade (ex.: normal, lognormal, retangular, hiperbólica, Poisson, etc.), logo é possível obter diferentes tipos de funções de pertinência.

Uma das funções de pertinência mais comuns é a função Sigmoidal (Figura 3), dada pela expressão:

$$f_A(z) = 1 / (1 + a(z - c)^2) \text{ para } 0 \leq z \leq P, (7);$$

Onde:

A o conjunto fuzzy;

a o parâmetro determinante da forma da função,

c define o valor da propriedade **z** (inflexão).




Figura 3: Função de pertinência sigmoideal.

Fonte: ANTUNES, 2003.

BURROUGH & McDONNELL (1998) e METTERNICHT (1999) salientam que a determinação dos parâmetros da função de pertinência depende do conhecimento geográfico em questão. As funções de pertinência são utilizadas para representar o quão difuso são os limites geográficos. O tamanho da zona de transição ($d_1; d_2$) e as formas da função podem ser definidas através de um conhecimento do espaço espectral fuzzy.

Tal como na teoria dos conjuntos Booleanos, os conjuntos fuzzy podem ser combinados. Seja um conjunto fuzzy **B** contido num conjunto **A**, a função de pertinência de **B**

será sempre menor que a função de pertinência em A, para qualquer elemento x no universo X. A função de pertinência de um conjunto C resultante da união de dois conjuntos A e B, é dada pelo o maior valor de pertinência, aos conjuntos A e B de cada elemento x :

$$C = A \cup B$$

$$f_c(x) = f_a(x) \cup f_b(x) = \text{Max}\{f_a(x), f_b(x)\}; x \in X \quad (8)$$

A função de pertinência C resultante da intersecção dos conjuntos A e B, é dada pelo menor valor de pertinência aos dois conjuntos:

$$C = A \cap B$$

$$f_c(x) = f_a(x) \cap f_b(x) = \text{Min}\{f_a(x), f_b(x)\}; x \in X \quad (9)$$

Com vistas à classificação, os principais operadores quando se manipula um ou mais conjuntos fuzzy são a de união (maximização), intersecção (minimização) e negação complemento $f_c(x) = 1 - f_c(x)$ (BURROUGH & McDONNELL, 1998; AZEVEDO et al. 2001). BENZ (1999) e BAATZ & SCHÄPE (2001) salientam a importância da teoria fuzzy na análise da classificação de feições espectralmente próximas entre si. O resultado da análise fuzzy é uma relevante fonte de informação que pode, junto com outras fontes de dados, permitir uma melhora significativa no processo de classificação digital. A tendência atual é que a classificação de imagens de alta resolução seja cada vez mais amparada nesta lógica. Segundo BINAGHI et al. (1997) a estrutura fuzzy é o principal meio de integrar o conhecimento na classificação de objetos principalmente quando diferentes fontes de informação são associadas.

3.8 Classificação Orientada ao Objeto

Entre as principais aplicações das imagens de SR, destacam-se a análise e o mapeamento temático do uso e cobertura da Terra (LILLESAND E KIEFER, 2000). Os *pixels* que compõem uma imagem representam os diferentes alvos terrestres que possuem comportamento específico ao longo do espectro eletromagnético.

A classificação digital de imagens representa o agrupamento e rotulação de *pixels* com características similares. Normalmente, a tomada de decisão sobre quais *pixels* devem ser

rotulados e agrupados é realizada por métodos estatísticos (SCHOWENGERDT, 1997; LILLESAND e KIEFER, 2000). A classificação de imagens pode ser realizada “*pixel a pixel*” ou através de “regiões”.

Nessas duas formas, há três métodos para classificação de imagens (LILLESAND e KIEFER, 2000). Um método é a classificação não-supervisionada, quando o usuário não possui conhecimento prévio das classes temáticas presentes na imagem, deixando que o algoritmo as defina; outra é a supervisionada onde o usuário orienta a busca das classes temáticas através da aquisição de amostras; e a híbrida, onde utiliza em conjunto, as duas abordagens citadas anteriormente. Outro método híbrido é a classificação da imagem por um determinado algoritmo e, posteriormente, o usuário realiza as correções de possíveis erros que ocorrem durante a classificação através da edição de polígonos (MOREIRA, 2001).

A segmentação é um processo realizado antes da classificação, com o objetivo de dividir a imagem em regiões homogêneas, para solucionar problemas de subjetividade em classificações supervisionadas. O processo consiste em separar os atributos espectrais da imagem em regiões homogêneas, isto é, os *pixels* com características similares (forma, textura, área, parâmetros espectrais) são associados (MOREIRA, 2001).

A análise estatística de cada *pixel* individual, de uma imagem com alta resolução espacial, não é o método mais adequado para representar a paisagem, bem como os fenômenos ecológicos. Outros parâmetros devem ser considerados na extração de informações, como: textura, distância, localização e conceitos de vizinhança. Nesse sentido, a classificação por regiões e a segmentação da imagem são soluções importantes no processo de classificação (BLASCHKE e STROBL, 2001; HOFFMANN e VEGT, 2001).

Para BLASCHKE e STROBL (2001) os novos sistemas sensores orbitais, como o IKONOS-II e o QUICKBIRD, exigiram novos métodos para a extração de informações das respectivas imagens. HOFFMANN e VEGT (2001) sugerem a classificação orientada ao objeto como uma solução para classificar imagens com alta resolução.

Ao contrário dos métodos tradicionais para a classificação digital de imagens, na classificação orientada ao objeto, a análise é realizada sobre objetos ou segmentos na imagem e não apenas sobre *pixels*. Na imagem um objeto representa uma entidade que pode ser individualizada, tem atributos próprios e as mesmas propriedades da classe que lhe deu origem (DEFINIENS, 2002). Entre os motivos para se adotar a classificação de imagem orientada ao objeto podem ser citados (GONÇALVES *et al.*, 2001):

- o processamento de imagens aproxima-se mais dos processos cognitivos humanos que as

análises baseadas em *pixel*;

- é mais fácil incorporar informação de contexto com significado numa abordagem orientada ao objeto do que numa abordagem apenas ao nível do *pixel*.

A detecção das feições florestais é essencial para a elaboração de um bom trabalho. Deve-se investigar se as feições de interesse podem ser discriminadas na imagem digital e quais são as características que permitem sua separação das demais, se as técnicas de extração de informações são eficientes e apropriadas, se é possível usar o método de mapeamento de forma sistemática, se a técnica escolhida deve substituir os métodos tradicionais e quais são as possibilidades de uso de dados auxiliares neste processo (DONNAY et al., 2001).

Assim sendo, de acordo com os objetivos do estudo e os dados e recursos disponíveis, é possível delimitar os alvos a serem mapeados bem como suas características. Este tipo de análise inicial irá determinar, por exemplo, se será mapeada a cobertura ou o uso da terra. BARNESLEY et al. (2001) consideram que enquanto o tipo de cobertura da terra tem uma relação simples e direta com a captação da reflectância espectral o mesmo não acontece com o uso da terra que é um conceito abstrato e possui um conjunto de fatores culturais e econômicos que não podem ser diretamente extraídos por meio do sensoriamento remoto. Indicam que este é um problema central para estudos urbanos já que o uso da terra é de grande interesse para os planejadores. Por isso investigam a possibilidade de inferir o uso da terra a partir do reconhecimento de padrões espaciais e estruturais obtidos pelo mapeamento de sua cobertura.

A classificação baseada em funções *fuzzy* transforma os valores de atributos de um intervalo arbitrário para um intervalo padronizado entre zero e um, indicando a pertinência de um objeto a uma classe específica. Desta maneira, cada objeto pode ter uma pertinência *fuzzy* a mais de uma classe, expressa pelo seu grau de adequabilidade para cada classe (BLASCHKE et al., 2000). A maior vantagem desta abordagem é a expressão de incerteza na pertinência e conhecimento (BOCK et al., 2005).

O ganho do uso da lógica *fuzzy* é a avaliação do grau de pertinência. Este método reúne todas as incertezas trazidas durante a definição das classes dos objetos e dos erros das coletas das amostras de treinamento além daqueles erros inerentes aos sensores e aos sistemas de classificação propriamente ditos (BENZ, 1999).

Técnicas de classificação orientadas a objetos permitem ao usuário definir regras complexas baseadas em características espectrais e em relações espaciais herdadas. Objetos podem ser definidos e classificados pela estrutura e comportamento de objetos similares

(BLASCHKE et al., 2000). As regras desenvolvidas por meio das funções *fuzzy* possibilitam estas associações além de prover adequabilidade à descrição do atributo.

4. MATERIAIS E MÉTODOS

4.1 Localização

A Floresta Nacional de Irati é uma unidade de conservação do Instituto Chico Mendes, com características excepcionais para a realização de estudos ecológicos do ecossistema Floresta Ombrófila Mista (FOM). Esta FLONA está situada no segundo planalto paranaense, no âmbito dos municípios de Fernandes Pinheiro e Teixeira Soares, integrantes da microrregião Colonial de Irati. A Flona está localizada entre a margem direita do rio das Antas e esquerda do rio Imbituvão, pertencentes à bacia hidrográfica do rio Tibagi, a uma altitude média de 820 metros acima do nível do mar, com relevo suave ondulado (MAZZA *et al.*, 2005).

Segundo DISPERATI e OLIVEIRA FILHO (2006), a FLONA de Irati, situa-se a aproximadamente 150 km oeste de Curitiba - PR. Criada em 1942, com área de 3.495 hectares, a FLONA tem 36% (1.272,9 hectares) de floresta nativa com predominância de araucária e com o sub-bosque rico em espécies folhosas como canelas, imbuias, angico, entre outras. Trata-se de uma área protegida por mais de 60 anos, sem similar na região. A figura 4 mostra a localização da FLONA no contexto Paranaense e da micro região de Irati – PR

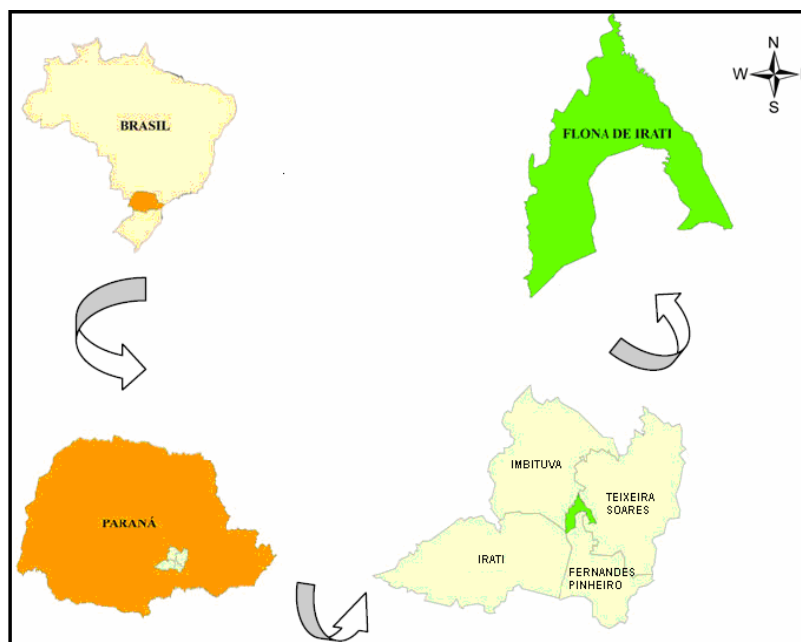


Figura 4: Mapa de localização da FLONA de Irati.

Fonte: Mazza, 2006.

4.2 Clima

Conforme classificação de Köppen, o clima da região pertence ao tipo Cfb, subtropical úmido mesotérmico, caracterizado por verões frescos, geadas severas e freqüentes, sem estação seca (MAZZA 2006).

O caráter subtropical do clima dessa área é evidente pela redução de seus valores térmicos. Por esse motivo é dominada pelos ventos de NE, que quando é orientada pelas feições topográficas da bacia do Rio Ribeira contígua à do Rio Tibagi, favorece a atuação das massas de ar Tropical Atlântica e Polar Atlântica. Fato este que no decorrer do ano, manifesto pelas oscilações da frente Polar Atlântica, é o maior responsável pelas chuvas que nela ocorrem (MENDONÇA e DANNI-OLINEIRA 2002).

4.3 Solos

Segundo MAZZA *et al.* (2005), a FLONA de Irati apresenta 37,8% de Latossolo Vermelho Distrófico típico-álico, localizando-se na porção interna esquerda, no sentido Norte - Sul. A associação do Latossolo Vermelho Distrófico típico-álico com o Nitossolo Háptico Distrófico típico-álico, de textura argilosa representa 26,62% da área, e está localizado no limite esquerdo, sentido Norte - Sul, margeando o Rio das Antas. Ocupando 25,42% da área, a associação Cambissolo Háptico Distrófico típico-álico com Gleissolo indiscriminado localiza-se na várzea do Rio Imbituva, em praticamente todo o limite direito.

A associação Argissolo Vermelho-Amarelo Distrófico típico + Cambissolo Háptico Distrófico típico + Latossolo Vermelho Distrófico típico representa 9,59% da área e localiza-se na porção sudeste da FLONA, seguida de mais uma mancha a leste. As demais classes são pouco representativas, totalizando 0,57% da área da FLONA: associação Argissolo Vermelho-Amarelo Distrófico típico + Latossolo Bruno Distrófico típico (0,39%), associação Cambissolo Háptico Distrófico típico, álico + Alissolo Crômico Húmico típico (0,10%) e Argissolo Vermelho Amarelo Distrófico Câmbico, álico (0,08%). Essas características podem ser observadas na Figura 5.

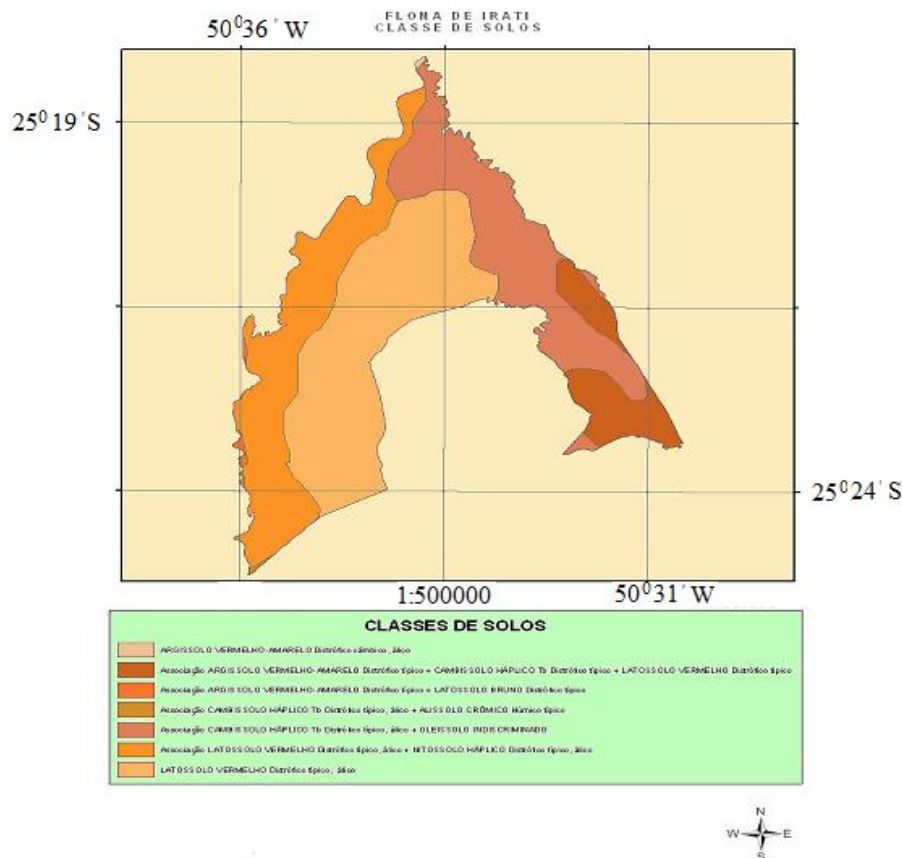


Figura 5: Mapa das classes de solos na FLONA de Irati - PR.
Fonte: Mazza *et al* (2005).

4.4 Vegetação

A composição florística da Flona é formada pela floresta nativa com araucárias (36,55%), Floresta pluvial subtropical (6,73%), Capoeira (5,27%) e a área de várzea (9,23%). Na área de reflorestamento da Flona, a composição é *Araucaria angustifolia* (2,39%), *Pinus* sp (22,32%), *Acácia* sp (1,34%), outras espécies (1,69%), a área não florestal é de (4,78%).

GALVÃO *et al.* (1989) encontraram, na Floresta Nacional de Irati, as seguintes comunidades arbóreas associadas à *Araucaria angustifolia*, diferindo entre si pela fisionomia ou ocorrência localizada de determinadas espécies:

- a) Caracterizada pelo monjoleiro (*Acacia poliphylla*) e canela-imbuia (*Nectandra megapotamica*), acompanhados do xaxim-com-espinho (*Alsophila* sp. e *Nephelea* sp.);
- b) Caracterizada pela araucária (*Araucaria angustifolia*) e maria-preta (*Diatenopteryx sorbifolia*), com sub-bosque bastante desenvolvido;

- c) Caracterizada pela araucária, canela-branca (*Nectandra lanceolata*), pimenteira (*Capsicodendron dinisii*), pessegueiro-bravo (*Prunus brasiliensis*) e podocarpus (*Podocarpus lambertii*);
- d) Caracterizada pela araucária, canela-branca, erva-mate (*Ilex paraguariensis*), miguel-pintado (*Matayba elaeagnoides*) e cambuí (*Siphoneugenia* sp.);
- e) Caracterizada pelo xaxim-com-espinho e canela-branca.

4.5 Área de pesquisa

Em 2002, 25 parcelas permanentes de 1 ha cada (100 m x 100 m) foram instaladas e medidas por professores do Departamento de Engenharia Florestal da UNICENTRO, na área com Floresta Ombrófila Mista (1272,9 ha) da Floresta Nacional de Irati, com a finalidade principal de estudar a dinâmica desse importante ecossistema florestal do sul do país (STEPKA 2008).

As parcelas permanentes (Figura 6) foram divididas em quatro sub parcelas de 0,25 ha (50 m x 50 m) e finalmente para facilitar a numeração e o mapeamento das árvores (X, Y), foram ainda subdivididas em cinco faixas de controle de 10 m x 50 m (0,05 ha).




Figura 6: Área das parcelas permanentes.

4.6 Dados de sensoriamento remoto

Este estudo foi desenvolvido com imagem de satélite Quickbird-2 (Tabela 1), e fotografias aéreas na escala 1:25.000 e 1:2.000.

Tabela 1: Especificações da Imagem Quickbird.

Data	Banda Pan	Multiespectrais	Visada lateral
08-03-2008	61 cm (445-900 nm)	Banda 1 (B)-2,4 m (450-520 nm) Banda 2 (G)-2,4 m (520-600 nm) Banda 3 (R)-2,4 m (630-690 nm) Banda 4 (NIR)-2,4 m (760–900 nm)	14,6° <i>off-nadir</i> sendo: -1° <i>across track</i> ; -14,7° <i>in track</i> .

As fotografias aéreas na escala 1:2.000 são de 70 mm colorido normal não-métricas, ampliadas (21 x 28 cm) para a escala 1:2.000, resultantes de uma linha de vôo de recobrimento fotográfico com 15 fotografias, em escala original 1:10.000, realizado na FLONA de Irati. As fotografias foram digitalizadas através de scanner de mesa HP Scanjet 3570-c, com resolução de 300 dpi, resultando num tamanho de pixel de 17 cm. Cada fotografia aérea digital continha 3 bandas, assim caracterizadas: banda 3 no canal R (*Red*), banda 2 no canal G (*Green*) e banda 1 no canal B (*Blue*). Nenhum procedimento de normalização radiométrica foi efetuada nas 8 fotografias aéreas utilizadas.

As fotografias aéreas em escala 1:25.000 referente ao recobrimento aerofotográfico realizado no estado do Paraná em 1980, com superposição longitudinal de 60% e distância focal nominal de 152 mm, foram utilizadas para elaboração do DTM.

4.7 Dados Cartográficos

Foi utilizado um arquivo em DXF referentes à restituição aerofotogramétrica (perfilamento e rede de drenagem). O perfilamento foi realizado em linhas paralelas com equidistância de 10 m e coletando a altimetria a cada 10 m em cada linha abrangendo uma área de 1326 ha.

4.8 Softwares e Aplicativos

Para o desenvolvimento deste presente estudo foram utilizados os seguintes *softwares* e aplicativos:

- a) *ENVI 4.6.1*: Utilizado nos testes de fusão de imagens, elaboração do DTM e pós classificação da imagem.
- b) *Módulo FX (Feature extraction)*: Utilizado na classificação orientada ao objeto.

- c) *ArcGis 9.3*: Utilizado na análise dos segmentos gerados pela classificação.
- d) *Topcon tools*: Utilizado para pós processamento dos pontos de GPS *Leica 900CS*.

4.9 Equipamentos

Foi utilizado um par de aparelhos DGPS modelo 900CS *Leica* para coleta dos dados de campo e um GPS Garmin para auxílio na localização dos indivíduos de *Araucaria angustifolia*.



(a)



(b)

Figura 7: Aparelho DGPS *Leica* (a) e GPS de caminhada Garmin (b), utilizados no trabalho de campo.

4.10 Metodologia

Os procedimentos metodológicos usados neste trabalho foram realizados para otimizar o tempo e entender o uso do material e das técnicas disponíveis conforme fluxograma apresentado na Figura 8.

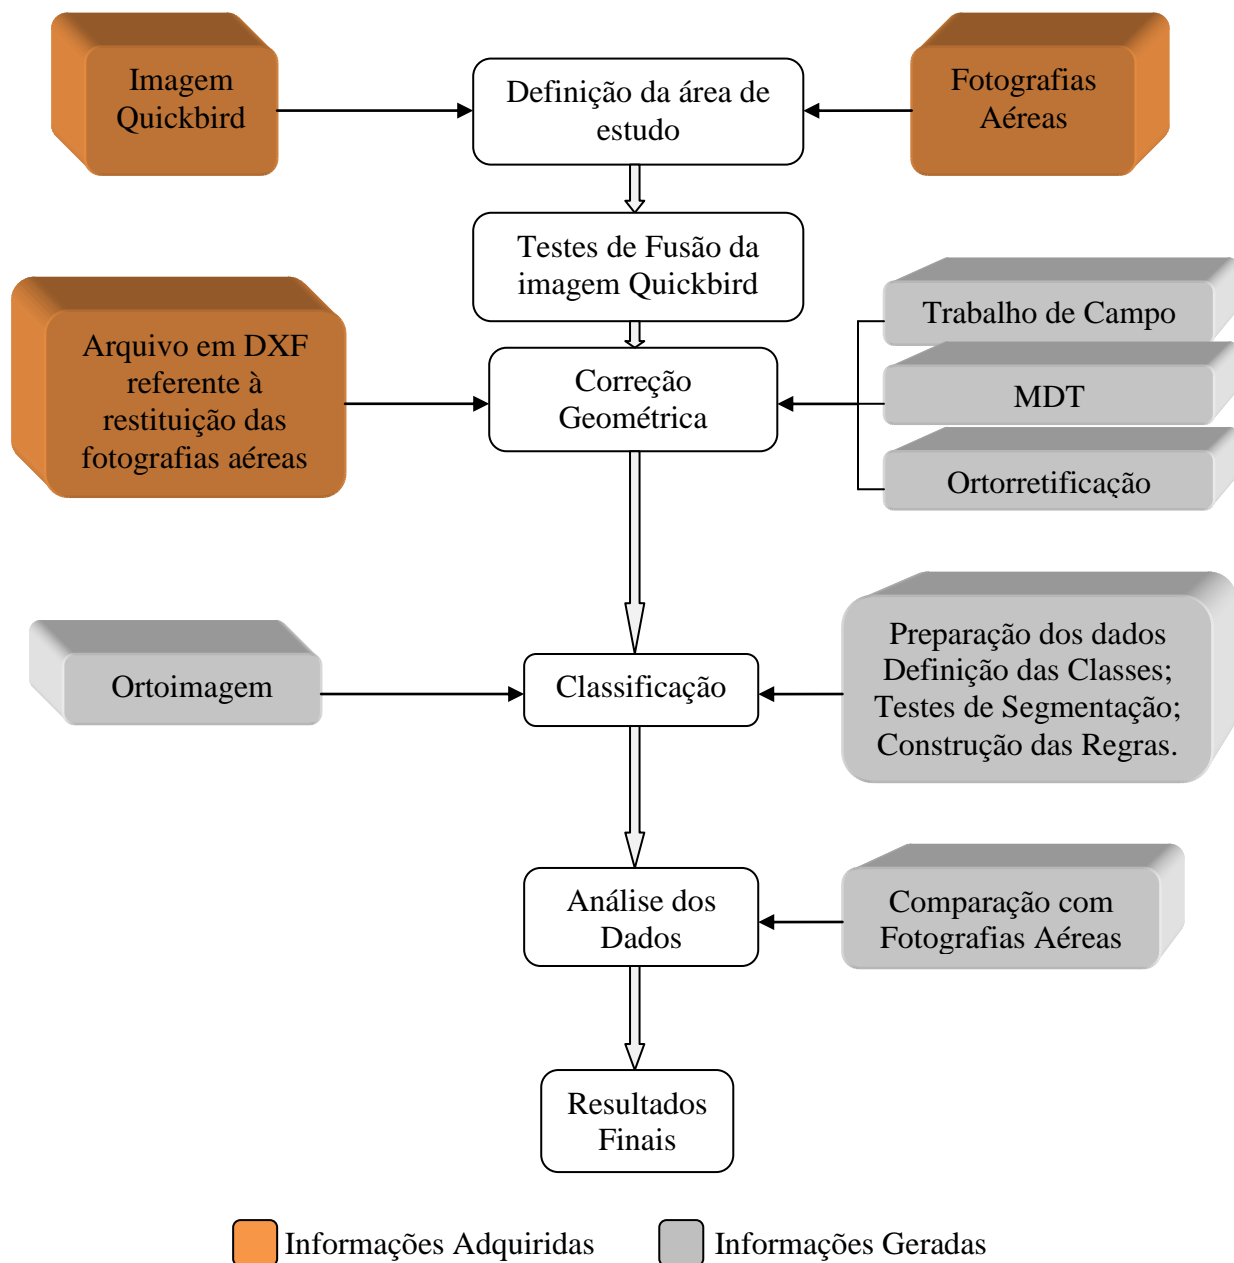


Figura 8: Fluxograma referente às etapas realizadas neste presente trabalho.

4.10.1 Definição da Área de Estudo

Em função da alta resolução espacial da imagem Quickbird II, optou-se pelo estudo de uma área pequena com 111 ha referentes à área a ser classificada. Também levou-se em consideração a localização do experimento de 25 hectares localizado sobre esta área. Vale ressaltar que foi realizado o trabalho de campo nos 10 primeiros hectares do experimento

servindo como verdade terrestre. A Figura 9 a seguir mostra um recorte da imagem Quickbird II com o experimento de 25 ha e a área recortada utilizada para efetuar os testes de classificação.

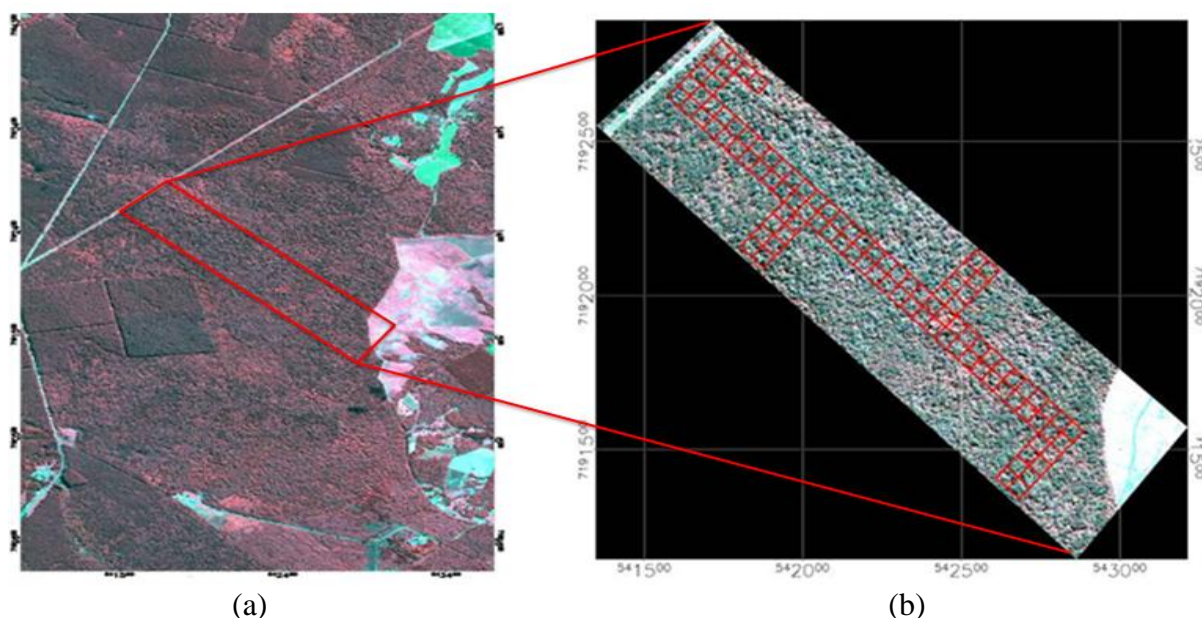


Figura 9: Imagem Quickbird (a), e composição falsa cor da imagem Quickbird (Bandas R4,G3 e B2), referente a área de estudo, com experimento de 25 ha (b).

4.10.2 Fusão de imagens

As bandas multiespectrais e a pancromática da imagem Quickbird II foram fusionadas com o objetivo de melhorar a resolução espacial das imagens. Para esse estudo foram testadas quatro técnicas de fusão disponíveis no *software* ENVI 4.6.1[®]: HSV (três bandas), *Color Normalized (Brovey)* (três bandas), *Gram-Schmidt Spectral Sharpening* (quatro bandas) e *Principais Componentes* (quatro bandas). As bandas selecionadas para participarem da fusão foram as bandas 1, 2 e 3, para as fusões com 3 bandas e incluído a banda 4 (infravermelho próximo) nas fusões com 4 bandas.

Para analisar o resultado das fusões foram realizados dois testes, sendo o primeiro uma análise visual entre os resultados das diversas técnicas de fusões utilizadas e a imagem multiespectral original. No segundo teste foi verificada a fidelidade espectral das imagens fusionadas com relação à imagem multiespectral original. Como as imagens fusionadas possuem resoluções espaciais diferentes em relação à imagem original, não foi possível compará-las diretamente. Sendo assim, a imagem Quickbird (pancromática e multiespectral)

tiveram de ser degradadas, de tal forma que as imagens fusionadas tivessem a mesma resolução espacial da imagem multiespectral original. A fusão entre as imagens degradadas é considerada uma fusão simulada somente para efeito de avaliação. No presente estudo, a imagem pancromática original foi degradada para resolução de 2,4 metros e a multiespectral original para 9,6 m. A fusão entre essas duas imagens gerou uma nova imagem fusionada com resolução de 2,4 m. Para a comparação das imagens foram utilizadas a média, desvio padrão e correlação entre bandas. Para efeito de comparação entre as bandas da imagem original e das fusionadas, os histogramas de cada imagem foram plotados para melhor visualização.

4.10.3 Trabalho de campo

Duas atividades diferentes de trabalho de campo foram efetuadas a saber:

- a) Apoio de pontos de controle planialtimétricos para dar suporte a correção geométrica da imagem e DTM da área;
- b) Mapeamento das copas de Araucária em 10 ha do experimento.

Para coleta dos pontos de controle necessários tanto para a restituição das fotografias aéreas e para a correção da imagem Quickbird-2, foi imprescindível a obtenção de pontos de controle com precisão compatível com a imagem de satélite disponibilizada pela empresa. Desta forma, coletaram-se 28 pontos com GPS em modo diferencial estático abrangendo toda a área de estudo. O roteiro do trabalho de campo e a localização dos pontos foram previamente planejados de forma a garantir a sua boa distribuição.

Os primeiros dias de campo serviram para os contatos pessoais necessários e o reconhecimento dos locais pretendidos para a obtenção dos pontos. Nos pontos amostrados, além das medidas das coordenadas (Figura 10), anotou-se uma série de informações adicionais de grande relevância para a caracterização do ponto como cruzamentos de estradas, pontes, divisa de reflorestamentos etc.



Figura 10: Coleta de um ponto de controle com GPS.

A permanência em cada ponto dependia da distância do aparelho móvel em relação ao aparelho base localizado na entrada da FLONA de Irati, e das condições de recepção do GPS. Em média, para distâncias variando de um a seis quilômetros, o tempo necessário foi de cerca de vinte minutos por ponto incluindo: traslado, montagem e desmontagem de equipamento e recepção. Vale ressaltar que não foram coletados pontos de controle com distâncias maiores que seis quilômetros do aparelho de base.

As coordenadas coletadas no campo foram importadas no aplicativo *Topcon Tools 7.1*[®], onde foi criado um projeto no qual se fez a distinção entre coordenadas da base fixa e coordenadas do móvel. Para efetuar a correção dos pontos foram utilizados dados das bases de Curitiba e Guarapuava. Para todos os pontos processados foi encontrada solução fixa L1/L2 para todos os pontos com acurácia de 68,7% (INCRA), e precisão média de 0,0099 e 0,022 metros para a planimetria e altimetria respectivamente, e PDOP médio de 3,27. Não foi necessário corrigir as altitudes, pois o aplicativo já calculou a altitude ortométrica (altitude elipsoidal – ondulação geoidal), com referência na baía de Imbituba - SC.

Também no trabalho de campo, foi efetuado um levantamento com base no banco de dados do inventário florestal efetuado no ano de 2008, nas parcelas permanentes (25 ha). Nesse levantamento foram visualizadas as copas de *Araucaria angustifolia* referente à sua situação, como copas isoladas, em agrupamentos e de difícil visualização numa área de 10 ha do experimento (bloco 1 ao 10). As copas de difícil visualização representam os indivíduos que ocorrem nos extratos inferiores da floresta não podendo ser visualizados no mosaico de fotografias aéreas e na imagem de satélite Quickbird, portanto não foram consideradas neste

estudo. A Figura 11 a seguir mostra o delineamento visual com base no trabalho de campo nos 10 ha do experimento. O delineamento das copas servirá como verdade terrestre para cálculo da exatidão/acurácia da classificação.




Figura 11: Levantamento de campo, referente à situação das copas.

4.10.4 Correção Geométrica

A imagem Quickbird adquirida encontrava-se previamente corrigida geometricamente. Para aumentar a precisão, a imagem passou por um processo de refinamento do georreferenciamento. A imagem Quickbird II fusionada (0,6 m) foi georreferenciada a partir de pontos de controle coletados em campo com DGPS ($L1$, $L2$).

Foram utilizados 10 pontos de controle bem distribuídos na imagem. A equação de transformação utilizada foi o “polinômio do 2º grau” e o método de reamostragem foi o interpolador “vizinho mais próximo”. Neste caso, poucos pontos de controle são necessários para refinar o processo. Uma equação do 2º grau deve ter no mínimo 6 pontos de controle para ser ajustada, no entanto, como as coordenadas medidas dos pontos de controle estão sujeitas a erros recomenda-se usar número maior que 6 pontos. Aconselha-se o uso de 6 pontos de controle para o polinômio de 1º grau, 10 pontos de controle para o polinômio de 2º grau e 14 pontos para o polinômio de 3º grau (SPRING, 2010). O método de interpolação por vizinho mais próximo foi escolhido por ser o que mais preserva o valor original do número digital (DN), uma vez que não envolve nenhuma média.

4.10.4.1 Modelo Digital do Terreno

Para a construção do Modelo Digital de Terreno (MDT), necessário para a ortorretificação, utilizaram-se pontos cotados sobre o terreno disponibilizados pelo técnico Romilton de Lima Pedrosa. Estes pontos georreferenciados em UTM SAD/69 zona 22 S, e em formato do aplicativo MAXICAD, foram geradas a partir de duas fotografias aéreas obtidas em 1980 na escala 1:25000 com superposição longitudinal de 60% e distância focal nominal de 152 mm, com restituição para a escala 1:5000. A perfilação foi feita em linhas coletando pontos a cada 10 m nos eixos X e Y variado somente as altitudes.

O MDT foi gerado usando a rotina (*Envi MDT*), disponibilizada pela SULSOFT. A resolução do produto gerado nesta etapa foi à mesma das imagens a serem ortorretificadas, ou seja, 0,6m. Este cuidado foi tomado porque segundo SILVA E VERGARA (2005) e ARAÚJO (2006), em regiões com grande inclinação do relevo, a distância entre dois pontos do MDT adequa-se melhor à realidade do terreno do que se forem utilizadas distâncias maiores. Além disso, como o modelo gerado em formato matricial possui coordenadas planimétricas e altimétricas (nível de cinza) e tem a mesma resolução da imagem Quickbird a ser corrigida, não há perda de informação por degradação da resolução espacial ao se fazer a reamostragem do MDT no processo da ortorretificação.

4.10.4.2 Ortorretificação

Com todos os dados planialtimétricos disponíveis realizou-se a ortorretificação da imagem Quickbird. Como dados de entrada foi utilizado o modelo RPC (*Rational Polynomial Coefficients*), e o MDT gerado a partir da restituição das fotografias aéreas.

No processo de correção geométrica, optou-se pela ortorretificação da imagem fusionada (bandas multi espectrais com a pancromática), mas neste caso ao selecionar a imagem é preciso indicar os metadados contendo as informações de RPC, que se perdem ao fazer a fusão (ARAÚJO, 2006). O arquivo indicado deve ser aquele que contém as informações da banda PAN, pois a sua geometria se mantém depois de fusionadas as bandas.

Seguindo a ordem proposta, foi gerada a correção geométrica com o MDT (baseado no perfilamento) sem pontos de controle. Escolheu-se esta opção pelo fato de que o MDT é mais refinado do que usar somente o modelo RPC da imagem.

A avaliação da ortorretificação gerada foi feita com base nos pontos de controle

coletados em campo com DGPS. Desta maneira foram plotados oito pontos teste bem distribuídos na imagem para efetuar o cálculo do RMS (*Erro médio quadrático*).

Este teste foi realizado manualmente embora o projeto montado no aplicativo fornecesse um relatório dos erros. Esta opção foi feita usando uma melhor compreensão do procedimento utilizado.

4.10.5 Classificação Orientada a Objetos

Completada a operação de correção geométrica das imagens, definiram-se as classes de cobertura do solo através do reconhecimento visual da área. Após esta etapa realizou-se a classificação da cobertura do solo utilizando a abordagem orientada a objetos e sua respectiva avaliação. Esta etapa envolveu os seguintes procedimentos como mostra a Figura 12 a seguir.

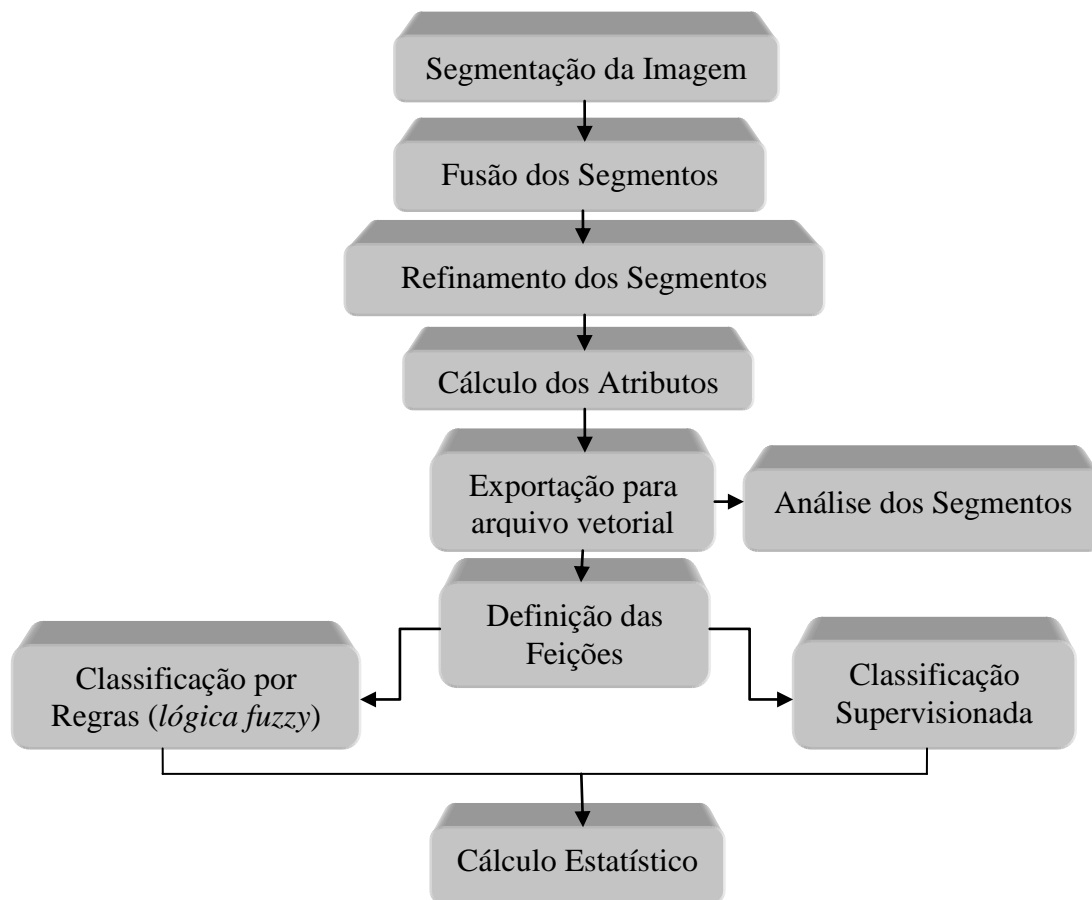


Figura 12: Etapas para realização da classificação da imagem.

4.10.5.1 Preparação dos Dados e Definição das Classes.

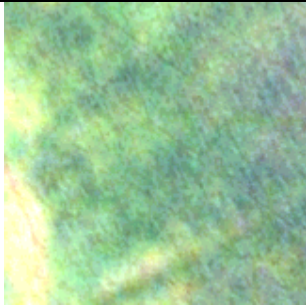



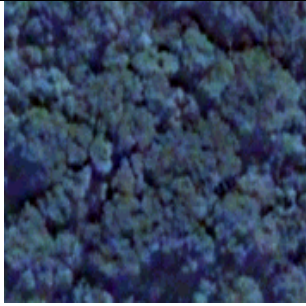

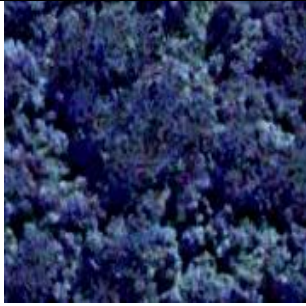
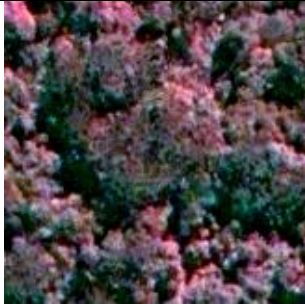
Como o objetivo da etapa de classificação foi identificar alvos que compõem a paisagem florestal, foi importante considerar outro parâmetro que pudesse auxiliar nessa tarefa. Nesse sentido, optou-se pelo uso de um mosaico de fotografias aéreas não controlado em escala 1:2000 (Figura 13), para auxiliar na identificação das classes e também servir como base (verdade terrestre) na comparação com a imagem classificada.



Figura 13: Mosaico de fotografias aéreas 1:2000 utilizado como base para identificação das classes.

Para aperfeiçoar a classificação da cobertura do solo, além de considerar o objetivo do trabalho necessitar-se de um bom conhecimento do local estudado e dos dados a serem utilizados. Neste trabalho, as classes foram definidas a partir da interpretação visual da imagem de satélite e das fotografias aéreas (Figura 13), com o suporte das observações de campo. As classes definidas são mostradas na Tabela 2.

Tabela 2: Classes selecionadas para o estudo.

Classes	Composição 3, 2, 1 (RGB)	Composição 4, 3, 2 (RGB)
Agricultura		
<i>Araucaria angustifolia</i>		
Folhosas		
Sombra		

O primeiro propósito da chave de interpretação é a identificação de alvos da superfície terrestre de forma mais precisa e objetiva. Desta forma, o uso de chaves de interpretação através de procedimentos sistematizados visa obter o mesmo resultado com diferentes

intérpretes, ou com o mesmo fotointérprete, mas em ocasiões diferentes, utilizando o mesmo produto de sensoriamento remoto.

Um dos tipos de chaves de interpretação mais utilizados é o que apresenta uma descrição dos objetos conforme sua aparência e ocorrência no terreno, seguido de uma descrição de como são percebidos através das fotografias aéreas.

As chaves de interpretação variam conforme o produto de sensoriamento remoto utilizado, uma vez que, em função da resolução espacial, espectral e radiométrica do sistema sensor utilizado, diferentes fatores guia são gerados para auxiliar o fotointérprete. As características mais importantes na interpretação voltada ao uso da terra através de imagens orbitais são: forma, tamanho, sombra, tonalidade/cor, padrão, textura, localização e relação de aspectos (PEREIRA et al, 1989).

Neste trabalho, os elementos de fotointerpretação utilizados para compor a chave de interpretação, a fim de caracterizar os diferentes usos analisados nas imagens foram cor e textura que são brevemente explicados a seguir:

Cor: A cor é uma propriedade que os materiais possuem de refletir raios de luz de um comprimento de onda particularmente dominante. Croma, saturação e brilho são as três variáveis que a constituem. As imagens fotográficas de cor verdadeira frequentemente facilitam a interpretação, pois fornecem ao fotointérprete uma visão mais completa do objeto em estudo.

Textura: Entende-se por textura o padrão de arranjo dos elementos tonais e que representa a imagem do conjunto, dada pela disposição das menores feições que conservam sua identidade na escala da imagem fotográfica. O elemento textural é a menor superfície contínua e homogênea, distinguível na imagem fotográfica.

4.10.5.2 Segmentação

Segmentação é o processo de particionamento de uma imagem em segmentos, agrupando os pixels vizinhos com valores de características similares (brilho, cor, textura, etc). Estes segmentos idealmente correspondem aos objetos do mundo real. Escolhendo-se um nível de escala alto (próximo de 100), resulta a menor quantidade de segmentos definidos, e a escolha de um nível de escala baixo (próximo de 0), faz com que mais segmentos sejam gerados.

O processo de segmentação é o primeiro passo para a classificação e é a partir dele que os objetos, alvos deste tipo de abordagem, são criados. O resultado desta fase repercute nas demais. Por isso foram feitos vários testes (Tabela 3) até se obter uma segmentação multi escala que atendessem aos interesses da classificação. Para o primeiro nível da segmentação utiliza o algoritmo “*edge based segmentation*” que requer somente a manipulação de um parâmetro de escala. Este algoritmo liga os pixels adjacentes se eles têm as mesmas propriedades onde:

- (a) A magnitude similar: $|kri(x, y) - kri(x_0, y_0)| < T$ para algum limiar de diferença de magnitude T.
- (b) Semelhante orientação $|(RI(x, y) - RI(x_0, y_0))| < A$ para um limite angular A.

A quantidade de segmentos gerados depende da manipulação do parâmetro de escala e do uso opcional, da função “merging segments” (segundo nível), neste caso usa o algoritmo “*Full Lambda-Schedule*” (ROBINSON, REDDING AND CRISP; 2002). Este algoritmo mistura interativamente combinando os segmentos adjacentes com base na combinação espacial e espectral. O algoritmo considera um par de regiões, I e J, de tal forma que a fusão dos segmentos u_i, u_j , é inferior ao valor padrão λ parâmetro limiar.

Onde:

$$t_{i,j} = \frac{\frac{|O_i| \cdot |O_j|}{|O_i| + |O_j|} \cdot \|u_i - u_j\|^2}{length(\partial(O_i, O_j))}$$

O_i = A região i-ésima da imagem;

O_j = A região j-ésima da imagem;

$|O_i|$ = A área da região i-ésima da imagem;

$|O_j|$ = A área da região j-ésima da imagem;

u_i = Valor médio da região i-ésima;

u_j = Valor médio da região j-ésima;

$\|u_i - u_j\|^2$ = Distância euclidiana entre os valores espectrais da região i-ésima e j-ésima;

$length(\partial(O_i, O_j))$ = É o comprimento da borda em comum O_i, O_j .

Após a análise visual da imagem Quickbird-2, levando em consideração o formato das copas de Araucária optou-se por adotar o segundo nível de escala (*merging segments*) para corrigir os erros (*over-segmentation*) da primeira etapa, devido ao fato de que as copas de *Araucaria angustifolia* estavam divididas em mais de um segmento, melhorando assim a definição do limite das copas.

Para este presente trabalho foram testados vários níveis de escala para o primeiro nível de escala e um valor fixo para o segundo nível. Atribuindo um nível alto de escala (próximo de 100), há geração de poucos segmentos e atribuindo um nível baixo (próximo de 0), ocorre a geração de muitos segmentos. A Tabela 3 mostra resumidamente as escalas testadas.

Tabela 3: Escalas de segmentação testadas para a imagem Quickbird-2.

Primeiro Nível (escala)	Segundo Nível (escala)
70	90
75	90
80	90
85	90

4.10.5.3 Construção das regras

Após a etapa de segmentação da imagem, foram computados todos os atributos dos objetos e depois foram exportados para o *software* ArcGis 9.3[®].

A seleção dos atributos utilizados para diferenciar cada classe foi feita, inicialmente, visualizando-se o comportamento dos objetos (segmentos) em relação a um determinado atributo, que foram espacializados na imagem Quickbird. Na imagem exportada, como visto anteriormente, continha todas as regras disponíveis no aplicativo com seus respectivos valores referente aos atributos espaciais, espectrais, textura e razão de bandas, servindo como base para a classificação. A Figura 14 a seguir mostra um recorte da imagem mostrando os valores de intensidade dos objetos variando de zero (verde) a um (vermelho).

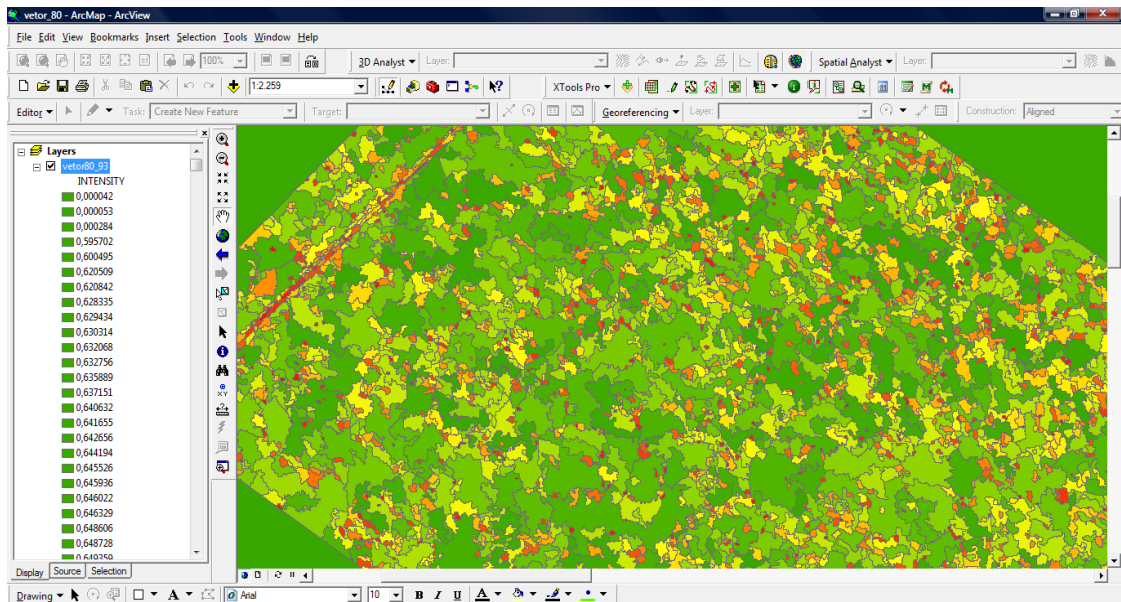


Figura 14: Interface do *ArcView* mostrando os valores de intensidade dos objetos.

Esta espacialização foi feita para diversos atributos espaciais como área, *length*, *formfactor*, *solidity*, espectrais como valores mínimos e máximos de cada banda, e atributos referentes à razão de bandas como intensidade, saturação e NDVI, e desta maneira foi possível identificar quais deles poderiam ser utilizados na separação das classes. No entanto, este procedimento isolado não foi suficiente, porque os limites que definem cada classe não são muito claros. Para isso foram utilizadas uma combinação de regras (mais de uma regra para definir cada classe), diminuindo assim a confusão entre elas.

4.10.5.4 Classificação Supervisionada e por Regras

Para classificar a imagem Quickbird-2, foram testados os dois classificadores implementados no *Envi Zoom*, sendo uma supervisionada (*K Nearest Neighbor*) e a classificação por regras utilizando a lógica *Fuzzy* (*Fuzzy Membership Functions*). O classificador por Vizinho mais Próximo exige a aquisição de amostras para as classes mapeadas. Já no classificador por regras é necessário estabelecer descritores para a discriminação das classes temáticas. Os descritores aplicados foram àqueles baseados em valores espectrais, espaciais e razão de bandas. A seleção dos atributos utilizados para diferenciar cada classe foi feita, inicialmente, visualizando-se o comportamento dos objetos em relação a um determinado atributo que foi espacializado por meio de uma imagem como visto no item 5.5.5.3.

Na classificação supervisionada foram selecionados os segmentos referentes às classes de interesse, que serviram como treinamento do algoritmo. Neste caso também podem ser utilizados atributos espaciais, espectrais, ou propriedades de textura durante a classificação. Como amostras de treinamento foram utilizadas 70 amostras para a classe *Araucaria angustifolia*, 55 para a classe “folhosas”, 15 para a classe “agricultura” e 15 para a classe “sombra”. A escolha destas amostras foi feita com base no mosaico de fotografias aéreas e na própria imagem de satélite utilizada neste presente estudo. Este método é geralmente mais robusto do que um classificador vizinho mais próximo tradicional, uma vez que a distância K mais próxima é usada como um valor majoritário para determinar qual classe pertence o alvo.

Na classificação por regras são computados os atributos da imagem de forma automática. Este método é baseado no conhecimento cognitivo humanos onde são escolhidos os atributos espaciais, espectrais, textura e razão de bandas que poderão ser utilizados em conjunto ou isoladamente para mapear as classes de interesse. Os atributos utilizados para classificar a imagem são descritos na Tabela 4:

Tabela 4: Regras utilizadas para classificar a imagem Quickbird-2.

Classes onde foram utilizadas as regras	Atributo Espacial	Definição
Agricultura	Área	A área total do polígono, menos a área dos furos. Os valores estão em unidades de mapa.
Agricultura	<i>Elongation</i>	Uma medida da forma que indica a razão entre o eixo principal do polígono ao eixo menor do polígono. Os eixos principais e secundárias são derivadas de uma caixa orientada delimitadora que contém o polígono. O valor de alongamento de um quadrado é de 1,0, eo valor de um retângulo é maior que 1,0. ELONGATION = MAXAXISLEN / MINAXISLEN
	Atributo Espectral	Definição
Agricultura	Valor mínimo da banda 1.	Valor mínimo dos pixels que compõem uma região em uma banda X.
	Atributo referente à razão de bandas	Definição
Araucária e Folhosas	<i>Bandratio</i>	Foi atribuída a banda do vermelho para B1 e da banda do infravermelho próximo para B2, o atributo BANDRATIO é uma medida do índice de vegetação por diferença normalizada (NDVI). $(B2 - B1) / (B2 + B1 + eps)$
Sombra	<i>Intensity</i>	Intensidade geralmente fornece uma medida melhor do brilho do que usando o atributo AVGBAND_x espectral. A intensidade é medida em valores de ponto flutuante 0-1,0.

4.10.5.5 Avaliação da Classificação

Para avaliar o resultado da classificação foi gerada uma matriz de confusão da qual se

extrai uma série de informações muito relevantes para avaliar a qualidade deste procedimento. Dentre estas informações, está o índice *Kappa* que foi usado como parâmetro para a avaliação da qualidade do processo de classificação.

A matriz de confusão (CONGALTON et al., 1983; STEHMAN, 1997) apresenta o número de *pixels* classificados corretamente em oposição ao número de *pixels* previstos para cada classe no decorrer da classificação. Esta matriz permite obter informação da precisão global do respectivo classificador, bem como a precisão de classificação de cada classe, através do cálculo do coeficiente Kappa, dado pela seguinte equação:

$$k = \frac{Po - Pe}{1 - Pe}$$

Onde:

Po: Razão entre o somatório da diagonal principal e o número total de pixels que deveriam ser classificados corretamente;

Pe: é expresso pelo somatório do produto dos elementos das linhas e colunas marginais pelo número total de observações ao quadrado.

Este coeficiente indica o grau de concordância entre o resultado da classificação digital e a realidade no campo.

Na avaliação da exatidão da classificação, fez-se primeiramente uma análise visual do resultado comparando-o com a imagem e o mosaico de fotografias aéreas. Como a alta resolução da imagem utilizada permite o reconhecimento de grande parte dos objetos de interesse, a percepção visual foi utilizada para uma interpretação dos resultados de forma qualitativa. Na verdade esta interpretação moldou a construção de todo processo de classificação por meio de comparações entre os resultados preliminares e a visualização da realidade com base no trabalho de campo.

Após a interpretação visual coletaram-se amostras para cada classe. Foram coletadas 110 amostras sendo 50 para a classe “*Araucaria angustifolia*”, 50 para a classe de “Folhosas” e 20 para a classe “Agricultura/solo-exposto”.

Estas amostras foram coletadas usando como base a interpretação visual das fotografias aéreas apoiadas no trabalho de campo, e na própria imagem de satélite. As amostras então foram comparadas com o resultado da classificação, e calculados o índice *Kappa* para todas as classes e outro somente para as classes “*Araucaria angustifolia*” e “Folhosas” que é o objeto principal do presente trabalho e também os erros do usuário e

produtor.

Para este trabalho também foi calculado o índice individual para a classe Araucária por ser de maior relevância como segue:

$$\mu_{pi} = \frac{X_{ii}}{X_{i+} + X_{+i} - X_{ii}}$$

Onde:

μ_{pi} = Índice de acurácia do mapeamento.

X_{ii} = Valor da classe.

Interpretação: $0 \leq \mu_p \leq +1$.

5. RESULTADOS E DISCUSSÃO

5.1 Fusão de Imagens

5.1.2 Avaliação Qualitativa

Em todas as imagens fusionadas neste presente trabalho foi possível ver o ganho em detalhes, como estradas mais visíveis e principalmente a vegetação ficou com melhor definição.

Após a aplicação das técnicas de fusão na imagem Quickbird-2, os resultados mostraram visualmente melhor conservação de cores foram a *Principais Componentes* e *Gram Schmidt*, empregando as 4 bandas multiespectrais (Figura 15b e 15e). Todas as técnicas testadas produziram imagens fusionadas com uma variação de cores bastante significativa em comparação com a imagem original, destacando-se as fusões *HSV* e *Brovey* que apresentaram, nas áreas com vegetação, cores variando do verde brilhante até o azul escuro. Nas técnicas que utilizaram três e quatro bandas verificaram-se uma diferença de tonalidade também para as áreas cobertas com vegetação. Nas fusões com três bandas, a cor da vegetação ficou com tom verde mais brilhante.

Estes dois problemas detectados acima são decorrentes da amplitude espectral da imagem pancromática do sensor *Quickbird* que se estende até o infravermelho próximo, região do espectro onde a vegetação possui resposta muito alta (PINHO et al. 2005). Desta forma processos de fusão que utilizam as imagens do referido sensor devem incorporar a banda 4 (infra-vermelho) para que não apresentem grandes mudanças de cores. O mesmo autor também encontrou que, em relação à conservação de cores, o melhor resultado foi obtido pela técnica de *Principais componentes*.

5.1.3 Avaliação Quantitativa

No segundo teste, foi analisada a fidelidade espectral das imagens fusionadas com relação à multiespectral original. Na Tabela 5 são apresentados os valores de média (nível de cinza), desvio padrão e correlação para a imagem multiespectral e para as técnicas de fusão testadas.

Tabela 5: Comparação entre os parâmetros estatísticos da imagem multiespectral original e da sintética simulada.

Método	Banda 1			Banda 2			Banda 3			Banda 4			Média
	Média	DP	Cor.	Média	DP	Cor.	Média	DP	Cor.	Média	DP	Cor.	
Orig.	19,7	1,9	1	24,1	4,8	1	12,2	5,4	1	56,3	16,6	1	1,00
HSV	111,4	60,7	0,75	72,8	46,8	0,92	90,6	54,2	0,92	x	x	x	0,92
Brovey	13,5	5,6	0,37	8,4	3,7	0,75	10,6	3,8	0,75	x	x	x	0,75
GS	19,7	1,9	0,92	24,2	4,8	0,92	12,3	5,6	0,93	56,1	16,9	0,39	0,93
PC	19,7	2,0	0,95	24,4	5,1	0,95	12,4	5,8	0,95	56,8	14,5	0,55	0,95

Orig. = Imagem Original

HSV = *Hue Saturation Value*

DP = Desvio Padrão

GS = *Gram Schmidt*

Cor. = Correlação linear simples

PC = Principais Componentes


Pode-se observar que a média e o desvio padrão do método HSV se mostraram bem diferentes dos valores da imagem original. A média e o desvio padrão estão relacionados com o brilho e o contraste da imagem, respectivamente (LUZ, 2009). Havendo uma menor variação na média, o brilho é conservado. Uma menor variação entre os valores de desvio padrão demonstra melhor preservação do contraste da imagem (PINHO et al, 2005). Por outro lado, a técnica de fusão HSV teve alta correlação entre as bandas devido à banda pancromática apresentar um intervalo espectral que engloba o intervalo das três bandas multiespectrais de entrada. Segundo (FUCKNER et al, 2007), a fusão pela técnica IHS apresenta bons resultados quanto à representação de cores somente quando a imagem pancromática apresenta um intervalo espectral que engloba o intervalo das três bandas multiespectrais de entrada. Apesar de o sistema de cores HSV não ser o mesmo do IHS, o princípio da técnica de fusão é o mesmo. LUZ (2009), obteve baixa correlação (0,318) testando esta técnica por utilizar a composição falsa cor devido a banda 4 (infravermelho próximo) englobar apenas uma pequena parte da banda pancromática, sendo que neste trabalho esta mesma técnica obteve correlação de 0,92 sendo ligeiramente melhor que o resultado obtido por LUZ (2009).

Na fusão, a técnica *Principais componentes* resultou em uma menor variação entre os valores de desvio padrão, ou seja, preservou melhor o contraste da imagem original. Já a técnica de *Gram Schmidt* forneceu melhores resultados para o valor média indicando uma conservação do brilho da imagem.


A comparação entre os histogramas (imagem original / imagem simulada) também revelou resultados similares aos comentados anteriormente, visto que, o melhor desempenho

foi obtido pelas técnicas *Principais Componentes* e *Gram-Schmidt* (Figura 16), sendo que a primeira apresentou histogramas mais coerentes com a imagem original.


Pode-se analisar na Figuras 16 a seguir o resultado das técnicas de fusão testadas neste presente trabalho.



(a) Imagem Original




(b) HSV



(c) Gram-Schmidt



(d) Brovey



(e) Principais componentes

Figura 15: Comparação entre a imagem multiespectral Original (a) e as técnicas de fusão testadas.

A seguir são apresentados o histograma (Figura 16) de cada imagem para verificar o comportamento de cada técnica de fusão testada.

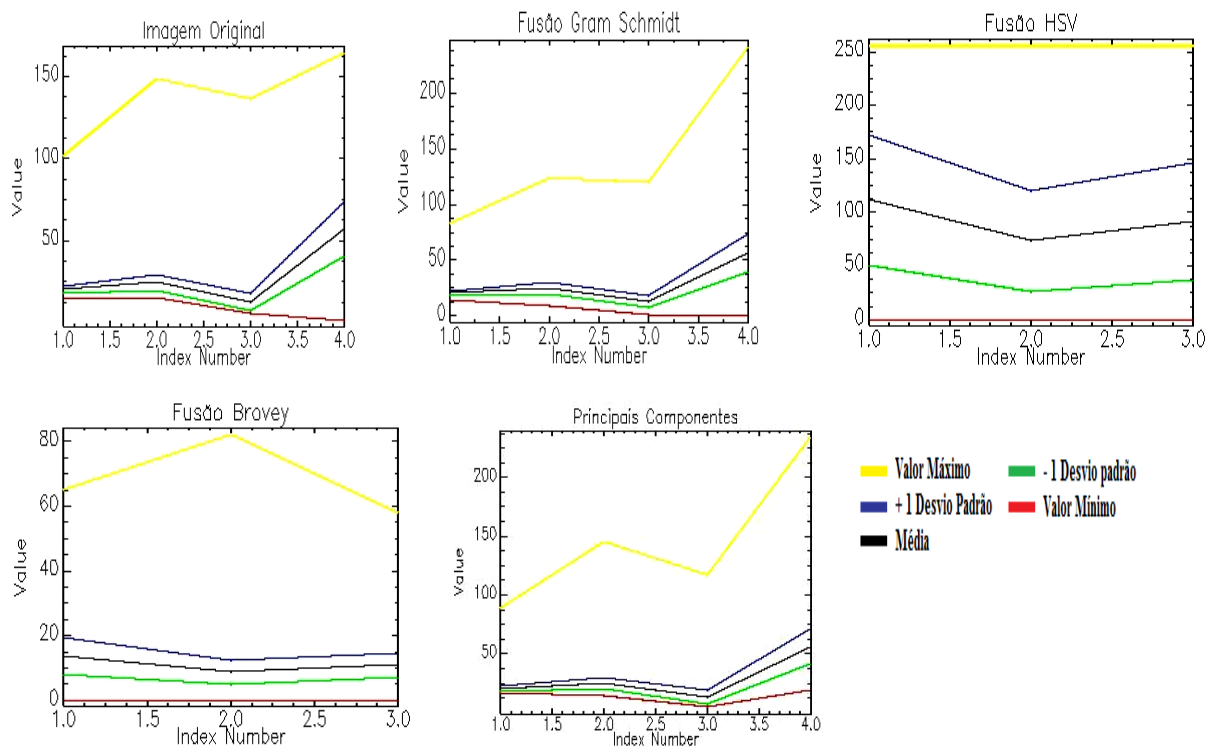


Figura 16: Histogramas comparando a imagem multiespectral original (a) e as técnicas de fusão testadas.

Com base na avaliação qualitativa e quantitativa verificou-se que as técnicas de *Gram Schmidt* e *Principais componentes* se mostraram superiores às demais técnicas testadas neste presente estudo. Em função disso para as demais etapas realizadas nesta presente dissertação foi utilizada a técnica de *Principais componentes*.

5.2 Correção Geométrica

O RMS obtido no georreferenciamento da imagem Quickbird fusionada pelo método de *Principais componentes* foi de 0,2155 metros. O Erro Médio Quadrático Total (RMS) descreve o erro de posicionamento característico de todos os pontos de controle em relação à equação, indicando a probabilidade com a qual uma posição mapeada poderá variar em

relação à sua localização verdadeira (ROSOT, 2001). Podem-se verificar (Apêndice 1), que os pontos 3 e 9 tiveram um maior erro, mas não ultrapassando o limite aceitável. Segundo CROSTA (1992), a margem de erro recomendável é de ± 1 pixel, estando o resultado de acordo com o esperado para todos os pontos.

Para este trabalho foi testado o polinômio de 1° e 2° grau para correção da imagem. Após as análises do erro resultante destes dois ajustes foi empregado somente o polinômio de 2° grau.

5.2.1 Ortorretificação

A Figura 17 mostra os pontos testes plotados sobre a imagem Quickbird para medir a precisão da ortorretificação. Vale ressaltar que neste processo não foram feitos testes com variados dados de entrada como diferentes Modelos digitais do terreno (DTM), ou o conjunto de pontos de controle e coeficientes RPC's. Escolheu-se somente o método utilizando o DTM e o modelo RPC por ser o modelo mais refinado para ortorretificar a imagem. A Figura 18 mostra o DTM utilizado para ortorretificar a imagem Quickbird-2.




Figura 17: Pontos-testes distribuídos sobre a imagem ortorretificada.




Figura 18: Modelo digital do terreno utilizando a rotina Envi MDT.

A correção da imagem foi feita sobre a imagem fusionada pelo método de *Principais componentes*, pois este método foi o que apresentou melhor correlação. Araújo (2006), diz que a correção sobre a imagem fusionada por um lado é positivo, pois diminui o número de etapas (há apenas um procedimento de ortorretificação). Por outro lado, a imagem poderia ficar “borrada” uma vez que as bandas multi e PAN, são coletadas em tempos ligeiramente diferentes.

No que se refere aos pontos utilizados como teste pode-se afirmar que a precisão encontrada foi suficiente para obter uma correção adequada na imagem, reforçada pelos resultados da análise estatística. Os resultados deste processamento (Apêndice 2), indicaram que o RMS foi satisfatório (0,4233 m) para a sua utilização em etapas subseqüentes.

Os pontos utilizados como teste para aferir a qualidade da ortorretificação da imagem Quickbird foram diferentes dos pontos utilizados para fazer o georreferenciamento da imagem.

Cabe salientar que para diminuir o erro na correção dessas imagens seria necessário possuir o modelo de superfície da área, pois, além da topografia do terreno, existe a altura dos objetos que compõem a superfície coberta pela imagem. Estas alturas podem ser obtidas por


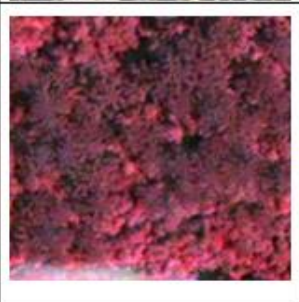

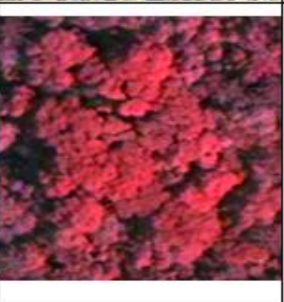
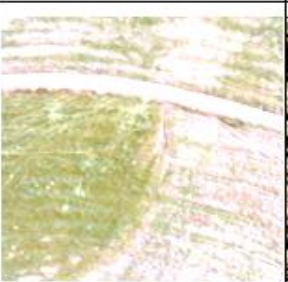
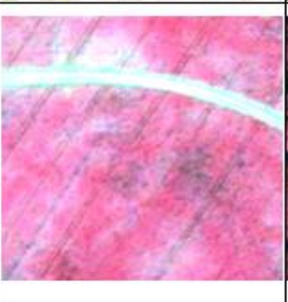
uma cobertura aérea de *laser scan*, por exemplo. Desta maneira, poder-se-ia se corrigir os deslocamentos ocasionados devido ao relevo e às árvores.

Para minimizar esse problema, várias imagens do mesmo sensor podem ser adquiridas, porém com geometrias complementares. Uma alternativa é o uso da câmera *High Resolution Stereo Camera - Airborne* (HRSC-A) que capta diversas imagens da área (Möller, 2005). Todas estas informações ajudam a resolver algumas questões da geometria da imagem, porém aumentariam imensamente o custo de um projeto: uma cena HRSC-A é cerca de dez vezes mais cara que uma fotografia aérea convencional (Möller, 2005).

5.3 Interpretação Visual da Imagem Quickbird

MOREIRA (2001) comenta que durante o trabalho de análise visual pode-se cometer alguns erros devidos: à falha na identificação das classes temáticas; ao intérprete; à delimitação precisa dos diferentes alvos contidos na cena; à escala de trabalho e; à resolução do sensor. Para minimizar os erros da interpretação visual foi efetuada, uma interpretação visual nas fotografias aéreas colorido normal e imagem de satélite (falsa cor) que podem ser vistas na Tabela 6, baseadas num trabalho de campo, estando estas fotos com melhor resolução que a imagem Quickbird.

Tabela 6: Chave de interpretação das classes de estudo.

Classes	Composição colorido normal, 3, 2 e 1 nos canais RGB respectivamente. (Fotografia aérea)	Composição falsa cor, 4, 3 e 2 nos canais RGB respectivamente. (Imagem Quickbird- 2)	Cor	Textura
<i>Araucaria angustifolia</i>			Apresenta tons de marron-avermelhado escuro. Nas fotografias aéreas apresentam tons de verde escuro denominadas de “matas pretas” REITZ e KLEIN (1966).	Rugosa em ambas as imagens.
Folhosas			As colorações das copas variam de acordo com a espécie variando do vermelho claro até vermelho escuro. Nas fotografias aéreas apresentam tons acinzentados e de verde claro.	Grosseira a rugosa em ambas as imagens.
Agricultura/solo exposto e estradas			Azul suave até o vermelho claro. Nas fotografias aéreas apresentam tons acinzentados até verde claro.	Na imagem de satélite apresenta textura fina e nas fotografias aéreas apresenta textura fina a média.

5.4 Segmentação

Para o processamento da respectiva imagem de satélite utilizou-se as bandas 4, 3 e 2 (falsa cor) nos canais RGB respectivamente, devido a melhor separação entre coníferas e folhosas principalmente considerando a banda do infravermelho próximo. A primeira etapa da classificação foi escolher qual nível de escala (espacial) deveria ser usada para segmentar a imagem.

O processo de segmentação de imagens digitais é sempre interativo, de modo que o usuário entra com valores (limiares) que determinam os critérios que vão definir o resultado final. Estes valores estão ligados diretamente aos objetivos de trabalho e também à heterogeneidade da área de interesse (SHANDLEY et al, 1998). A segmentação multiresolução ou multi escala torna o processo mais flexível uma vez que feições de diferentes tamanhos e formas podem ser trabalhadas. CAMPOS et al. (2002), utilizando a segmentação multi escala, encontrou melhores resultados dando maior peso ao parâmetro de escala (nos 3 níveis), por ser o parâmetro de maior relevância na segmentação. Na figura 19 podem ser observadas os níveis de escala que foram testados neste trabalho.




Figura 19: Valores de escala testados.

O nível de escala, 70 (Figura 19 a) e 75 (Figura 19 b) apresentou um grande número de segmentos gerados, sendo que ambas as escalas não se adequaram ao padrão das copas. O nível de escala 80 foi o que mais se aproximou da realidade da arquitetura da copa, mas ainda com problemas principalmente devido a mais de um segmento separando uma única copa. O nível de escala com valor 85 foi muito alto, pois gerou segmentos que agruparam muitas copas o que não condiz com a realidade de campo comparando com as fotografias aéreas.

Esta imagem apresenta densa vegetação com grandes agrupamentos de copas tanto de folhosas como de Araucária, sendo assim, aumentando o nível de escala (na fase 1) não foi suficientemente para delimitar as copas das árvores. Os resultados podem ser mais segmentados, se for definido um pequeno valor de escala, ou sub-segmentado se for definido um valor de escala grande. A fusão dos segmentos foi útil neste caso para melhorar a definição dos limites das árvores ou copas.

No segundo nível da segmentação foi aplicado um nível de escala 90 para agrupamento desses segmentos que fazem parte das copas das árvores, pois foi a valor que mais se adequou a realidade das mesmas. Com base nestas considerações pode-se dizer que a combinação de nível de escala 80 para o primeiro nível e 90 para o segundo nível da segmentação foi o que apresentou melhores resultados.

A avaliação da segmentação em imagens digitais ainda é realizada visualmente na maioria das vezes em que esta técnica é empregada (como por ex.: ALMEIDA FILHO et al. (1998), SHIMABUKURO et al. (1998)). Segundo SHANDLEY et al. (1998), pesquisadores têm encontrado dificuldade em fazer afirmativas quantitativas sobre resultados de segmentação. DARWISH et al. (2003) afirmam que a avaliação da segmentação é feita indiretamente pela avaliação da classificação.

5.5 Classificação Orientada ao Objeto

Nesta dissertação foram testados dois métodos de classificação orientada ao objeto sendo uma supervisionada (seleção de amostras) e classificação por regras utilizando *lógica fuzzy*.

5.5.1 Supervisionada

Partindo-se da segmentação, foi também computado todos os atributos da imagem

(espaciais, espectrais e razão de bandas), na composição falsa cor (bandas 4, 3 e 2 nos canais RGB respectivamente), sendo esse processo totalmente automático.

Para seleção dos segmentos que pertenciam às classes foi utilizado uma ferramenta chamada “*transparency*”, sendo de grande importância, pois se podia ver a imagem segmentada e imagem original simultaneamente. A partir daí foram selecionados, 70 amostras para a classe *Araucaria angustifolia*, 70 para a classe folhosas, e 15 amostras para a classe Agricultura/solo exposto e 15 amostras para a classe sombra. O resultado da classificação pode ser visto na Figura 20.

Como visto no item 5.2.5 o método de classificação K *Nearest Neighbor* considera a distância euclidiana no espaço n-dimensional da meta para os elementos dos dados de treinamento. O *K-Nearest Neighbor* é um método muito menos sensível a *outliers* e ruídos no conjunto de dados e geralmente produz uma classificação mais precisa em comparação com o vizinho mais próximo utilizando os métodos tradicionais. O parâmetro K é o número de vizinhos considerados durante a classificação. Então foi feito alguns testes mudando o valor de K para 5 e 7, mais os resultados não foram satisfatórios, mudando consideravelmente os resultados da classificação. Valores maiores tendem a reduzir o efeito do ruído e *outliers*, mas podem causar classificação imprecisa (RSI, 2009). A escolha ideal para o parâmetro k depende do conjunto de dados e os dados de treinamento que são selecionados. Neste trabalho optou-se por utilizar o valor padrão (3) que o próprio *software* indica por ter apresentado melhor resultado, não confundindo as classes.

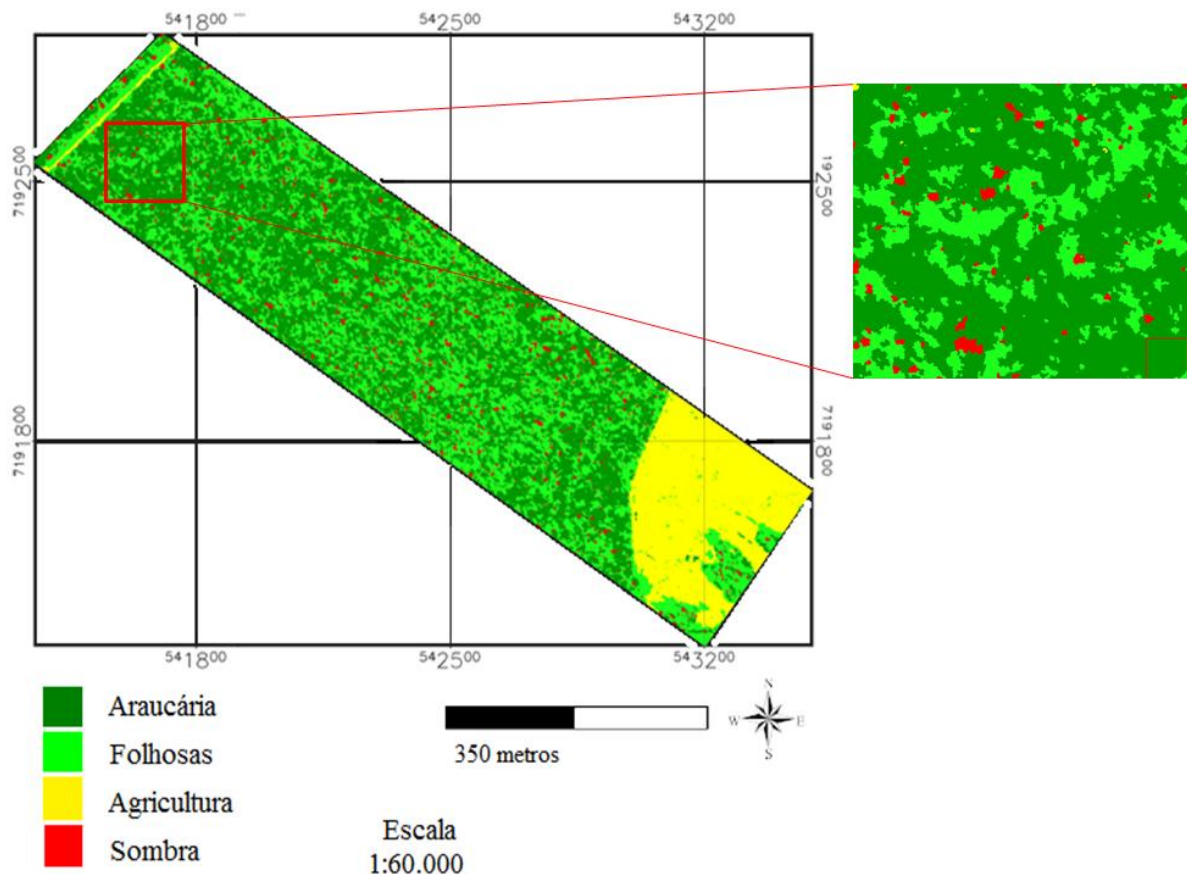


Figura 20: Resultado da classificação supervisionada.

5.5.2 Classificação por regras

Após a segmentação e cálculo (feito automaticamente no *software*) dos atributos espaciais, espectrais, *color space* e razão de bandas, os segmentos foram carregados para um projeto no *ArcView* analisando as regras disponíveis. Comparando os segmentos destacaram-se as regras espectrais, espaciais e razão de bandas para diferenciação das classes. Neste processo foram carregadas as bandas 4, 3 e 2 da imagem Quickbird nos canais RGB respectivamente.

Para as classes *Araucaria angustifolia* e *Folhosas* foram destacadas as regras espectrais como valores mínimos e máximos da banda infravermelho próximo, e as regras referentes ao NDVI (razão de bandas), e o atributo espacial “área”.

Para a classe sombra destacou-se as regras de “intensidade”, e valores espectrais como valores máximos e mínimos da banda verde. Na classe agricultura, como gerou segmentos grandes devido à homogeneidade da classe em questão, o atributo espacial “área” e “textura” se mostraram com melhor resposta. Vale ressaltar que as regras visualizadas no *ArcView* é

uma análise prévia de quais regras se destacam para classificar a respectiva imagem.

Após a etapa de escolha das regras foi carregada novamente a imagem e feita à segmentação com os mesmos parâmetros, sendo a segmentação com nível de escala 80 e a opção *merge segments* com nível de escala 90. Após foram feitas combinações de regras para classificar as tipologias florestais.

As regras aplicadas para classificar a imagem foram: espacial, espectral e razão de bandas. A Tabela 7 a seguir mostra as regras adotadas para cada classe.

Tabela 7: Regras utilizadas para cada classe.

Regras	Espacial	Espectral	Textura	Razão de Bandas
Classes				
Araucária	x	x	x	<i>Bandratio</i>
Folhosas	x	x	x	<i>Bandratio</i>
Agricultura	<i>Área Elongation</i>	<i>Min-band 1</i>	x	x
Sombra	x	x	x	<i>Intensity</i>

As regras baseadas na textura dos objetos não se mostraram eficientes, confundindo especialmente as classes “Araucária” e “Folhosas”, e *portanto*, não foram aplicadas nesta classificação. WANG et. al (2004) diz que a textura da imagem Quickbird não contribui tanto quanto a textura da imagem IKONOS para distinguir as espécies, mostrando que a imagem IKONOS é ligeiramente superior ao da imagem Quickbird na separação de espécies que ocorrem no mangue na costa do Panamá.

Para a classe “Araucaria” e “Folhosas” foi utilizado à regra *bandratio* (NDVI), se mostrando superior as demais regras. A regra ficou num intervalo de $0 > 0.4200$ para a classe “Araucaria”, e foi utilizada a opção “*not*” com este mesmo intervalo para a classe “Folhosas”, sendo assim invertendo os valores aplicados para a classe “Araucaria”. SOUSA et. al (2010), utilizou o NDVI como banda auxiliar para classificar duas espécies dominantes de coníferas (*Q. suber* e *P. pinea*) na região do Alentejo – Portugal, sendo que a detecção da vegetação foi determinada com elevado rigor, sendo a data das imagens um fator muito importante para o resultado. Neste trabalho foram testados também os valores mínimos e máximos da banda infravermelho próximo diferenciando as classes “Araucaria” e “Folhosas”, mas neste caso optou-se somente por uma combinação de classes.

Para a classe “Agricultura” foi aplicada a regra “*área*” com intervalo de 1316,56 – 311419,66 pixels, sendo esta área correspondente ao tamanho do segmento gerado, mas ao

aplicar esta regra à classe foi também inserido um agrupamento de copas de Araucária. Para isso, como a classe “Araucária” apresenta grande absorção e baixa reflectância especialmente na região do infravermelho próximo, foi utilizada a regra valor mínimo da banda 2 (verde) com intervalo de 0 a 17.0000 (DN), para retirar este agrupamento da classe “Agricultura”, mas neste caso foi aplicada tolerância *fuzzy* de 0% por esse agrupamento estar exatamente dentro deste intervalo. Vale ressaltar que para as demais regras foi utilizada uma tolerância *fuzzy* de 5%. A classe “Sombra” foi aplicado o valor mínimo da banda 2 (verde) com intervalo de 9 a 12,5. Foi aplicada esta regra, devido principalmente aos baixos valores reflectância que apresenta a referida classe.

Antes de efetuar a classificação propriamente dita foi analisado o resultado através da função “*Preview*”. Analisando a imagem visualmente verificou que a área que correspondia à classe “Agricultura” foi classificada erroneamente, necessitando assim diminuir o peso das classes “Araucária” e “Folhosas” para 90%. A imagem a seguir (Figura 21) mostra o resultado da classificação com detalhes da identificação da espécie Araucária (verde escuro), baseada em lógica *fuzzy*.

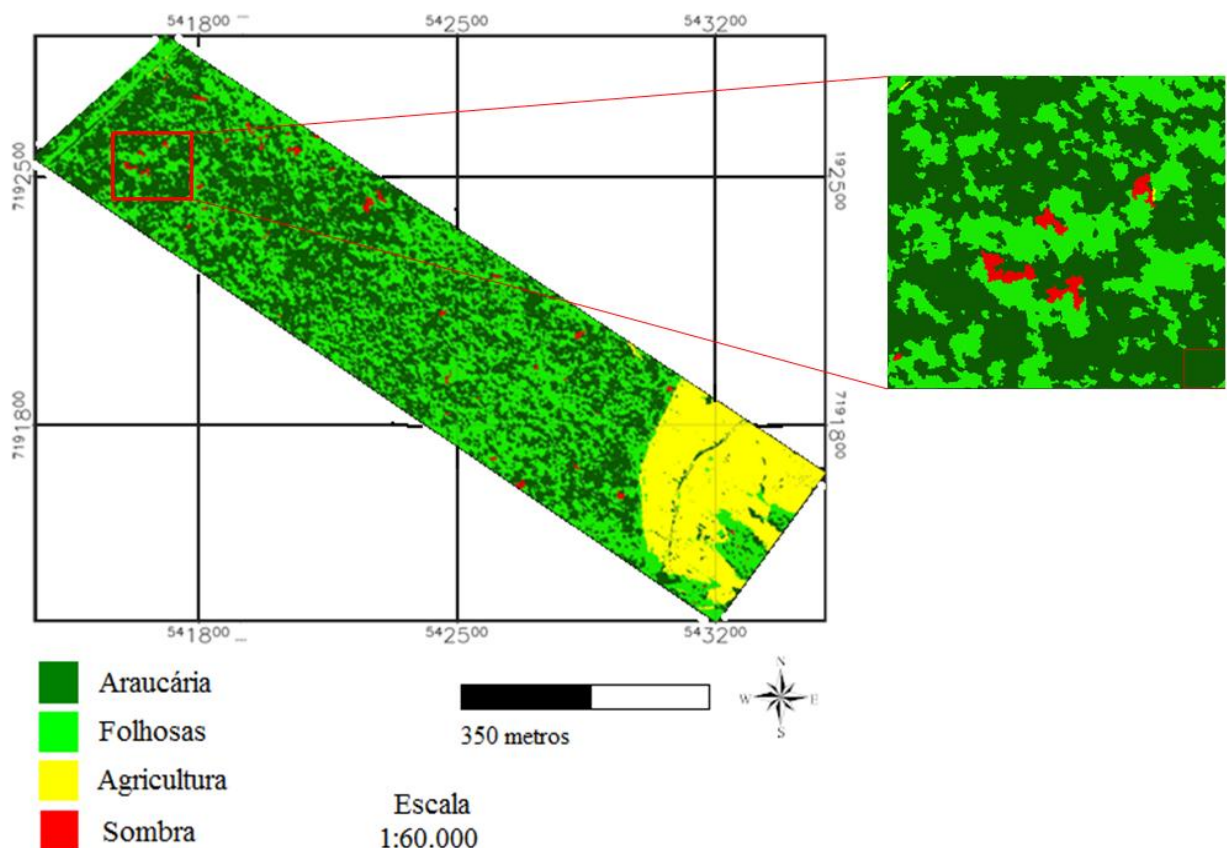


Figura 21: Imagem classificada por regras.

5.5.3 Comparação entre classificação supervisionada e por regras

Como visto anteriormente tanto para a classificação supervisionada e classificação por regras foram aplicados os mesmos parâmetros de segmentação para poder efetuar a comparação entre as classificações. Verifica-se na Tabela 8 a seguir o resultado da classificação referente à área de cada classe.

Tabela 8: Resultado referente à classificação da imagem Quickbird.

Classes	Classificação por Regras		Supervisionada	
	Área (ha)	%	Área (ha)	%
Não classificado	0,00	0,00	0,00	0,00
Araucaria	44,40	40,00	52,72	47,50
Folhosas	49,77	44,83	37,93	34,17
Agricultura	16,02	14,44	16,99	15,31
Sombra	0,81	0,73	3,37	3,03
Total	111,00	100,00	111,00	100,00

Pode-se verificar na Tabela 8 verifica-se que a classe “Araucaria” para a classificação supervisionada obteve diferença de 8,32 ha a mais em relação à classificação por regras. Isto também ocorreu para as classes “Agricultura” (0,97 ha), e “Sombra” (2,56 ha). Para a classe “Folhosas” houve diferença de 11,84 ha a mais do que na classificação por regras.

Para montar a matriz de confusão foram plotados pontos sobre a imagem de satélite referente à interpretação visual feita sobre a mesma, com base no trabalho de campo e interpretação do mosaico de fotografias aéreas. Foram plotados num total de 70 pontos para a classe “*Araucaria angustifolia*”, 55 pontos para a classe “Folhosas” e 15 pontos para a classe “Agricultura” e 15 pontos para a classe “Sombra”. Para avaliar a acurácia da classificação foram utilizados os mesmos pontos para ambas as imagens. A Tabela 9 a seguir mostra a matriz de confusão para a classificação supervisionada.

Tabela 9: Matriz de confusão para a classificação supervisionada

Supervisionada					
Classes	Araucaria	Folhosas	Agricultura	Sombra	Total de pontos
Araucaria	64	6			70
Folhosas	6	49			55
Agricultura			15		15
Sombra	5			10	15
Totais	75	55	15	10	155

Podemos verificar na Tabela 9 que para esta classificação foi obtido uma acurácia geral de 89 % e um índice *kappa* de 0,83 e uma variância de *kappa* de 0,001577, que segundo LANDIS e KOCH (1977) é avaliado como classificação excelente. Para a classificação supervisionada também foi calculado o índice *kappa* para a classe de maior importância considerada neste estudo, sendo a classe “*Araucaria angustifolia*” com *kappa* de 0,84. DISPERATI et al (2009), verificaram o uso da banda infravermelho próximo em uma imagem Quickbird não ortorretificada, para esta mesma área de estudo para mapear as copas de Araucária, e obtiveram um índice *kappa* de 0,79, sendo este valor inferior ao encontrado neste presente trabalho tanto para a classificação por regras como a classificação supervisionada. Isto se deve ao fato destes autores terem empregado somente uma banda (infravermelho próximo), sendo que nesta presente dissertação a separação entre Araucária e folhosas foi encontrada com a regra *bandratio* (NDVI), ou seja, empregando mais de uma banda.

Na Tabela 10 verifica-se a acurácia do produtor e do usuário. A classe agricultura e sombra para ambas a classificações, apresentaram valores de 100% de acurácia. A classe de menor valor foi à classe Araucária com 84,4% e 85,3%, para a classificação por regras e supervisionada respectivamente. Na acurácia do usuário na classificação por regras, as classes folhosas e Araucária obtiveram os maiores valores com 96,36% e 92,86% respectivamente. Já para as classes agricultura (80%) e sombra (53,33%), foi encontrado os menores valores de acurácia. Esses baixos valores principalmente no caso da sombra foram obtidos devido à dificuldade de encontrar uma regra ou um conjunto de regras que pudessem classificar com exatidão esta classe. Vale ressaltar que a classe sombra representa apenas 3,3% da imagem, sendo de baixa representatividade em relação às demais classes, como visto na Tabela 9 não interferindo na classificação.

Tabela 10: Acurácia do produtor e do usuário para a classificação por regras e supervisionada.

Regras			Supervisionada		
Classes	Acurácia do Produtor	Acurácia do Usuário	Classes	Acurácia do Produtor	Acurácia do Usuário
Araucaria	84,42	92,86	Araucaria	85,33	91,43
Folhosas	89,83	96,36	Folhosas	89,09	89,09
Agricultura	100	80	Agricultura	100	100
Sombra	100	53,33	Sombra	100	66,67

Tabela 11: Matriz de confusão para a classificação por regras

Regras					
Classes	Araucaria	Folhosas	Agricultura	Sombra	Total de Pontos
Araucaria	65	5			70
Folhosas	2	53			55
Agricultura	2	1	12		15
Sombra	8			7	15
Totais	77	59	12	7	155

A classificação por regras obteve um índice *kappa* de 0,82 e variância de *kappa* de 0,001634, mostrando a classificação como excelente e uma exatidão global de 88%. Calculando o índice *kappa* somente para a classe de interesse ou de maior relevância (araucária), obteve um índice de 0,86. Pode-se concluir neste trabalho que tanto a classificação por regras como a supervisionada obtiveram resultados altamente satisfatórios para classificar as tipologias florestais (Tabela 11).

É importante ressaltar que nenhuma operação de pós-classificação foi efetuada. As operações de pós-classificação poderiam proporcionar melhorias à classificação digital e, conseqüentemente, na acuracidade temática do mapeamento, mas a subjetividade do analista poderia introduzir vieses nos resultados tornando-os inconsistentes para a análise de desempenho de algoritmos (DLUGOZ, 2005).

O delineamento e identificação automática de espécies florestais através do sensoriamento remoto, torna-se cada vez mais importante no setor florestal. Estes dados podem contribuir com a distribuição espacial das espécies florestais de forma mais rápida e com menor custo, auxiliando na tomada de decisões em inventários florestais, gestão de povoamentos florestais e estimativa de biomassa e área basal.

6. CONCLUSÕES E RECOMENDAÇÕES

Considerando a qualidade visual das imagens fusionadas, e principalmente devido à melhor conservação das cores, as técnicas de Gram-Schmidt e Principais Componentes forneceram os melhores resultados. Em relação a fidelidade espectral das imagens fusionadas com relação à multiespectral original, com a técnica de fusão *Principais componentes* preservou-se melhor o contraste da imagem original, mas a técnica de *Gram Schmidt* forneceu melhor resultado quanto a conservação do brilho da imagem.

Na segmentação da imagem Quickbird os níveis de escala mais adequados para delimitar as copas da espécie *Araucaria angustifolia*, foram os valores 80 e 90 para o primeiro e segundo nível respectivamente.

Comparando a classificação por regras e supervisionada, apresentaram coeficiente *Kappa* semelhante com 0,83 e 0,84 respectivamente. Calculando o índice somente para a classe Araucária a classificação por regras se mostrou superior com acerto de 86% e a classificação supervisionada com acerto de 82%, sendo assim, a classificação por regras se mostrou superior a supervisionada, mas, necessita de um maior tempo para encontrar regras para classificar a imagem e conseqüentemente um maior conhecimento e controle sobre o comportamento espacial e espectral dos objetos.

A imagem Quickbird-2 se mostrou eficiente para a identificação da espécie *Araucaria angustifolia*, para ambas as classificações podendo ser utilizadas para estimativa de cobertura de copas existente na área da FLONA.

Para a seqüência das pesquisas nesta área recomenda-se:

Testar novas técnicas de fusão, utilizando imagens de outros sensores com melhor resolução e imagens de radar;

A utilização de dados LIDAR aerotransportado para a confecção de um MDT com maior precisão aumentando assim a acurácia da ortorretificação;

Utilizar outros algoritmos para efetuar novos testes de segmentação e classificação desta respectiva imagem.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ANTUNES, A.F.B. Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial. **Tese de Doutorado** em Ciências Geodésicas – Universidade Federal do Paraná - UFPR, Curitiba, 2003. 147 p.

ARAÚJO, E. H. G. Análise multi-temporal de cenas do satélite quickbird usando um novo paradigma de classificação de imagens e inferências espaciais: estudo de caso-Belo horizonte, MG. **Dissertação de Mestrado** em Sensoriamento Remoto – Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, 2006. 175p.

AZEVEDO et al. Redes neurais com aplicações em controle em sistema especialista. **Visual books**. Florianópolis. 2000.

BARBOSA, K.M. do N.; ACCO, M.; KIRCHNER, F.F. Classificação de imagens Ikonos e comparação por meio de segmentação e fotointerpretação da área amostral. Simpósio brasileiro de sensoriamento remoto, 11, 2003, Belo Horizonte. **ANAIS**, São José dos Campos: INPE, 2003, p. 281-283.

BARNSLEY, M. J.; MOLLER-JENSEN, L. E BARR, S. L. Inferring urban land use by spatial and structural pattern recognition. In:Donnay, J.; Barnsley, M. J.; Longley, P. A. (eds). **Remote sensing and urban analysis**. London: Taylor & Francis. 2001.Cap. 7, p. 115- 144.

BARRET, E. C., CURTIS, L.F. **Introduction to Environmental Remote Sensing**: 4 ed. Cheltenham: Stanley Thornes Ltd. 457 p. 1999.

BATISTA, G.T.; NASCIMENTO, P.S.R.; ALMEIDA FILHO, R. Efeito de pré processamento (filtro mediana) no desempenho da segmentação e classificação de imagens Landsat-TM. In: Simpósio Latinoamericano de Percepção Remota, Mérida, Venezuela, 1998. **ANAIS**, São José dos Campos: INPE, 1997. Sessão Técnica e Metodológica.

BENZ, U. Supervised fuzzy analysis of single- and multichannel SAR data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 37, n. 2, p. 1023-1037, Mar. 1999.

BERNARDI, J.V.E.; LANDIM, P.M.B. **Aplicação do Sistema de Posicionamento Global (GPS) na coleta de dados**. Rio Claro: DGA,IGCE,UNESP, jan. 2002. 31 p. (Geomatemática,Texto Didático 10). Disponível em: <http://www.rc.unesp.br/igce/aplicada/textodi.html>. Acesso em: 20 set. de 2010.

BINAGHI, et al. Fuzzy contextual classification of multisource remote sensing images. **IEEE transactions on Geosciences and Remote Sensing**, vol35, n 7. 1997.

BLASCHKE, T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P. Object oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. In: Cremers, A. and Greve, K. (eds). **Environmental information for planning, politics and the public**. Metropolis, Marburg: [s.n.], v. 2, p. 555-570, 2001.

BOCK, M.; XOFIS, P.; MITCHLEY, J.; ROSSNER, G.; WISSEN, M. Object-oriented methods for habitat mapping at multiple scales – Case studies from Northern Germany and Wye Downs, UK. **Journal for Nature Conservation**, v. 13, n. 2-3, p. 75-89, July, 2005.

BRITEZ, R. M. Aspectos ambientais a serem considerados na restauração da Floresta de Araucária no Estado do Paraná. **Pesquisa Florestal Brasileira**. n. 55, p. 37-43, 2007.

BURROUGH, P. A. **Principles of geographical information systems for land resources assessment**. Oxford: Clarendon Press, 1986, 193 p.

BURROUGH, P.; McDONNELL, R. A. **Principles of Geographical Information System**. Oxford: Oxford Uni. Press, 1998.

CAMPBELL, J.B. **Introduction to Remote Sensing**. 2nd. Ed. New York: The Guilford Press, 1996. 622 p.

CAMPOS, M.A.A.; ROLIM, F.A.; LINGNAU, C. Segmentação multiresolução e lógica fuzzy na classificação automática de imagens Ikonos. In: GISBRASIL 2002, 8, Curitiba. **ANAIS**, Curitiba: Fatorgis, 2002. Seção Mostra do Talento Científico - Planejamento e Uso do Solo. 1 CD-ROM.

CARPER W. J., LILLESAND T. M., AND KIEFER R. W., 1990. The use of intensity- hue saturation transformations for merging SPOT panchromatic and multispectral image data, **Photogrammetric Engineering & Remote Sensing**., vol. 56, pp. 459–467.

CARVALHO, P. E. R. **Espécies florestais brasileiras: recomendações silviculturais, potencialidades uso da madeira**. Colombo: Empresa Brasileira de Pesquisa Agropecuária, Centro Nacional de Pesquisas Florestais. EMBRAPA: CNPF. 640 p. 1994.

CENTENO, J.A.S. **Sensoriamento remoto e processamento de imagens digitais**. Universidade Federal do Paraná – Departamento de Geomática. Curitiba: UFPR, 2003. 210 p.

CHAVEZ P. S. AND KWARTENG A. Y., 1989. Extracting spectral contrast in Landsat Thematic Mapper image data using selective principle component analysis, **Photogrammetric Engineering & Remote Sensing**., vol. 55 (3), pp. 339–348.

CHAVEZ, JR. P. S., SIDES S. C. AND ANDERSON J. A., 1991. Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic, **Photogrammetric Engineering & Remote Sensing**, vol. 57 (3), pp. 295–303. Cheltenham: Stanley Thornes Ltd. 457 p. 1999.

CHENG, P.; TOUTIN, T.; ZHANG, Y.; WOOD, M. QuickBird – geometric correction, path and block processing and data fusion. **EOM**, v. 12, n. 3, p. 24-30, May 2003.

CHENG, T. Fuzzy Objects: Their Changes and Uncertainties. **Photogrammetric Engineering & Remote Sensing**, v.68, n.1, p. 41-49, 2002.

CHMIEL, J.; KAY, S.; SPRUYT, P. **Orthorectification and geometric quality assessment of very high spatial resolution satellite imagery for common agricultural policy**

purposes. Disponível em: <<http://www.isprs.org/istanbul2004/comm4/comm4.html>>. Acesso em: 20 jul. 2010.

COLWELL, J.E. Vegetation Canopy Reflectance. **Remote Sensing of Environment**. v.3, n.3, 1974, p.175-183.

CONGALTON, R. A Review of Assessing the Accuracy of Classification Remotely Sensed Data. **Remote Sensing of Environment**, USA, No 37, p. 35-36, 1991.

CONGALTON, R. G.; ODERWALD, R. G.; MEAD, R. A. Assessing Landsat classification accuracy using discrete multivariate statistical techniques. **Photogrammetric Engineering & Remote Sensing**, v. 49, n. 12, p. 1671-1678, Dec. 1983.

COULOIGNER I., RANCHIN T., VALTONEN V. P., AND WALD L., 1998. Benefit of the future SPOT-5 and of data fusion to urban road mapping, **Int. J. Remote Sens.**, vol. 19 (8), pp. 1519–1532.

COUTINHO, A.C. Segmentação e classificação de imagens Landsat-TM para o mapeamento dos usos da terra na região de Campinas, SP. São Paulo, 1997. 150 p. **Dissertação de Mestrado** em Ciências, Curso de Pós-Graduação em Ciências, Departamento de Ecologia Geral do Instituto de Biociências, Universidade de São Paulo.

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

DARWISH, A.; LEUKERT, K.; REINHARDT, W. Image segmentation for the purpose of Definiens. **e-Cognition: User Guide 4**. Germany, 2004. 486 p.

DigitalGlobe, Inc.. **QuickBird imagery products: product guide** . Longmont, Colorado: Digital Globe Inc., 2009. 69p.

DISPERATI, A. A., OLIVEIRA FILHO, P.C. Delineamento de copas de árvores em fotografias aéreas de alta resolução, através de suas sombras periféricas: estudo de caso na Floresta Ombrófila Mista. **Revista Árvore**. Viçosa-MG. v. 29, n. 2, p. 195-202, 2005.

DISPERATI, A. A., PESCK, V. A., DISPERATI, J., SANTOS, J. R., RUDEK, A., FIGUEIREDO FILHO, A. Identificazione di chiome di *Araucaria angustifolia* nella banda dell'infrarosso vicino, fornite da Quickbird 2, In: *13ª Conferenza Nazionale ASITA* (Federazione Italiana delle Associazioni Scientifiche per le Informazioni Territoriali e Ambientali), **ANAIS**, 2009, Bari - Itália. p. 1005-1010, 2009.

DISPERATI, A. A., SANTOS, J. R., SERVELLO, E., CAMARGO, F. F., DISPERATI, J., LISBOA, G. S. Semantic network applied to IKONOS-2 image for the delineation of *Araucaria angustifolia* (Brazilian pine) crowns in a Mixed Ombrophilous Forest, In: *33rd International Symposium on Remote Sensing of Environment*, 2009, Stresa, Lago Maggiore, Italy. **ANAIS**, ISPRS, JRC, International Center for Remote Sensing of Environment, 2009.

DISPERATI, A. A; OLIVEIRA FILHO, P. C. Copas de Araucária observadas em fotografias aéreas 70 mm colorido normal em escala muito grande (1:1.000). **Ambiência** - Revista do Centro de Ciências Agrárias e Ambientais V. 2 Edição Especial 1. 2006. p 137-

149.

DLUGOSZ, F. Classificação orientada a regiões na discriminação de tipologias da Floresta Ombrófila Mista usando imagens orbitais Ikonos. **Dissertação de Mestrado** em Ciências Florestais – Universidade Federal do Paraná-UFPR, Curitiba, PR. 135 p. 2005.

DONNAY, J.; BARNESLEY, M. J. E LONGLEY, P. A. Introduction. In: Donnay, J.; Barnesley, M. J. & Longley, P. A. (eds) **Remote sensing and urban analysis**. London: Taylor & Francis, 2001. Cap. 1, p. 3-18.

EASTMAN, J. R. **IDRISI for Windows: Manual do Usuário**. Porto Alegre: UFRS, 1998.

EDWARDS K. AND DAVIS P. A., 1994 . The use of Intensity-Hue- Saturation transformation for producing color shaded-relief images, **Photogrammetric Engineering & Remote Sensing**, vol. 60 (11), pp. 1369–1374.

ENVI. The environment for visualizing images. **Guia do ENVI em português**, ENVI versão 4.6.1. 2009. Disponível em: <<http://www.sulsoft.com.br>>. Acesso em: 20 abr. 2009.

FANELLI A., LEO A., AND FERRI M., 2001. Remote sensing images data fusion: A wavelet transform approach for urban analysis, in **Proc. Joint IEEE/ISPRS Workshop Remote Sensing Data Fusion Over Urban Areas** , pp. 112–116.

FUCKNER, M. A., ROSA, V.G.C., ROSEMBACK, R. Análise comparativa da aplicação de transformações radiométricas e técnicas de fusão de imagens em área urbana. **ANAIS do XIII Simpósio Brasileiro de Sensoriamento Remoto**. Florianópolis. p. 6343-6350, 2007.

GALVÃO, F.; KUNIYOSHI, Y. S.; RODERJAN, C. V. Levantamento fitossociológico das principais associações arbóreas da Floresta Nacional de Irati - PR. **Floresta**, v. 19, n. 1 e 2, p.30-49, 1989.

GAUSMAN, H.W. Leaf reflectance of near-infrared. **Photogrammetric Engineering & Remote Sensing**. v.51, n.11, 1985, p.1725-1734.

GILLESPIE A. R., KAHLE A. B., AND WALKER R. E. Color enhancement of highly correlated images—II. Channel ratio and ‘chromaticity’ transformation techniques, **Photogrammetric Engineering & Remote Sensing**, vol. 22, p. 343–365. 1987.

GONZÁLES AUDÍCANA M. AND SECO A., 2003. Fusion of multispectral and panchromatic images using wavelet transform. Evaluation of crop classification accuracy, in **Proc. 22nd EARSeL Annu. Symp. Geoinformation Eur.-Wide Integr.**, Prague, Czech Republic, 4–6 June 2002, T. Benes, Ed., 2003, pp. 265–272.

GONZALES, R.C; WINTZ, P. **Digital image processing**. Proding, Addison Wesley, 1987. 431p.

GONZALES, R. C., WOODS, R.E. **Digital Image Processing**. 2ª ed. Prentice Hall. New Jersey, 793 p., 2002.

GOUGEON, F. A. Automatic individual tree crown delineation using a valley-following algorithm and a rule-based system. In **International Forum Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry**, Victoria, Canada, Canadian Forest Service, pp. 11-23, 1999.

GRODECKI, J.; DIAL, G. Block adjustment of high-resolution satellite images described by rational polynomials. **Photogrammetric Engineering & Remote Sensing**, v. 69, n. 1, p. 59-68, jan. 2003.

HOFMANN, P.; W. REINHARDT. The extraction of GIS features from high resolution imagery using advanced methods based on additional contextual information – first experiences. In: International Archives of Photogrammetry and Remote Sensing, **ANAIS**, Amsterdam: IAPRS, 2000. p. 51-58.

HOWARD, J. A. **Remote Sensing of Forest Resources – Theory and Application**. London: Ed.Chapman & Hall. 436 p. 1991.

IBAMA. Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis. **Portaria nº 37-N, de 03 de abril de 1992**. Lista Oficial de Espécies da Flora Brasileira Ameaçada de Extinção. 1992. 2p.

IBGE. **Manual técnico da vegetação brasileira**. Série Manuais Técnicos em Geociências, n.1, Rio de Janeiro, 1992.

JACOBSEN, K.; Geometric potential of Ikonos- and Quickbird-images. **Photogrammetric Weeks**, n. 3, p. 101-110, 2003.

JENSEN, J.R. **Introductory digital image processing**. 2. ed. Upper Saddle River: Prentice Hall, 1996. 318 p.

KLEIN, R. M. O aspecto dinâmico do pinheiro-brasileiro. **Sellowia**. v.12, n.12: 17-48 p. 1960.

LAMPRECHT, H. **Silvicultura nos Trópicos: ecossistemas florestais e respectivas espécies arbóreas - possibilidades e métodos de aproveitamento sustentado**. Eschborn : GTZ, 1990.

LANDIS, J., KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**. v.33, n. 3, p. 159-179, 1977.

LEITE, P. F.; KLEIN, R. M. **Vegetação**. In: Geografia do Brasil : Região Sul. v. 2 . Rio de Janeiro: IBGE, 1990.

LEITE, P.F. As diferentes unidades fitogeográficas da região sul do Brasil proposta de classificação. Curitiba, 1994. 160 p. **Dissertação de Mestrado** em Ciências Florestais. Curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal

do Paraná.

LEE, S & ZHU, Q. **Fuzzy and evidence reasoning**. Springer-Verlag. Germany. 1995.

LILLESAND, T.M.; KIEFER, R.W. **Remote sensing and image interpretation**. 3. ed. Crawfordsville: J. Wiley and Sons, 1994. 750 p.

LILLESAND, T. M.; KIEFER, R. W. **Remote sensing and image interpretation**. John Wiley and Sons, Inc., Fourth Edition, New York, 725 p., 2000.

LILLESAND, T. M., KIEFER, R.W., CHIPMAN, J.W. **Remote Sensing and Image Interpretation**: John Wilwy & Sons, Inc. 756 p., 2007.

LISBOA, G.S. Fotografias aéreas de escala grande e imagem Ikonos-2 no mapeamento de copas de *araucaria angustifolia*. **Dissertação de Mestrado** em Ciências Florestais – Universidade Estadual do Centro Oeste - UNICENTRO, Irati, PR. 104p. 2009.

LUZ, J. Imagens Alos para o Mapeamento da Vegetação Arbórea e Outros Usos do Solo em Área de Floresta Ombrófila Mista. **Dissertação de Mestrado** em Manejo Florestal – Universidade federal do Paraná – UFPR, Curitiba-PR, 121 p, 2009.

MAACK, R. **Geografia física do Estado do Paraná**. Curitiba: José Olympio, 350p. 1968.

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

MAZZA, C. A. da S., MAZZA, M. C. M., SANTOS, J. E. SIG aplicado à caracterização ambiental de uma unidade de conservação Floresta Nacional de Irati, Paraná. In: **Anais XII Simpósio Brasileiro de Sensoriamento Remoto**, Goiânia, Brasil, 16-21 abril 2005, INPE, p. 2251-2258.

MAZZA, Carlos Alberto da Silva. Caracterização ambiental da paisagem da Microregião Colonial de Irati e zoneamento ambiental da Floresta Nacional de Irati, PR. **Tese de Doutorado**, São Carlos/ SP: UFSCar, 2006. 147 p.

MENDONÇA F. A. & DANNI-OLIVEIRA, I. M. **Dinâmica atmosférica e tipos climáticos predominantes da bacia do rio Tibagi**. In: A bacia do rio Tibagi, Cap.2. Londrina, PR: M.E. Medri, 2002. p.589.

MENESES, P. R. **Fundamentos de Radiometria Óptica espectral**. In: (Ed.). Mesense, P.R., Madeira Netto, J.S. (org) - Sensoriamento Remoto: reflectância dos alvos naturais. Brasília-DF: Universidade de Brasília-UnB, Embrapa Cerrados, p.15-40, 2001.

METTERNICHT, G. Change detection assessment using fuzzy sets and remotely sensed data: an application in topographic maps revision. **ISPRS Journal of Photogrammetry and Remote Sensing**, vol. 54. p.221-233. 1999.

MÖLLER, M. Estudo da qualidade e aplicações práticas de dados de scanner com altíssima resolução. In: Blaschke, T.; Kux, H. (ed) **Sensoriamento remoto e SIG avançados: novos**

sistemas sensores: métodos inovadores. São Paulo: Oficina de Textos, nov. 2005. Cap. 22, p. 211-224.

MONICO, J. F. G.; **Posicionamento pelo NAVSTAR-GPS:** descrição, fundamentos e aplicações. São Paulo: UNESP, jan. 2000. 287 p.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação.** São José dos Campos-SP: Instituto Nacional de Pesquisas Espaciais-INPE. 250 p. 2001.

NOVO, E.M.L. de M. **Sensoriamento remoto.** Princípios e aplicações. 2. ed. São Paulo: Edgard Blücher, 1992. 308 p.

NUÑEZ, J.R. Segmentação automática e classificação em vídeos esportivos. **Dissertação de Mestrado em Informática Aplicada** – Pontifícia Universidade Católica do Paraná. Curitiba-PR. 2006. 178 p.

OLIVEIRA, L.T. Fusão de imagens de sensoriamento remoto e mineração de dados geográficos para mapear as fitofisionomias do bioma cerrado. **Dissertação de Mestrado** em Engenharia Florestal – Universidade Federal de Lavras – UFLA. Lavras-MG. 131 p. 2004.

ORELLANA, E. Funções densidade de probabilidade no ajuste da distribuição diamétrica de um fragmento de floresta ombrófila mista. **Dissertação de Mestrado** em Ciências Florestais – Universidade Estadual do Centro Oeste-UNICENTRO, Irati, PR. 122p. 2009.

PEDRO, P. C.; Ortorectificação de imagens de alta resolução Ikonos e Quickbird utilizando APM (Affine Projection Model). **Dissertação de Mestrado** em Ciências Geodésicas - Universidade Federal do Paraná, Curitiba-PR, 97p. 2005.

PEREIRA, M.N. Cobertura e uso da Terra através de Sensoriamento Remoto. **Dissertação de Mestrado** em Sensoriamento Remoto – Instituto Nacional de Pesquisas Espaciais. São José dos Campos, INPE, 1989. 118 p.

PINHO, C. M. D.; RENNÓ, C. D. KUX, H. Avaliação de técnicas de fusão aplicadas à imagem Quickbird. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 12., 2005, Goiânia. São José dos Campos: INPE, abr. 2005. v. 12, p. 4225 - 4232.

POHL, C., VAN GENDEREN, J.L., 1998. Multisensor image fusion in remote sensing: concepts, methods and applications. **International Journal of Remote Sensing** 19, pp. 823–854.

PONZONI, F. J., SHIMABUKURO, Y.E. **Sensoriamento Remoto no estudo da Vegetação.** São José dos Campos-SP: Parêntese. 127 p. 2007.

REITZ, R.; KLEIN, R.M. **Araucariáceas.** Flora Ilustrada Catarinense, Itajaí, 1966. 62 p.

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

RODERJAN, C. V.; GALVÃO, F.; KUNIYOSHI, Y. S.; HATSCHBACH, G. G. As unidades fitogeográficas do estado do Paraná. **Ciência & Ambiente**, Universidade Federal de Santa Maria, Santa Maria-RS, n. 24, p. 75-92, jan/jun 2002.

ROSOT, N. C. Integração de imagens de sensores de microondas e ópticos para fins de mapeamento e classificação de reflorestamentos no sul do Brasil. **Tese de Doutorado** em Engenharia de Produção. Universidade Federal de Santa Catarina-UFSC, Florianópolis-SC, 190 p. 2001.

RSI-Research Systems Inc. 2009. “**Tutorial Envi FX: Classificação por regras-segmentação orientada ao objeto**”, 15p.

SANQUETA, C.R.; TETTO, A.F. **Pinheiro-do-Paraná: lendas e realidades**. Curitiba: FUPEF do Paraná, 2000. 112p.

SANTURRI, L.; CARLÀ R.; FIORUCCI F.; AIAZZI B.; BARONTI S.; CARDINALI M.; MONDINI A. Assessment of very high resolution satellite data fusion techniques for landslide recognition. In: Wagner W., Székely, B. (eds.): **ISPRS TC VII Symposium – 100 Years ISPRS**, Vienna, Austria, 2010.

SCHNEIDER, M.J.; BELLON, O.R.P.; ARAKI, H. Experimentos em fusão de imagens de alta resolução. **Bol. Ciênc. Geod.**, séc. v. 9, n. 1, p. 75-88, Curitiba 2003.

SCHOWENGERDT, R. A. **Spectral Transforms** in: Remote Sensing: Models and Methods for Image Processing. London: Academic Press, 1997. 522p.

SCHOWENGERDT, R. A. **Techniques for Image Processing and Classification in Remote Sensing**. University of Arizona. 249p. 1983.

SHANDLEY, J.; FRANKLIN, J.; WHITE, T. Testing the Woodcock-Harward image segmentation algorithm in an area of southern California chaparral and woodland vegetation. **International Journal of Remote Sensing**, v.19, n.3, p.535-541, fev.1998.

SHIMABUKURO, Y. E.; BATISTA, G.; MELLO, E. M. K.; MOREIRA, J. C.; DUARTE, V. Using shade fraction image segmentation to evaluate deforestation in Landsat Thematic Mapper images of the Amazon region. **International Journal of Remote Sensing**, v.19, n.3, p.535-541, fev. 1998.

SILVA, E.L.S; PONZONI, F.J. Comparação entre a reflectância hemisférica de folhas e a reflectância bidirecional de um dossel. **Revista Árvore**. v.19, n.4, 1995, p.466-478.

SOUSA, A.M.O.; MESQUITA, P.; GONÇALVES, A.C.; SILVA, J.R.M. Segmentação e classificação de tipologias florestais a partir de imagens Quickbird. **Ambiência** - Revista do Centro de Ciências Agrárias e Ambientais V. 6 Edição Especial. 2010. p 57 - 66.

SOUSA, C.L. de. Avaliação de imagens-índice e de imagens-proporção para detecção de alteração no volume de madeira em florestas implantadas. **Dissertação de Mestrado** em Sensoriamento Remoto. Curso de Pós-Graduação do Instituto Nacional de Pesquisas Espaciais. São José dos Campos, 1997. 102 p.

SPRING. **Sistema de ajuda on-line.** Disponível em <file:///C:/Arquivos%20de%20programas/spring501_Port/helpport/registro.htm?versao=nclas sic a#transf_pc>. Acesso em: 6 de jun. 2010.

STEPKA, T. F. Modelagem da dinâmica e prognose da estrutura diamétrica de uma floresta ombrófila mista por meio de Matriz de Transição e Razão de Movimento. **Dissertação de Mestrado** em Ciências Florestais - Universidade Estadual do Centro Oeste- UNICENTRO, Irati, PR. 138p. 2008.

STORY, M & CONGALTON, R. Accuracy Assessment: a User's Perspective. **Photogrammetric Engineering & Remote Sensing**, Vol 52, nº3. p 379-399, 1986.

SZEKIELDA, K. **Satellite monitoring of the earth.** New York: John Wiley, 1988. 326 p.

TOUTIN, T; CHÉNIER, R.; CARBONNEAU, Y. 3D Models for high resolution images: examples with Quickbird, IKONOS, and EROS. In: ISPRS Commission IV Symposium, Joint International Symposium on Geospatial Theory, Processing and Applications. 2002, Ottawa **ANAIS**, Ottawa: ISPRS, feb. 2002. v. 34, p. 547- 551.

TSO, B., MATHER, P.M. **Classification Methods for Remotely Sensed Data.** New York: Taylor & Francis. 332 p, 2001.

VELOSO, H. P.; GÓES FILHO, L. Fitogeografia Brasileira: classificação fisionômica-ecológica da vegetação neotropical. In: PROJETO RADAM BRASIL, 1982, Salvador. **Bol. Técnico**. Série vegetação, 1.

VENANCIO, D.L. Mapeamento de *Araucaria angustifolia* utilizando DGPS e imagem de satélite Quickbird-2. **Dissertação de Mestrado** em Ciências Florestais – Universidade Estadual do Centro Oeste-UNICENTRO, Irati, PR. 64p. 2009.

VENTURA, F. N. Fusão de imagens de sensores remotos utilizando a transformação wavelet. **Dissertação de Mestrado** em Sensoriamento Remoto – Instituto Nacional de pesquisas Espaciais, São José dos Campos. 2002.

VICENTE P.P et al. **Sistemas Inteligentes : aplicações em recursos hídricos e ciências ambientais.** ABRH. UFRS. Porto Alegre . 1999.

WANG, F. Improving remote sense image analysis trough fuzzy information representation. **Photogrammetric Engineering & Remote Sensing**, vol.56, p.1163-1169. 1990.

WANG Z., ZIOU D., ARMENAKIS C., LI D., AND LI Q., 2005. A comparative analysis of image fusion methods, **IEEE Trans. Geosci. Remote Sens.**, vol. 43 (6), pp. 1391–1402.

WARNER, T. A.; LEE, J. Y.; MCGRAW, J.B. 1999. Delineation and identification of individual trees in the eastern deciduous forest. In **International Forum Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry**, Victoria, Canada, Canadian Forest Service, pp. 81-91.

WOLNIEWICZ, W.; Assessment of geometric accuracy of VHR satellite images. **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 35, n. 1, p. 19-23, Jan. 2004.

ZADEH, L. **Fuzzy Sets**. Inform. Contr. Vol 8. 338-353p. 1965.

APÊNDICE

APÊNDICE 1: Pontos utilizados na Correção da imagem Quickbird-2.

Nº	Mapa X	Mapa Y	Imagem X	Imagem Y	Predição X	Predição Y	Erro X	Erro Y	RMS
1	540980,19	7192150,05	1227,14	9971,86	1227,15	9971,71	0,01	-0,15	0,15
2	541813,67	7194324,59	2614,00	6346,71	2614,00	6346,68	0	-0,03	0,03
3	543143,90	7192439,82	4830,86	9483,86	4830,90	9483,49	0,04	-0,37	0,37
4	543656,61	7189819,17	5681,57	13852,14	5681,59	13851,95	0,02	-0,19	0,19
5	541195,53	7190542,76	1585,86	12663,57	1585,84	12663,73	-0,02	0,16	0,16
6	542004,47	7190068,75	2929,57	13448,43	2929,59	13448,20	0,02	-0,23	0,23
7	542032,84	7193138,70	2981,29	8324,86	2981,29	8324,88	0	0,02	0,02
8	541272,63	7192891,75	1711,57	8740,43	1711,56	8740,56	-0,01	0,13	0,13
9	543228,50	7190641,08	4969,71	12479,29	4969,66	12479,83	-0,05	-0,05	0,55
10	543176,57	7194221,05	4885,57	6519,00	4885,56	6519,11	-0,01	-0,01	0,11
								RMS Total	0,2155 m

APÊNDICE 2 : Pontos teste utilizados para aferir a precisão da ortorretificação

N°	Mapa X	Mapa Y	Imagem X	Imagem Y	Predição X	Predição Y	Erro X	Erro Y	RMS
1	542577,05	7193643,7	3889	7466,75	3888,92	7466,8	-0,08	0,05	0,1
2	540980,19	7192150,1	1224,25	9973,5	1224,03	9973,63	-0,22	0,13	0,26
3	542004,47	7190068,8	2927,25	13452,5	2927,62	13452,28	0,37	-0,22	0,43
4	543601,21	7192245,5	5594,25	9827,25	5594,25	9827,25	0	0	0
5	541813,67	7194324,6	2611,25	6350,5	2610,94	6350,68	-0,31	0,18	0,36
6	541060,18	7191242,7	1356,75	11489	1356,78	11488,98	0,03	0,02	0,03
7	543206,75	7189763,9	4925	13934,75	4925,01	13934,75	0,01	0	0,01
8	542112,29	7191378,9	3116,25	11257,75	3115,23	11258,36	-1,02	0,61	1,19
9	543143,9	7192439,8	4830,25	9486	4830,39	9485,92	0,14	-0,08	0,16
10	541757,99	7192877,7	2524,25	8757,25	2525,34	8756,6	1,09	-0,65	1,27
RMS Total									0,4233 m