

MÁRIO SEBASTIÃO TUZINE

**MAPEAMENTO DA COBERTURA E USO DA TERRA A PARTIR DE IMAGENS
IKONOS NA FLORESTA DE INHAMACARI, PROVÍNCIA DE MANICA -
MOÇAMBIQUE**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Florestal, área de concentração de Manejo Florestal, Setor de Ciências Agrárias da Universidade Federal do Paraná, como requisito parcial à obtenção do título de “Mestre em Engenharia Florestal”.

Orientador:
Prof. Dr. Nelson Carlos Rosot

Co-orientadora:
Dr^a Maria Augusta Doetzer Rosot

CURITIBA
PARANÁ- BRASIL
2011

Ficha catalográfica elaborada por Deize C. Kryczyk Gonçalves – CRB 1269/PR

Tuzine, Mário Sebastião

Mapeamento da cobertura e uso da terra a partir de imagens ikonos na floresta de Inhamacari, Província de Manica - Moçambique / Mário Sebastião Tuzine -2011.

80 fls. : il.

Orientador: Prof. Dr. Nelson Carlos Rosot

Co-orientadora: Prof.^a Dr.^a Maria Augusta Doetzer Rosot

Dissertação (mestrado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal.

Defesa: Curitiba, 23/02/2011

Inclui bibliografia

Área de concentração: Manejo florestal

1. Sensoriamento remoto – Moçambique. 2. Solos – Uso – Sensoriamento remoto. 3. Ikonos II (Satélites). 4. Teses. I. Rosot, Nelson Carlos. II. Rosot, Maria Augusta Doetzer. III. Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. IV. Título.

CDD – 621.367 8
CDU – 634.0.587.7(680)

DEDICATÓRIA

À minha Deusa Tima Abdul Remane Tuzine,
ao meu filho querido Cleyber Wayney Rooney Tuzine,
à minha mãe Maria Enoque Tovela,
em memória do meu pai Sebastião Zicuimane Tuzine,
aos meus irmãos Antonio e Milagre Sebastião Tuzine.

Dedico

AGRADECIMENTOS

Ao Orientador Professor Nelson Carlos Rosot, pela dedicação, interesse e sempre pronta disponibilidade na orientação deste trabalho.

Aos professores Jorge Antonio Silva Centeno e Maria Augusta Doetzer Rosot pela amizade, contribuição e ajuda na realização deste trabalho.

Ao Ministério das Relações Exteriores do Brasil (MRE) e Agência Brasileira de Cooperação (ABC) **mapa** projecto - BRA/04/044 sub-projecto - S162 pela disponibilização das imagens IKONOS

Ao MTC-Moçambique e CNPq pela concessão da bolsa de estudos, Assim como ao ISPG por me ter permitido sair para fazer o mestrado.

Ao Programa de Pós-Graduação em Engenharia Florestal da Universidade Federal do Paraná, pela oportunidade de aprimoramento técnico-científico através da realização deste curso.

A engenheira Naissa da Luz pela ajuda na utilização do software ecognition.

Aos colegas Alberto Manhiça, Miguel Jacob Bila, Hecrálito Constantino Mucavele, Cláudio João Cuaranhua, Horácia Celina Mula, Clemência Chitsondzo, Nocy Bila, Miguel Muguio, Ruben Taibo, João Batista Tavares, Alan e Ronan.

Aos professores e funcionários do Programa de Engenharia Florestal da UFPR.

SUMÁRIO

DEDICATÓRIA.....	i
AGRADECIMENTOS	ii
SUMÁRIO.....	iii
LISTA DE TABELAS	v
LISTA DE FIGURAS	vi
RESUMO.....	viii
ABSTRACT	ix
1. INTRODUÇÃO	1
1.1. OBJETIVO	2
1.2. OBJETIVOS ESPECÍFICOS.....	3
2. REVISÃO DE LITERATURA	4
2.1. SENSORIAMENTO REMOTO.....	4
2.1.1. Resolução espacial	4
2.1.2. Resolução espectral.....	6
2.1.3. Resolução Radiométrica	7
2.1.4. Resolução temporal	8
2.2. RESPOSTA ESPECTRAL.....	8
2.2.1. Vegetação	8
2.2.2. Água.....	11
2.2.3. Solos	11
2.3. SENSORES ORBITAIS	13
2.3. 1. IKONOS II	15
2.4. UTILIZAÇÃO DE IMAGENS LANDSAT E IKONOS II.....	16
2.5. PRÉ-PROCESSAMENTO DAS IMAGENS.....	18
2.5.1. Realce	18
2.5.2. Filtros	18
2.5.3. Correção geométrica.....	19
2.6. PROCESSAMENTO DAS IMAGENS.....	22
2.6.1. Segmentação	22
2.6.2. Segmentação multi-resolução e classificação baseada no objeto	22
2.6.3. Classificação	27
2.6.4. Classificação através de lógica <i>fuzzy</i>	27
2.6.5. Descritores da classificação.....	29
2.6.6. Avaliação da classificação	31
3 MATERIAIS E MÉTODOS.....	36
3.1. A ÁREA DE ESTUDO.....	36
3.1.1. Clima	37
3.1.2. Relevo e solos.....	38

3.1.3. Vegetação	38
3.2. MATERIAIS	40
3.2.1. Cartas e Mapas	40
3.2.2. Imagens de satélite Ikonos II.....	41
3.3. MÉTODOS.....	41
3.3.1. Pré-processamento	41
3.3.2. Processamento	42
3.3.2.1. Segmentação	42
3.3.2.2. Classificação via vizinho mais próximo no eCognition	43
3.3.2.3. A classificação <i>Fuzzy</i>	44
3.3.2.4. Classes da classificação	45
3.3.3. Avaliação da classificação	52
4. RESULTADOS E DISCUSSÕES	54
4.1. CORREÇÃO GEOMÉTRICA	54
4.2. SEGMENTAÇÃO	54
4.2.1. Segmentação de nível 1.....	54
4.2.2. Segmentação de nível 2.....	56
4.2.3. Segmentação de nível 3.....	57
4.3. CLASSIFICAÇÃO	58
4.3.1. Quantificação das áreas.....	63
4.3.2. Avaliação da classificação	66
5. CONCLUSÕES E RECOMENDAÇÕES.....	73
REFERÊNCIAS BIBLIOGRÁFICAS	74

LISTA DE TABELAS

TABELA 1- RESOLUÇÃO ESPACIAL DE ALGUNS SATÉLITES.....	6
TABELA 2 - ESPECIFICAÇÕES TÉCNICAS DO SATÉLITE IKONOS II.....	16
TABELA 3 - RELAÇÃO ENTRE OS VALORES DE ÍNDICE KAPPA E O DESEMPENHO DA CLASSIFICAÇÃO	35
TABELA 4 - ARRANJOS DOS NÍVEIS PARA A SEGMENTAÇÃO.....	42
TABELA 5 - ÁREAS OCUPADAS PELOS DIFERENTES TIPOS DE USO DE SOLO E COBERTURA	63
TABELA 6 - MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO PELO VIZINHO MAIS PRÓXIMO E LÓGICA FUZZY PARA NÍVEL 1 DE CLASSIFICAÇÃO	67
TABELA 7 - MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO PELO VIZINHO MAIS PRÓXIMO E LÓGICA FUZZY PARA NÍVEL 2 DE CLASSIFICAÇÃO	68
TABELA 8 - MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO PELO VIZINHO MAIS PRÓXIMO E LÓGICA FUZZY PARA NÍVEL 3 DE CLASSIFICAÇÃO	69
TABELA 9 - ACURÁCIA DO PRODUTOR E DO USUÁRIO PARA A CLASSIFICAÇÃO DO NÍVEL 1 DE SEGMENTAÇÃO	70
TABELA 10 - ACURÁCIA DO PRODUTOR E DO USUÁRIO PARA A CLASSIFICAÇÃO DO NÍVEL 2 DE SEGMENTAÇÃO	71
TABELA 11 - ACURÁCIA DO PRODUTOR E DO USUÁRIO PARA A CLASSIFICAÇÃO DO NÍVEL 3 DE SEGMENTAÇÃO	71

LISTA DE FIGURAS

FIGURA 1- CURVAS DE EFEITO DE PIGMENTOS E ÁGUA NA CURVA DE REFLECTÂNCIA DE UMA FOLHA	9
FIGURA 2- EFEITO DE TEOR DE UMIDADE NA CURVA DE REFLECTÂNCIA DA FOLHA	10
FIGURA 3- EFEITO DO TEOR DE UMIDADE NA CURVA DE REFLECTÂNCIA DE UM SOLO SILTOSO	13
FIGURA 4 - REPRESENTAÇÕES DE FUNÇÕES LINEARES DE CONJUNTOS FUZZY.....	29
FIGURA 5 - REPRESENTAÇÕES DE FUNÇÕES SIGMOIDAIIS DE CONJUNTOS FUZZY.....	29
FIGURA 6 - LOCALIZAÇÃO GEOGRÁFICA DA ÁREA DE ESTUDO EM MOCAMBIQUE	36
FIGURA 7 - CLASSE DE REFLORESTAMENTO DE PINUS	46
FIGURA 8 - CLASSE DE REFLORESTAMENTO DE EUCALIPTO.....	47
FIGURA 9 - CLASSE DE SOLO.....	48
FIGURA 10 - CLASSE DE AGRICULTURA E CAPIM	49
FIGURA 11 - CLASSE DE MATAGAIS	50
FIGURA 12 - CLASSE DA VEGETAÇÃO NATIVA	51
FIGURA 13 - AMOSTRAS (CENTRÓIDES DAS CLASSES - INTERPRETAÇÃO VISUAL)	53
FIGURA 14 - SEGMENTACAO DE NIVEL 1 FATOR DE ESCALA 40, FATOR DE COR 0,8 FATOR DE FORMA 0,2 COM SUAVIDADE A 0,5 COMPACIDADE DE 0,5.	55
FIGURA 15 - SEGMENTACAO DE NIVEL 2 FATOR DE ESCALA 80, FATOR DE COR 0,8 FATOR DE FORMA 0,2 COM SUAVIDADE A 0,5 COMPACIDADE DE 0,5.	57
FIGURA 16 - SEGMENTACAO DE NIVEL 3 FATOR DE ESCALA 120 , FATOR DE COR 0,8 FATOR DE FORMA 0,2 COM SUAVIDADE A 0,5 COMPACIDADE DE 0,5.	58
FIGURA 17 - IMAGEM DA CLASSIFICAÇÃO DA SEGMENTAÇÃO DO NÍVEL 1 ...	60

FIGURA 18 - IMAGEM DA CLASSIFICAÇÃO DA SEGMENTAÇÃO DO NÍVEL 2. ...	61
FIGURA 19 - IMAGEM DA CLASSIFICAÇÃO DA SEGMENTAÇÃO DO NÍVEL 3. ...	62
FIGURA 20 - ÁREAS OCUPADAS POR CADA CLASSE DE USO E COBERTURA EM CADA NÍVEL RESULTANTE DA CLASSIFICAÇÃO.	65

RESUMO

Um programa de desenvolvimento florestal deve conter um estudo detalhado sobre a ocupação e uso da terra para subsidiar a elaboração de um plano de manejo florestal sustentado que contemple os aspectos sociais, econômicos e ecológicos. No plano de manejo, a análise do uso e cobertura da terra através de dados de sensoriamento remoto, com imagens de alta resolução espacial, permite planejar uma ocupação mais ordenada e racional do meio físico e também monitorar a forma de exploração dos recursos naturais. Este estudo teve como objetivos: avaliar limiares de segmentação no mapeamento, identificar tipologias florestais, quantificar o uso e cobertura da terra e avaliar a classificação efetuada. A área estudada localiza-se no posto administrativo de Machipanda no distrito de Manica província de Manica em Moçambique. Foi utilizada uma imagem IKONOS II fusionada para 1 m de resolução espacial com segmentação em três níveis: 40 nível 1, 80 nível 2 e 120 nível 3 para fator de escala, repetindo-se para cada nível os valores 0,8 para a cor, 0,2 para a forma, 0,5 de suavidade e 0,5 de compacidade. A classificação foi realizada simultaneamente pelo vizinho mais próximo e pela lógica *fuzzy*. Foram identificadas 6 tipologias florestais de uso e cobertura da terra: agricultura e capim, eucalipto, matagal, pinus, vegetação nativa e solo. A melhor classificação, com segmentação de nível 2, resultou em 85,139 ha para vegetação nativa, agricultura e capim 302,856 ha, matagais 184,579 ha. Pinus e eucalipto ocupam 20,3% da área total sendo 136,553 ha com pinus e 101,759 ha com eucaliptos. Na avaliação da classificação obteve-se uma acurácia global de 55,5% e um valor do índice *Kappa* de 0,46 para o nível 1; 76,6% e 0,71 para o nível 2; 61,5% e 0,53 para o nível 3 respectivamente. A melhor classificação foi alcançada com o nível 2 de segmentação, com 80 para o fator de escala, 0,8 fator de cor e 0,2 fator de forma.

Palavras chaves: Sensoriamento remoto, imagens de alta resolução, segmentação, Mapeamento, classificação e uso da cobertura da terra e imagens Ikonos.

ABSTRACT

Towards an excellent classification of forestry typologies, it is necessary as a prerequisite a better segmentation, thus the objectives of the study were to evaluate thresholding thresholds, identify forestry typologies, quantify mulching and evaluate the classification. The study took place in a location called Machipanda in the district of Manica, province of Manica in Mozambique. For this study it was used an IKONOS II spatially image enhanced to 1 m spatial resolution. Three levels of segmentation were generated 40 level 1; 80 level 2 and 120 level 3 for the scale factor and was repeated for each level using the following values 0.8 for colour, 0.2 for the form, 0.5 of softness and 0.5 of compactness. The classification was done using simultaneously the nearest neighbour and fuzzy logic. The study resulted in identification of 6 typologies of forestry and soil use and coverage, agriculture and grass, Eucalyptus, scrub, Pinus, native vegetation and soil. The occupied areas with better classification level (level 2) was 85.139 ha of native vegetation, agriculture and grass 302.856 ha, 184.579 ha of scrubs, with pinus and eucalyptus occupying 20.3% of the total area being pinus with 136.553 and 101.759 ha of eucalyptus. The evaluation of the classification resulted in a global accuracy of 55.5% and Kappa index value of 0.46 on classification of level 1; global accuracy of 76.6% and a Kappa index value of 0.71 for level 2 and global accuracy of 61.5% with a Kappa index value of 0.53 for level 3. Classification of level 40 and 120 had good performance and the level of 80 very good performance. The best combination for mapping was level 2.

Keywords: Remote sensing, high-resolution images, spectral segmentation mapping, classification and use and soil coverage IKONOS II.

1. INTRODUÇÃO

Cerca de 70% do território moçambicano encontra-se coberto por alguma forma de vegetação lenhosa natural ou semi-natural, dos quais cerca de 51% são florestas definidas nas classes de florestas densas sempre verde, florestas densas decíduas, florestas abertas, florestas abertas decíduas, mais florestas abertas em áreas regularmente inundadas. Adicionalmente, 19% são ocupados por outras formações lenhosas tais como matagais, áreas arbustivas, arbustos em áreas úmidas e mosaicos de florestas com agricultura itinerante (MARZOLI, 2008).

Atividades como o manejo florestal sustentável e outras decisões como plantios e tratamentos silvicultural (desbastes e podas) dependem de um perfeito mapeamento de uso e cobertura da terra. Assim, o conhecimento da ocupação do solo e da sua localização em uma determinada região fornece elementos para o planejamento de uso ambiental e de extração de recursos naturais visando à melhoria da qualidade de vida da população.

A análise do uso e cobertura da terra, mediante informações de Sensoriamento Remoto, constitui uma estratégia de grande utilidade ao planejamento e administração da ocupação ordenada e racional do meio físico, além de possibilitar avaliar e monitorar a preservação de áreas de vegetação natural (SOUSA *et al.* 2010).

A floresta de Inhamacari já passou por vários proprietários, desde o governo da Rodésia (atual Zimbábwe), depois IFLOMA (Indústria Florestal de Manica) e atualmente pertence a Faculdade de Agronomia e Engenharia Florestal (FAEF) da Universidade Eduardo Mondlane (UEM) em nível de departamento, denominando-se Centro Florestal de Machipanda – CEFLOMA. Durante este percurso, o uso e a cobertura foram modificados segundo os objetivos de cada proprietário, assim, o CEFLOMA, em colaboração com a Universidade Federal de Paraná (UFPR) estão a desenvolver as bases para um manejo sustentado adequado para a floresta.

A floresta de Inhamacari possuía 468,95 ha dos quais 263,10 ha eram usadas por plantações e 184,15 ha eram ocupados por vegetação natural e outros 21,70 ha não discriminados. (DEF,1999; PEREIRA, 1998 e CHAMBA, 1994). Tais autores

destacaram também a existência de seis tipos principais de ocupação de terra para esta floresta, sendo nomeadamente Eucaliptos, Pinus, mata nativa, mistura de Pinus e mata nativa, mistura de Pinus com Eucaliptos e áreas queimadas com árvores dispersas.

Considerando-se aspectos ligados ao mapeamento de uso de terra, a segmentação e a classificação são ferramentas que possibilitam a extração rápida e eficiente de informações relacionadas às tipologias, bastando para tal o conhecimento prévio das características espectrais e de forma dos objetos. Contudo, os alvos vegetais não possuem forma pré-definida e são espacialmente de difícil estruturação. Assim a informação espectral surge como alternativa para detecção e classificação da tipologia florestal.

O crescimento de regiões é uma técnica de agrupamento de dados, na qual podem ser agrupadas somente as regiões adjacentes espacialmente. O processo calcula um critério de dissimilaridade para cada par de regiões adjacentes, baseado num teste de hipótese estatístico que testa a média entre as regiões. A seguir, o procedimento divide a imagem em um conjunto de subimagens e então, realiza a união entre elas, segundo um limiar de agregação previamente definido.

A ferramenta importante na segmentação é o “parâmetro de escala” que é o resultado da uniformidade espectral e espacial das regiões. O parâmetro de escala é uma medida que define a máxima mudança em heterogeneidade que pode ocorrer quando duas regiões são agrupadas na imagem, sendo indiretamente responsável pelo tamanho médio dos segmentos formados na imagem.

Neste contexto, as imagens de satélite constituem-se em uma importante ferramenta, como fonte de dados espaço-temporais, permitindo análises das mudanças ocorridas no uso do solo, ou seja, na forma como o espaço está sendo utilizado pelo Homem.

1.1. OBJETIVO

Contribuir no mapeamento de uso e cobertura da terra com o uso da tecnologia de sensoriamento remoto como uma fonte de dados eficaz no mapeamento do posto administrativo de Machipanda especificamente a floresta de Inhamacari.

1.2. OBJETIVOS ESPECÍFICOS

Os objetivos específicos foram os seguintes:

- Avaliar limiares de segmentação de imagens Ikonos;
- Identificar tipologias florestais;
- Quantificar a cobertura vegetal de diferentes tipos de uso;
- Comparar as diferentes formas de uso e cobertura da terra na região de Inhamacari;
- Gerar mapas de uso e cobertura da terra;
- Avaliar a classificação.

2. REVISÃO DE LITERATURA

2.1. SENSORIAMENTO REMOTO

Sensoriamento Remoto (SR) é a utilização conjunta de sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados, aeronaves, espaçonaves etc., com o objetivo de estudar o ambiente terrestre através do registro e da análise das interações entre a radiação eletromagnética e as substâncias componentes do planeta Terra e as suas mais diversas manifestações (NOVO, 1998).

Segundo MOREIRA (2001) os equipamentos que medem a radiação eletromagnética são genericamente chamados de radiômetros e podem ser classificados em não imageadores, aqueles que medem a radiância do alvo e apresentam os dados em forma de gráfico ou como dados numéricos, e os radiômetros imageadores, cujo resultado final é uma imagem de uma área de terreno.

A diversidade de aplicações do sensoriamento remoto faz com que um número cada vez maior de pesquisadores de diferentes áreas do conhecimento utilize essa ferramenta. Uma das principais vantagens dessa técnica com relação aos estudos ambientais é ela permitir a análise de grandes, em imageamentos contínuos e em intervalos regulares, permitindo a obtenção de dados multiespectrais, multitemporais e em diferentes resoluções espaciais (KOFFER, 1992).

As imagens podem ser consideradas sob vários tipos de resolução, destacando-se a resolução espacial, espectral, radiométrica e temporal.

2.1.1. Resolução espacial

O conhecimento das variáveis que determinam a resolução espacial de um sistema é importante na avaliação da viabilidade do uso de um dado sensor. Resolução espacial pode ser definida como a distância mínima de separação necessária entre dois alvos para que os mesmos possam ser diferenciados individualmente.

A resolução espacial refere-se ainda à habilidade do sistema sensor em distinguir e medir os alvos. Esta habilidade baseia-se na projeção geométrica do detector na superfície terrestre, definindo a sua área do campo de visada do instrumento numa certa altitude e num determinado instante. Os sensores heliosíncronos têm uma altitude fixa com relação à superfície terrestre, que corresponde ao tamanho da unidade mínima de informação da imagem, denominada de pixel (*picture element*, em inglês), ou “dot”, como é conhecido na engenharia civil (VINCENT *et al*, 1996, CENTENO 2009).

A resolução espacial é definida pela capacidade do sistema sensor em "enxergar" objetos na superfície terrestre; quanto menor o objeto possível de ser visto, maior a resolução espacial. O ângulo definido por esta projeção é denominado de campo de visada instantânea (*Instantaneous Field Of View*, IFOV). O IFOV define a área do terreno focalizada a uma dada altitude pelo instrumento sensor. A maneira mais comum de se determinar a resolução espacial de um sensor é pelo seu campo instantâneo de visada ou IFOV. Este campo é determinado pelas propriedades geométricas do sistema sensor e define a área do terreno imageado que é "vista" pelo instrumento sensor a uma dada altitude e a um dado momento. O IFOV é medido pelas dimensões da área vista no terreno e, de uma forma simplificada, ele representa o tamanho do pixel. Deve ser mencionado que o IFOV, e conseqüentemente a resolução espacial, é um conceito teórico, visto que existem variações na altitude da órbita dos satélites que provocam mudanças no IFOV (mas não no tamanho do pixel, que é fixo e é determinado pelo intervalo de amostragem do sinal recebido pelo sensor) (CROSTA, 1993 e CENTENO, 2009).

O sistema sensor tem a capacidade de cobrir uma linha de largura L , sendo que cada detector é responsável pela medição da energia num pequeno trecho desta linha. Assim cada pixel na imagem é obtido por um detector do arranjo linear. A energia refletida por todos os objetos presentes dentro desta unidade de área no terreno é ponderada e um único valor é registrado. Este valor corresponde à refletância média nesta unidade de área. Quando a unidade de área é muito grande os detalhes são perdidos, pois vários objetos são fundidos dentro do mesmo pixel (CENTENO, 2009).

A tabela 1 ilustra a resolução espacial de alguns sensores variando a sua resolução entre altíssima alta e moderada resolução espacial.

TABELA 1- RESOLUÇÃO ESPACIAL DE ALGUNS SATÉLITES

Resolução	satélites	Sensores e ou banda	Resolução espacial (m)
Altíssima	GEOEYE-1	Visível e infravermelho próximo	1,64
		Pancromático	0,41
	IKonos	Visível e Infravermelho próximo	4
		Pancromática	1
	Quick Bird	Visível e infravermelho próximo	2,8
		Pancromático	0,7
alta	Spot 5	HRV mono e HRG multi	10 e 20
		HRV Pancromática	5
moderada	CBERS	WFI	260
		IR-MSS	80 e 160
		CCD	20
	Landsat	MSS	70
		TM	30
		Pancromático	15

2.1.2. Resolução espectral

Segundo NOVO (1993) resolução espectral é “uma medida da largura das faixas espectrais e da sensibilidade do sistema sensor em distinguir entre dois níveis de intensidade do sinal de retorno”. Para melhor compreender este conceito destacam-se dois pontos importantes: o comprimento de onda detectado pelo sensor e a quantidade de faixas espectrais.

A resolução espectral está associada ao número de faixas e à largura das faixas espectrais nas quais a radiação eletromagnética é medida. As faixas espectrais correspondem aos intervalos de comprimento de onda nos quais os sistemas de sensor operam. Quanto maior o número de faixas e menor a largura delas maior é a capacidade do sistema de registrar diferenças espectrais. A resolução espectral de uma imagem aumenta com o número de bandas e a redução da largura destas bandas (CROSTA, 1993).

A resolução espectral é muito importantes no sensoriamento remoto porque a partir delas podem-se distinguir diversos alvos, como corpos de água na porção visível, os picos de absorção dos pigmentos de vegetação na porção do infravermelho. As imagens pancromáticas geralmente são obtidas medindo-se a radiação refletida ao longo de toda a região do visível e do infravermelho próximo.

2.1.3. Resolução Radiométrica

A “resolução radiométrica” representa a menor diferença de brilho que um sistema sensor é capaz de perceber, determinando se o alvo pode ser visto na imagem em função de seu contraste com alvos vizinhos. Está relacionada ao número de níveis de cinza usados para expressar os dados coletados pelo sensor, considerando que, quanto maior o nível de cinza, maior a resolução radiométrica, (SILVA, 1995).

A resolução radiométrica é dada pelo número de níveis digitais, representando níveis de cinza usados para expressar os dados coletados pelo sensor. Para entender melhor esse conceito, pensemos numa imagem com apenas 2 níveis (branco e preto) em comparação com uma imagem com 32 níveis de cinza entre o branco e o preto; obviamente a quantidade de detalhes perceptíveis na segunda será maior do que na primeira e portanto a segunda imagem terá uma melhor resolução radiométrica. O número de níveis é comumente expresso em função do número de dígitos binários (bits) necessários para armazenar em forma digital o valor do nível máximo. O valor em bits é sempre uma potência do número 2; desse modo, "6 bits" quer dizer $2^6 = 64$ níveis. Os sistemas sensores mais comuns, dos satélites LANDSAT e SPOT, possuem resolução radiométrica variando entre 6 e 8 bits, o que significa de 64 a 256 níveis de cinza. O sistema visual humano não é muito sensível a variações em intensidade, de tal modo que dificilmente são percebidos mais do que 30 diferentes tons de cinza numa imagem. O computador, por sua vez, consegue diferenciar qualquer quantidade de níveis, razão pela qual se torna importante ter imagens de alta resolução radiométrica. (CROSTA, 1993; CENTENO, 2009; SILVA, 1995 E NOVO, 1993).

2.1.4. Resolução temporal

A resolução temporal se refere ao intervalo de tempo em dias ou horas, que o sistema demora para obter duas imagens consecutivas da mesma região sobre a terra. Quanto maior for o intervalo de tempo, menor é a resolução temporal.

A resolução temporal é também conhecida como tempo de revisita e depende das características da órbita do satélite. Os sensores orbitais descrevem órbitas em torno da terra e sobrevoam o mesmo ponto em intervalos de tempo fixo. Porém, sensores com capacidade de imageamento com visada lateral ou off-nadir, podem aumentar o tempo de revisita, nominalmente estabelecido pela órbita do satélite para imageamento no nadir. No entanto alguns têm capacidade de orientar seus sensores em diferentes direções, tornando possível obter dados de uma região quando a plataforma sobrevoa uma órbita vizinha. Assim sendo, a resolução temporal deste tipo de sistema pode ser menor que o tempo entre as duas passagens sucessivas acima do mesmo ponto. (CROSTA, 1993; CENTENO, 2003).

A resolução temporal é de fundamental importância quando se pretende monitorar processos dinâmicos como, por exemplo: a ocorrência de incêndios ou queimadas em reservas florestais, derramamento de óleo no oceano, mudanças fenológicas de culturas e o crescimento de uma cidade.

2.2. RESPOSTA ESPECTRAL

2.2.1. Vegetação

A folha é o principal elemento a ser estudado no processo de interação da energia eletromagnética com a vegetação. O comportamento espectral de uma folha é função de sua composição, morfologia e estrutura interna.

Quando o alvo de interesse é a vegetação, as folhas são os elementos que mais contribuem para o sinal detectado pelos sensores contribuindo em maior parte com os comprimentos de ondas que serão absorvidos pelos sistemas sensores (JACKSON e HUETE, 1991). O comportamento espectral característico de uma folha varia conforme o comprimento de onda proveniente dos raios solares que incidem sobre uma mesma região. Tal região, compreendida entre 400nm e

2600nm, pode ser dividida em três faixas: visível (400nm a 700nm), infravermelho próximo (700nm a 1300nm) e infravermelho médio (1300nm a 2600nm) na região do visível, a maior parte da radiação incidente é absorvida pelos pigmentos presentes nas folhas. O comportamento espectral da vegetação está relacionado com a presença de pigmentos, pela presença da água e pela estrutura do mesófilo das folhas (GATES, 1980). Os pigmentos (clorofilas a e b, carotenos e xantofilas), absorvem a energia solar radiante nesta faixa de comprimento de onda, e a convertem em calor, fluorescência ou em energia estocada através da fotossíntese (GATES et al., 1965; PONZONI e SHIMABUKURO, 2009). A curva de refletância da folha verde sadia apresenta duas bandas de absorção bem marcadas, centradas em 0,45 μm , região do azul, e 0,65 μm , região do vermelho (GUYOT et al., 1989), permitindo um pico de refletância em aproximadamente 0,54 μm , região do verde, (SWAIN E DAVIS, 1978).




FIGURA 1- CURVAS DE EFEITO DE PIGMENTOS E ÁGUA NA CURVA DE REFLECTÂNCIA DE UMA FOLHA

FONTE: Adaptada de Moreira 2001

A região do infravermelho próximo é caracterizada pela alta refletância e pela baixa absorção causadas pela ausência de substâncias que absorvem a radiação neste comprimento de onda e também decorrentes do espalhamento interno causado pela estrutura interna da folha (GATES et al., 1965), de forma que quanto mais lacunosa for a estrutura interna, maior o brilho nesta faixa de comprimento de onda. Na região

do infravermelho médio o conteúdo de água nos tecidos é o principal condicionante no comportamento espectral, com forte absorção ocorrendo em 1,45; 1,95 e 2,7 μ m, causando picos de refletância entre as regiões de absorção, aproximadamente em 1,65 e 2,2 μ m.

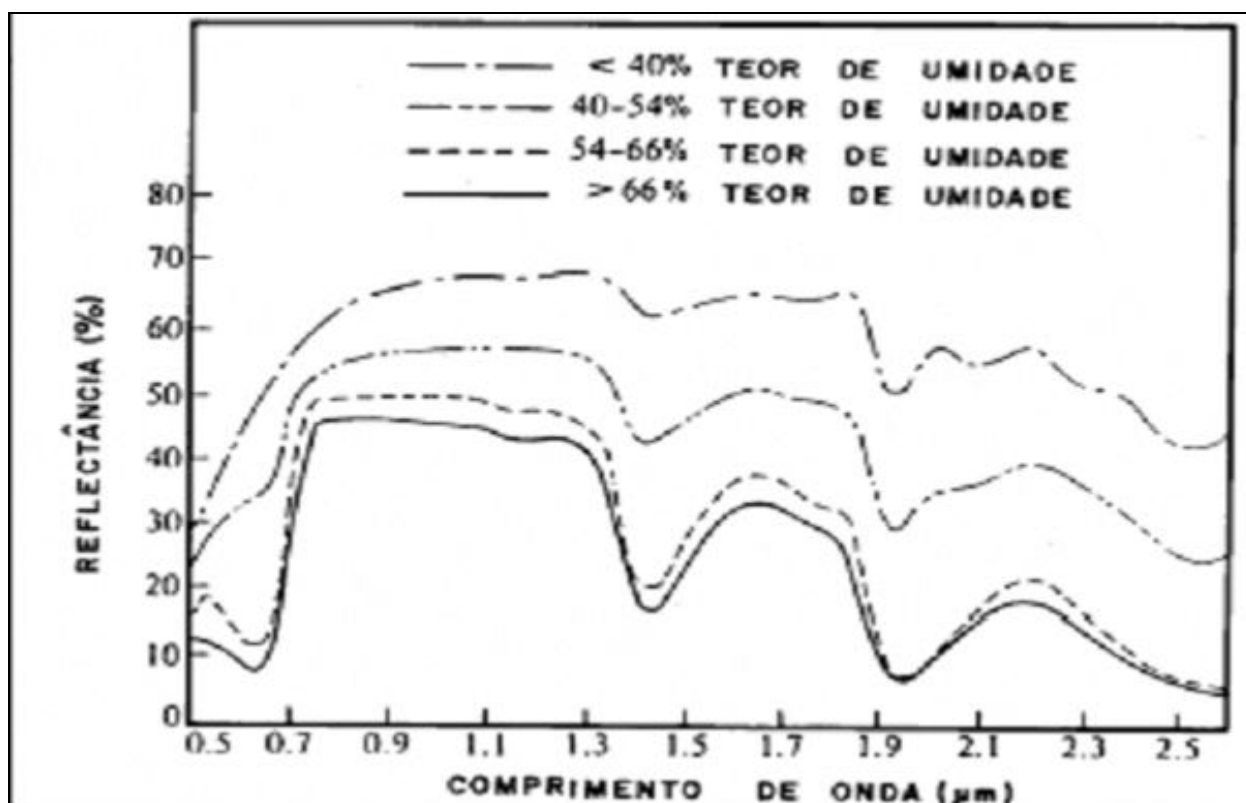


FIGURA 2- EFEITO DE TEOR DE UMIDADE NA CURVA DE REFLECTÂNCIA DA FOLHA

Fonte: adaptada de SWAIN e DAVIS (1978)

Além disso, a refletância espectral de folhas isoladas é superior àquela dos dosséis dos quais estas fazem parte, ocasionado por um maior sombreamento (PONZONI e SHIMABUKURO, 2009).

Na região do infravermelho médio, a refletância da vegetação sofre um decréscimo dos valores da energia refletida, devido principalmente ao conteúdo de água presente na folha (GUYOT, 1990), estando a refletância relacionada inversamente com a quantidade total de água (BAUER e STEINNOCHER, 2001).

2.2.2. Água

A água apresenta alta absorvância, ou seja, absorve grande parte da energia eletromagnética incidente. A curva de refletância típica da água é baixa, estando entre 0,38 e 0,7 μm (*região do visível*). A água absorve toda energia solar incidente em comprimentos de onda superiores a 0,7 μm (*região do infravermelho*).

A curva de refletância da água, assim como do solo é mais simples que a de vegetação. Na região do visível, o comportamento espectral da água é mais complexo. Os valores de refletância são baixos (menos de 10%) e são influenciados pela ondulação de sua superfície, pelo material em suspensão e do fundo e pela concentração de clorofila (RICHARDS, 1993; HOFFER, 1978; LILLESAND E KIEFER, 2000).

Na realidade é difícil encontrar água totalmente pura na natureza. Os corpos de água geralmente contem outros elementos dissolvidos ou em suspensão, que alteram a sua resposta espectral. Estes elementos podem causar absorção de energia ou espalhamento. Quanto mais turva for à água, em decorrência da presença de materiais em suspensão, maiores serão seus valores de refletância isto é, a turbidez da água aumenta a refletância de corpos de água. A refletância é linearmente proporcional a turbidez entre 0,5 a 0,7 μm (*região do visível*). (HOFFER, 1978; CENTENO 2003). O aumento na concentração de clorofila diminui a refletância na região do azul e aumenta na região do verde, e até no vermelho, podendo-se monitorar a presença e estimar a concentração de algas, pois a presença de clorofila é um índice de produção primária e eutrofização do corpo de água devido a presença de algas

2.2.3. Solos

O perfil das curvas de refletância espectral dos solos é menos complexo que as curvas da vegetação, tendo como característica mais marcante os valores crescentes de refletância com o aumento do comprimento de onda. O solo é uma mistura complexa de materiais que afetam suas propriedades espectrais. Diferentes tipos de solos possuem suas curvas típicas com formatos semelhantes, mas com

diferenças na amplitude, devido às suas características como: conteúdo de água, quantidade de matéria orgânica e de óxido de ferro, granulométrica e textura (HOFFER, 1978; LILLESAND E KIEFER, 2000). Estes fatores são muito variáveis tornando sua interpretação complexa (LILLESAND E KIEFER, 2000).

A textura do solo é determinada pelas proporções de argila, silte e areia. Os solos argilosos são compostos por partículas muito pequenas, conseqüentemente com poucos espaços livres, resultando em um solo mais compacto. Já nos solos arenosos, onde as partículas são maiores, os espaços entre elas são grandes, permitindo maior quantidade de ar ou de água. Nos solos argilosos, pelos espaços serem menores, a água não é drenada, nem evaporada tão rapidamente quanto nos solos arenosos. Assim, quanto maior o conteúdo de água, menor a refletância, principalmente nas bandas de absorção da água, e quanto mais fina a textura, maior é a refletância (LILLESAND E KIEFER, 2000).

A curva de solo apresenta poucas bandas de absorção (LILLESAND E KIEFER, 2000), sendo três de absorção pela água em $1,4\mu\text{m}$, $1,9\mu\text{m}$ e $2,7\mu\text{m}$ (as mesmas da vegetação), quase invisíveis em solos secos, e duas bandas de absorção por hidroxilas em $1,4\mu\text{m}$ e $2,2\mu\text{m}$, presentes nos solos argilosos (RICHARDS, 1993).

Na porção do visível, o aumento da quantidade de água causa uma diminuição na refletância, que explica o fato dos solos escurecerem ao serem molhados. Nas regiões do infravermelho próximo e médio, a diminuição da refletância com o aumento do conteúdo de água deve-se a baixa refletância da água nestes comprimentos de onda (LILLESAND E KIEFER, 2000).




FIGURA 3- EFEITO DO TEOR DE UMIDADE NA CURVA DE REFLECTÂNCIA DE UM SOLO SILTEOSO

FONTE: Adaptada de SWAIN E DAVIS (1978)

2.3. SENSORES ORBITAIS

As cenas coletadas pelos sensores podem ser imageadas pelas diferentes categorias de satélite tais como: militares, científicos e meteorológicos entre outros. Os sensores utilizados em nível orbital estão geralmente voltados para os estudos dos recursos naturais e operam em diferentes números de bandas, diferentes larguras da faixa espectral e diferentes resoluções espaciais, (MOREIRA 2005). Segundo o autor existem três categorias de sensores, os de baixa, alta e altíssima resolução, onde estão incluídos o IKONOS II, o QUICKBIRD e o GEOEYE-1, que a literatura, freqüentemente reporta-os como sendo satélites de alta resolução.

Um sistema sensor pode ser definido como qualquer equipamento capaz de transformar alguma forma de energia em um sinal passível de ser convertido em informação sobre o ambiente. No caso específico do sensoriamento remoto a energia utilizada é a radiação eletromagnética (NOVO 1993).

Há dois conceitos relevantes no contexto da captura de imagens de sensoriamento remoto: o sistema sensor e a plataforma.

A plataforma é o elemento de suporte usado como base para o sistema sensor encarregado do transporte do mesmo até a posição mais adequada para o registro dos dados. Aviões e satélites são exemplos de plataformas, localizando-se a grande altura acima da superfície da Terra. As plataformas podem ser terrestres – quando se deslocam na superfície do terreno, aéreas – quando o sensor é transportado a bordo de uma aeronave ou espaciais – quando o sensor é transportado a bordo de satélites ou transportadores espaciais em órbita em torno da Terra (CENTENO, 2003).

O sistema sensor é o elemento encarregado de medir a radiação eletromagnética, podendo gerar um valor digital ou um produto analógico. Podem ser classificados segundo diferentes características: ativos ou passivos, quanto à energia radiante, podendo a energia registrada ser proveniente de fonte natural ou não; imageadores ou não-imageadores, segundo o tipo de produto gerado, existindo sensores que efetuam apenas medições de energia refletida pelos objetos, armazenando esses valores apenas sob forma de números; e utilizadores de radiação refletida ou radiação emitida, segundo a faixa espectral utilizada (CENTENO, 2003).

Sensoriamento remoto orbital através de sistemas ópticos, ou seja, que operam na faixa do visível e infravermelho do espectro eletromagnético, representa atualmente a grande maioria dos estudos. Existem várias plataformas em operação, oferecendo diferentes opções de resolução espacial, temporal, espectral e radiométrica, de acordo com as necessidades de cada aplicação.

O programa espacial de satélites Landsat pode ser visto como o pioneiro nos sistemas de sensoriamento remoto voltados para o estudo de processos terrestres, e ao mesmo tempo, como um dos programas de maior sucesso na história do sensoriamento remoto.

A série completa consiste de 7 plataformas, lançadas entre 1972 e 1999. Durante este período, vários modelos de sensores foram empregados, iniciando-se com o *Return Beam Vidicon* (RBV), passando pelo sistema *Multispectral Scanner* (MSS), e

culminando com os sensores *Thematic Mapper* (TM) e *Enhanced Thematic Mapper Plus* (ETM+) (JENSEN, 1996). Uma falha mecânica no sistema ETM+ resultou em problemas na coleta de dados a partir de 31 de maio de 2003 (USGS, 2010), e a maior parte das aplicações de estudos terrestres reverteram, atualmente, para o uso de imagens do sensor TM 5.

2.3. 1. IKONOS II

O satélite IKONOS II foi lançado em 24 de setembro de 1999 e entrou em fase operacional a partir de janeiro de 2000. Foi o primeiro satélite comercial de alta resolução espacial e além desta característica, nele foram melhoradas as resoluções radiométrica e temporal destacando-se assim uma grande evolução em relação aos satélites até então disponíveis. Este satélite é administrado pela *Space Imaging* e opera em cinco faixas espectrais. É um sensor do tipo CCD que opera nos comprimentos de onda de 450 nm até 900 nm. As características técnicas do satélite IKONOS II são apresentadas na tabela 2.

TABELA 2 - ESPECIFICAÇÕES TÉCNICAS DO SATÉLITE IKONOS II

Altitude da órbita	681 km
Orbita(Inclinação)	98,1° sol-síncrono
Sentido da orbita	Descendente 10h30min a.m
Velocidade	7km /s
Duração da orbita	98 min.
Tempo de revisita	1-3 dias dependendo da altitude
Largura da faixa imageada	11,3 km <i>nadir</i> 13,8 km 26° <i>off nadir</i>
Resolução espacial	0,82m, <i>nadir</i> Pancromática 3,2 m, <i>nadir</i> multiespectral 1m, 26° <i>off nadir</i> pancromática 4 m, 26° <i>off nadir</i> multiespectral
Bandas espectrais	Pancromática 0,45-0,9 um Azul 0,45-0,52 um Verde 0,51- 0,60 um Vermelho 0,63- 0,70 um Infravermelho 0,76-0,85 um
Frequência de Revisita	2.9 dias para 1m de resolução. Para valores de +/- 40°.
Resolução radiométrica	11 bits (2048 níveis de cinza)

FONTE: Adaptada ENGESAT (2010)

2.4. UTILIZAÇÃO DE IMAGENS LANDSAT E IKONOS II

As imagens IKONOS II têm amplo uso, desde a gestão do espaço geográfico complexo até análise pontual, porque elas têm a capacidade de ser ampliadas com qualidade até 1: 2.500, facilitando estudos em planejamento e meio ambiente integrado com GIS. A diversidade da utilização do IKONOS II pode ser demonstrada por múltiplos trabalhos (ENGESAT, 2010).

Existem seis tipos de produtos IKONOS. A classificação se dá de acordo com o grau de acurácia dos objetos na imagem em relação ao seu posicionamento na superfície terrestre.

GOWARD et al. (2001) realizaram um trabalho de comparação da resolução espacial do IKONOS II e Landsat 7 ETM estudando a complexidade estrutural da floresta tropical e de savanas e revelaram a presença de uma marcante variação espacial para ser medida pelos sensores. WARNER e ASNER (2003) utilizaram 44 imagens IKONOS II para obter a quantificação da variação espacial da fração de cobertura no cerrado brasileiro.

STURM *et al.* (2003) visando dar suporte ao planejamento de uma área de preservação permanente, realizaram um estudo de classificação em área de floresta ciliar, destinado ao mapeamento e avaliação da ocupação urbana utilizando classificação orientada ao objeto, com base em uma imagem IKONOS II. A classificação orientada ao objeto realizada no eCognition permitiu que fossem encontradas áreas de solo exposto, dando suporte a recomendação de recuperação da área.

GONÇALVES, *et al.* (2001) apresentaram uma análise preliminar das imagens IKONOS II para atualização de cartografia de ocupação do solo com ênfase na cobertura florestal e urbana, realizando processamento ao nível de pixel, classificação de uso do solo pelo método da análise orientada ao objeto, implementado no eCognition e apresentando uma boa capacidade da extração de informação temática, em comparação com os métodos convencionais de análise baseados no pixel.

Avaliar a melhoria dos resultados da classificação digital automática com a utilização de dados auxiliares, como a textura de imagens e informações de relevo foi à proposta de LUZ (2002) que utilizou a classificação da imagem IKONOS II pelo algoritmo de Redes Neurais Artificiais. Os resultados apresentados foram excelentes quando realizados em um recorte da imagem, porém não se mostraram da mesma forma eficientes quando os parâmetros e a arquitetura da rede foram aplicados à imagem inteira.

WATZLAWICK (2003) utilizou uma metodologia com imagens do satélite IKONOS II para realizar estimativas de biomassa e carbono orgânico em plantações de *Pinus taeda*, *Araucaria angustifolia* e na Floresta Ombrófila Mista Montana, caracterizando aspectos estruturais, biomassa e carbono, determinando a correlação com os dados de radiância das bandas do satélite IKONOS II e mapeando a biomassa e o carbono orgânico na área de estudo.

ROLIM (2003) avaliou o potencial da classificação orientada a objeto aplicada a imagem de alta resolução espacial IKONOS II, para a geração de informações a respeito da cobertura e uso do solo em bacias hidrográficas no auxílio ao manejo dos recursos naturais. O autor relata que as informações extraídas de imagens IKONOS II e classificadas por esta metodologia são eficientes para serem inseridas em um Sistema de Informações Geográficas, visando auxiliar o monitoramento em uma microbacia hidrográfica.

2.5. PRÉ-PROCESSAMENTO DAS IMAGENS.

2.5.1. Realce

MOIK (1980) considera o realce de imagem como o primeiro passo do processamento, que corresponde ao conhecimento da distribuição estatística dos dados da imagem, obtendo-se o valor do nível de cinza. O realce é utilizado somente para distinguir características ou contornos de interesse na imagem, adaptando-as ao nosso sistema visual humano. Tipos de operações de realce: pontual ou local. O primeiro é efetuado pela modificação do histograma, e depende somente do nível de cinza do pixel. Na segunda operação, o novo valor do pixel depende dos valores de seus vizinhos e inclui técnicas de filtragem, detecção de bordas e interpolação.

2.5.2. Filtros

Segundo MATHER (1999), os filtros são utilizados quando se pretende realçar alguma característica ao lado da desfiguração de outras. Em estudos de áreas urbanas os filtros são usados para detectar feições como a rede rodoviária, porém

muitas vezes esta extração é incompleta, sendo conhecida como extração semi-automática.

2.5.3. Correção geométrica

Logo após o processo de aquisição das cenas pelos sensores, estas não possuem qualquer vínculo com a superfície terrestre no que diz respeito às coordenadas. Essas imagens estão sujeitas a uma série de distorções espaciais, não possuindo precisão cartográfica quanto ao posicionamento dos objetos nela representados (CROSTA, 1993).

Segundo NOVO (1993) correção geométrica é a reorganização dos pixels de uma imagem em relação a um sistema de projeção cartográfica. Esta reorganização pode ser obtida por várias técnicas de reamostragem dos pixels da cena. Os mais comuns são: “vizinho mais próximo”, “interpolação bilinear” e “convolução cúbica”. A reamostragem dos pixels pode ocasionar a modificação da qualidade radiométrica dos dados, de forma que a técnica do “vizinho mais próximo” não modifica a radiometria dos dados e a “convolução cúbica” é a técnica que impõe a alteração mais acentuada.

A correção geométrica tem a função de reorganizar os “pixels” da imagem em relação a um determinado sistema de projeção cartográfica. Ela objetiva minimizar as distorções geométricas, provenientes das características do sensor utilizado e das variações decorrentes do movimento do mesmo durante a passagem sobre o alvo. (LUIZ, et al, 2003).

As imagens retratam a superfície imageada, porém cada pixel possui apenas as coordenadas da imagem, ou seja, um par ordenado (i,j) do tipo linha e coluna associado, necessário para a construção da imagem na tela do computador.

A imagem pode sofrer um processo de reamostragem dos pixels de forma que se crie um vínculo com outra(s) imagem(s), mapas ou diretamente com a superfície terrestre através de pontos de GPS (Global Positioning Systems) ou métodos tradicionais de levantamento. Isso ocorre quando se associa à imagem um sistema

de coordenadas qualquer. Quando este sistema de coordenadas possui como base uma projeção cartográfica, que é uma maneira matemática de se representar em papel o plano da superfície curva da Terra, diz-se que a imagem está georreferenciada (possui uma referência direta com a superfície da Terra, sofrendo inclusive as deformações a ela inerentes). Para a realização deste processo cria-se uma relação entre os pontos de verdade terrestre e os pixels da imagem de sensoriamento remoto, onde uma função é ajustada, conforme o número de pontos de controle (MATHER, 1999).

O conceito por trás deste método é estabelecer as diferenças de posicionamento de alguns pontos entre a imagem a ser corrigida e o documento cartográfico tomado como base. A partir destas diferenças a distorção presente na imagem pode ser estimada e uma transformação adequada pode ser introduzida, no sentido de corrigir a imagem (CROSTA, 1993).

As imagens de satélite podem apresentar uma série de distorções espaciais, além de não conter a exatidão cartográfica no posicionamento dos objetos nelas representados. Estas distorções estão associadas ao modelo orbital do satélite, imagens com plataforma, propriedades do sensor, rotação e curvatura da Terra, além dos efeitos topográficos (SCHOWENGERDT, 1997). As distorções oriundas da topografia da área imageada, normalmente, geram grandes erros em mapas (FORD E ZANELLI, 1985).

As distorções geométricas podem ser eliminadas e/ou reduzidas, por meio de modelos de correção geométrica. A correção geométrica das imagens é necessária para realizar medições sobre as mesmas, além de integrá-las com outros dados.

A avaliação da geometria de uma imagem é expressa através das geometrias interna e externa. A geometria interna indica o grau de similaridade entre a imagem e o terreno nela representado. A geometria externa estabelece a exatidão das coordenadas da imagem em relação a um determinado referencial. A correção geométrica objetiva modelar os efeitos provocados pelas diversas fontes de distorções introduzidas no momento de aquisição da imagem (FORD E ZANELLI, 1985).

A operação de georreferenciamento produz um erro na reorganização dos pixels devido a diversos fatores que vão desde a correta identificação dos pontos de controle até as deformações devidas à curvatura da Terra. A precisão exigida para cada georreferenciamento varia com a finalidade do trabalho que está sendo desenvolvido.

O erro médio quadrático (RMS) é uma medida do desvio dos valores calculados pelo polinômio 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 este diretamente comparável ao conceito de desvio padrão.

$$RMS = \sqrt{(X_1 - X_{org})^2 + (Y - Y_{org})^2} \quad (1)$$

onde:

X_1 : Coordenada de linha calculada na imagem não registrada ;

Y_1 : Coordenada original de linha do ponto de controle na imagem;

X_{org} : Coordenada de coluna calculada na imagem não registrada;

Y_{org} : Coordenada original de coluna do ponto de controle na imagem.

2.6. PROCESSAMENTO DAS IMAGENS

2.6.1. Segmentação

Para tornar mais eficiente a identificação dos valores de brilho das imagens referentes aos valores médios de biomassa e carbono das parcelas de um inventário florestal, uma simplificação dos dados da imagem torna mais simples esta tarefa. Esta simplificação conhecida como “SEGMENTAÇÃO DE IMAGEM” consiste em dividir em objetos as regiões espectralmente homogêneas da imagem (MOREIRA, 2001), onde dados biofísicos médios das parcelas com os valores médios de brilho dos segmentos constituem-se nas entradas das redes neurais artificiais utilizadas para treinar o algoritmo. O critério de semelhança é usado para definir a uniformidade dos segmentos. Dois critérios são usados para descrever a separação do objeto da imagem, o critério espectral e o critério da forma suavização e compactação. Estes critérios controlam a homogeneidade dos segmentos e regiões (BLASCHKE e STROBL, 2001).

A heterogeneidade no domínio espectral, definida pela equação (2) é composta pela soma dos desvios padrão dos níveis digitais para uma dada banda “ σ_c ” ponderada pelos pesos “ W_c ”. Contudo, em muitos casos, a heterogeneidade espectral pode resultar em segmentos fragmentados e por isto deve-se considerar a heterogeneidade no domínio espacial.

2.6.2. Segmentação multi-resolução e classificação baseada no objeto

O procedimento de segmentação elaborado pelo programa eCognition 4.0 é conhecido como *Multiresolution Segmentation*. A técnica básica utilizada é a de crescimento de regiões por agregação de pixels (BAATZ E SHAPE, 2007 e ROLIM, 2003).

Cada vez mais imagens de alta resolução são utilizadas para se extrair informações do espaço através de métodos de segmentação e classificação. A segmentação é um processo que consiste em dividir as imagens em segmentos homogêneos (GONZALEZ E WOODS, 2000).

O critério de semelhança é usado para definir a uniformidade dos segmentos. Dois critérios são usados para descrever a separação do objeto da imagem: critério da cor (espectral) e o critério da forma (suavização e compactação). Estes critérios controlam a homogeneidade dos segmentos e regiões (BAATZ E SHAPE, 2007).

A descrição de heterogeneidade (h) espectral é conjugada pela soma dos desvios padrão dos tons de cinza para uma dada banda (σ_c) ponderados pelos pesos (w_c), sendo:

$$h = \sum_c w_c \sigma_c \quad (2)$$

Onde:

σ_c : desvios padrão dos tons de cinza para uma dada banda;

w_c : pesos dados à banda.

O valor de fusão versa em duas partes: Um critério de cor e um critério de forma. O critério de cor é a mudança na heterogeneidade que acontece após a fusão de dois objetos, descrita pela mudança do desvio ponderado dos valores espectrais. O critério de forma é um valor que descreve o aperfeiçoamento da forma em relação a dois modelos de padrão de forma. O cálculo genérico do valor de fusão para heterogeneidade da cor e para heterogeneidade da forma é feito da seguinte maneira:

$$f = w \cdot h_c + (1 - w) \cdot h_f \quad (3)$$

Onde:

w : o peso definido pelo usuário para cor ($0 \leq w \leq 1$);

f : valor de fusão;

h_c : heterogeneidade da cor;

h_f : heterogeneidade da forma;

O critério espectral h_{cor} é a média ponderada das mudanças nos desvios padrões para cada banda c . Os desvios padrões são ponderados pelos tamanhos dos objetos n_{obj} :

$$h_{cor} = \sum w_c \left(n_{fusao} \cdot \sigma_c^{fusao} - \left(n_{obj1} \cdot \sigma_c^{obj1} + n_{obj2} \cdot \sigma_c^{obj2} \right) \right) \quad (4)$$

Onde:

σ_c : desvios padrão dos tons de cinza para uma dada banda;

w_c : pesos dados à banda.

n_{obj} : tamanho de cada objeto

Na segmentação orientada a regiões, uma região é um conjunto de pontos “ligados”, ou seja, de qualquer ponto da região pode-se chegar a qualquer outro ponto por um caminho inteiramente contido na região. As regiões que se desejam detectar em geral são regiões “homogêneas” e apresentam alguma propriedade local aproximadamente constante em toda sua extensão. Algumas propriedades locais

usadas comumente são níveis de cinza, textura e cor (MASCARENHAS e VELASCO, 1989).

Para os algoritmos de crescimento de regiões segundo a varredura, a imagem é percorrida de cima pra baixo e da esquerda pra direita. Cada ponto (x,y) é comparado com seus vizinhos anteriores (já rotulados) e adicionado ou não a classe da região de um dos vizinhos. Se um ponto não for adicionado à região de um vizinho, ele deverá iniciar uma nova região (GONZALEZ e WOODS, 2000). Os autores comentam que a principal vantagem de se trabalhar com a classificação por regiões é que essa técnica fornece informações de natureza espacial, que não podem ser extraídas individualmente de pixels e que são normalmente consideradas durante o processo de análise visual de imagens.

Em um processo de classificação orientada ao objeto, duas são as etapas principais: a segmentação e a classificação das regiões resultantes. Durante o processo de segmentação, a imagem é sub-dividida em porções uniformes menores (segmentos ou regiões) utilizando o algoritmo de crescimento de regiões e guardando a associação espacial entre os segmentos.

Dado um determinado critério de heterogeneidade para uma região, o crescimento de heterogeneidade na fusão deve ser minimizado e como descrito por RIBEIRO *et al.* (2002) os segmentos são descritos por meio de variáveis espectrais e/ou espaciais. As variáveis ou imagens compostas por níveis digitais espectrais podem ser o “brilho”, o valor médio de brilho ou a razão, e pode-se citar como variáveis espaciais o comprimento, a largura e a direção principal, dentre outras.

GONZALEZ e WOODS (2000) ressaltam que a segmentação deve isolar os objetos de interesse na imagem para ser eficiente. Os algoritmos de segmentação de imagens são muitos específicos e desenvolvidos para determinada aplicação. O algoritmo que detecta com grande precisão um tumor não obteria o mesmo resultado ao tentar detectar um defeito de uma peça numa linha de montagem, não existindo um modelo formal para segmentação.

Esse processo é essencialmente empírico e deverá se ajustar a diferentes tipos de imagens (BAATZ e SCHÄPE, 2007; ROLIM (2003).

GONZALEZ e WOODS (2000) afirmam que os algoritmos de segmentação para imagens são geralmente baseados nas propriedades básicas dos valores de níveis de cinza, da descontinuidade e da similaridade. A primeira categoria aborda a partição da imagem baseada em mudanças bruscas nos níveis de cinza. Sua utilização é aplicada geralmente para a detecção de pontos isolados ou linhas e bordas na imagem. Já a similaridade baseia-se em limiarização, crescimento de regiões e divisão e fusão de regiões.

Outro método com potencial para o monitoramento é a segmentação multi-resolução e classificação orientada a objeto. Esta técnica foi desenvolvida para suprir as limitações das técnicas tradicionais de classificação de imagens, baseadas em métodos de classificação por pixel. A classificação orientada a objeto não considera apenas a informação espectral, mas também a informação espacial e contextual dos objetos, determinados através de padrões locais na imagem por um grupo de pixels vizinhos. O método utilizado é a segmentação por crescimento de região e baseada em conhecimento espectral e espacial dos objetos. O algoritmo é baseado na idéia conceitual que a importante informação semântica requerida para interpretar uma imagem não é representada por simples pixels, mas em significantes imagens objeto e suas relações mútuas. A técnica por crescimento de regiões inicia com um pixel objeto e a partir deste, outros pixels são agrupados em objetos maiores. O crescimento é baseado nos critérios de homogeneidade descrito pela similaridade das imagens objeto em termos de tamanho, distância, textura, similaridade espectral e/ou forma (VAN DER SANDE et al, 2003).

Os objetos ou regiões criados da segmentação possuem relações hierárquicas entre si, onde os mesmos podem ser definidos não somente pelas características espectrais, de forma ou textura, mas também pelas relações de vizinhança com sub e super objetos (BENZ et al, 2004). Esta dependência mútua entre objetos ou classes é definida como uma rede semântica espacial. A classificação orientada a objeto vem sendo utilizada com sucesso na detecção de estradas urbanas (HOFMANN, 2001) e na geração de mapas para auxiliar no monitoramento dos recursos naturais, como: mapeamento de cobertura da terra para ajudar na avaliação de risco e danos da inundação (VAN DER SANDE et al, 2003), identificação de ambiente ciliar para gerar mapas de vegetação capazes de

direcionar estratégias de manejo para preservação das florestas ao longo dos rios (ANTUNES, 2003) e no mapeamento da bacia hidrográfica para auxiliar no monitoramento ambiental (ROLIM, 2003).

2.6.3. Classificação

A classificação de imagens pode ser realizada por diferentes métodos como algoritmos de máxima verossimilhança, isodata, árvore de decisão lógica *fuzzy* e vizinho mais próximos, contudo esta pode ser supervisionada ou não supervisionada.

Na classificação supervisionada, o usuário define as classes e apresenta amostras ao computador, e a partir das quais ele pode calcular parâmetros estatísticos para descrever cada classe. Uma vez definidas as classes e calculados os seus descritores todos os pixels na imagem são classificados (CENTENO, 2003). Assim ele identifica na imagem áreas onde as classes puras e informa ao computador que a partir dos valores correspondentes a estas regiões, calcula parâmetros estatísticos para cada classe (média e variância, por exemplo).

A fase mais importante deste processo é a amostragem, pois é nela que o usuário define as classes e escolhe as amostras representativas. Esta decisão depende do interesse do usuário e pode ser diferente em cada aplicação.

A classificação não-supervisionada é um procedimento em que a interação do analista com o sistema é mínima. No entanto, certos algoritmos necessitam que o analista forneça alguns parâmetros na fase de treinamento. Embora os classificadores não-supervisionados sejam indicados nos casos em que o analista não possui conhecimento a priori da área de estudo, eles também podem ser usados quando se conhece a área. Isto é feito quando se quer eliminar a subjetividade no processo de obtenção das amostras de áreas, para criar o pacote de treinamento, como indicado no processo supervisionado (MOREIRA, 2001).

2.6.4. Classificação através de lógica *fuzzy*

A classificação orientada a objeto baseia-se em classificadores *fuzzy*, os quais incorporam medições imprecisas do sensor, descrições indefinidas da classe e modelagem imprecisa de uma análise (BENZ et al, 2004).

Os descritores associados aos objetos são combinados através de operadores *fuzzy*, o que permite gerar funções de pertinência que refletem o conhecimento. Assim, desaparece a tradicional noção determinística que considera que um objeto PERTENCE ou NÃO PERTENCE a uma determinada classe. Utilizando regras *fuzzy*, um objeto pode estar associado a várias classes com diferentes graus de pertinência. O grau de pertinência varia de 0 (não pertence) a 1 (pertence) e a classe considerada é aquela cujo grau de pertinência é maior. Por exemplo, um objeto pode apresentar o grau de pertinência 0,8 para telha cerâmica e 0,6 para a classe solo exposto. Neste caso, o objeto seria classificado como telha cerâmica, embora seja considerado um objeto com pouca estabilidade já que seu grau de pertinência é elevado para duas classes distintas.

Na lógica *fuzzy* os valores que pertencem estritamente a uma classe assume valores de pertinência 1. À medida que os membros se afastam do valor central, são definidos numa amplitude de valores de pertinência com tendência a zero. A forma como os valores de pertinência são atribuídos a classificação contínua depende da função de pertinência, ou seja que associa a cada elemento um valor no intervalo contínuo entre 0 e 1 (SILVA, 1995).

Quando se analisa as funções que indicam o valor de cada elemento *fuzzy*, pode-se perceber que a disposição dos membros podem admitir diferentes curvas. As curvas são disposição linear ou sigmoideal, tal com mostrada nas figuras 6 e 7.

A escolha de determinada função é uma decorrência da distribuição dos elementos do conjunto *fuzzy*.




FIGURA 4 - REPRESENTAÇÕES DE FUNÇÕES LINEARES DE CONJUNTOS FUZZY




FIGURA 5 - REPRESENTAÇÕES DE FUNÇÕES SIGMOIDAIS DE CONJUNTOS FUZZY.

2.6.5. Descritores da classificação

Para a realização da classificação é necessária a descrição dos atributos inerentes aos objetos a serem classificados. Os descritores podem ser baseados em parâmetros espectrais e de forma, podendo ainda ser inseridos ainda outros tipos de descritores, baseados em textura ou no relacionamento entre objetos vizinhos, sub-objetos e super-objetos.

Os descritores baseados em valores espectrais das bandas são os seguintes (BAATZ E SHAPE., 2007):

A média é umas das características dos objetos, calculada a partir dos valores das diferentes camadas de informação (que podem ser as bandas espectrais), computando-se o valor médio dos níveis de cinza dos pixels que formam determinado objeto;

$$\overline{nc} = \frac{1}{n} * \sum_{i=1}^n nc \quad (5)$$

Onde:

n : número de pixels que formam o objeto;

nc : valor do nível de cinza para determinada camada e determinado objeto.

O desvio padrão é determinado a partir dos valores da camada de todos os n pixels que forma uma imagem do objeto.

$$\sigma_c = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (nc - \overline{nc})^2} \quad (6)$$

Onde:

n : número de pixels que formam o objeto;

nc : valor do nível de cinza para determinada camada e determinado objeto.

O brilho pode ser dado pela somatório dos valores médios das bandas espectrais e dividida pelo número de bandas que formam o segmento; o brilho varia de [0; ate comprimentos dos dados]. Exemplo numa imagem de 8 *bit* o brilho variaria de [0;255].

$$\boxed{Brilho = \frac{1}{n_{bandas}} * \sum_{i=1}^n \overline{nc_i}}$$
(7)

Onde

$\overline{nc_i}$:é o valor médio da banda i.

Razão é valor médio de uma banda dividido pela soma dos valores médios de todas as bandas espectrais que formam um segmento. Descreve a predominância de uma banda em relação às demais e varia de [0;1].

Diferença média entre objetos vizinhos: para cada objeto vizinho é determinada a diferença média em determinada banda, proporcionalmente ao comprimento limite entre os objetos.

Os descritores baseados em forma são os seguintes (BAATZ E SHAPE, 2007):

- Comprimento;
- Largura;
- Comprimento do limite: somatório dos segmentos limítrofes entre dois objetos;
- Índice de Forma: Expressa a suavidade do limite entre objetos. Quanto mais fractal, maior o índice de forma.
- Densidade: é descrita pela razão da área que cobre um objeto pelo seu raio;
- Assimetria: É determinado de acordo com o semi-eixo maior e o semi-eixo menor de uma elipse que compreende o objeto.
- Compacidade: definida pela razão da área do objeto e o raio da circunferência abrangente.

2.6.6. Avaliação da classificação

A avaliação da acurácia determina a qualidade dos mapas produzidos a partir dos dados de sensoriamento remoto, sendo que essa avaliação pode ser qualitativa ou quantitativa. A avaliação quantitativa é realizada por meio da comparação dos

mapas com as informações de campo (referência de campo), que devem ser precisas e independentes das informações utilizadas na geração dos mapas.

CENTENO (2009) ressalta que contendo o número de pixels corretamente classificados, uma estimativa de qualidade do resultado pode ser facilmente obtida pela equação.

$$Q = \frac{nc}{nt} \quad (8)$$

Onde:

nc : é o número de pixels corretamente classificados;

nt :é número total de pixels nas amostras.

Esta estimativa global, no entanto não permite maiores conclusões como por exemplo qual classe foi melhor classificada ou quais classes encontram-se associadas a maior confusão e são responsáveis pela maior parcela de erros.

Assim a mesmas estimativas podem ser determinadas a partir de matriz de confusão onde calcula-se a soma da diagonal principal dividida pelo total de pixels nas amostras ou seja a soma de todas as células da matriz:

$$Q = \frac{\sum d_i}{\sum m_{(i,j)}} \quad (9)$$

Onde:

D_i : é cada elemento da diagonal principal

$m(i,j)$: é cada elemento na linha i e coluna j

No resultados de classificação distinguem-se dois tipos principais de erros: erros de omissão e erros de inclusão (CENTENO, 2009).

Os erros de omissão são pixels pertencentes a uma dada classe que foram erroneamente classificados como sendo da outra, ou seja, foram omitidos da classe. Estes erros podem ser avaliados para cada classe dividindo-se o número de pixels incorretamente classificados da classe pela soma parcial da linha da mesma classe:

$$Eom_{(i)} = \frac{\sum l_{(i)} - d_i}{\sum l_{(i)}} \quad (10)$$

Onde:

$\sum l(i)$: é a soma parcial da linha i ;

d_i : é o elemento da diagonal na linha i

Já os erros de inclusão correspondem aos pixels que sendo na realidade de outra classe, foram incluídos na classe considerada. Este erro pode ser medido por:

$$\boxed{Ein_{(i)} = \frac{\sum c_{(i)} - di}{\sum c_{(i)}}} \quad (11)$$

Onde:

$\sum c(i)$: é a soma parcial da coluna i ;

di : é o elemento da diagonal na coluna i

Os erros de omissão e de inclusão são elementos que servem para avaliar quanto cada classe foi sub ou superestimada. A primeira estatística, erros de omissão serve para descrever com precisão uma determinada classe definida. Já a taxa de erros de inclusão indica quanto cada classe foi superestimada (CENTENO,2009).

CONGALTON (1991) destaca que o índice Kappa é um coeficiente baseado na diferença entre a concordância observada (diagonal principal da matriz de confusão com a concordância entre a classificação e os dados de referência) e a chance de concordância entre os dados de referência de uma classificação aleatória (produto entre os totais marginais da matriz). A equação que fornece o valor de Kappa é apresentada a seguir:

$$\boxed{k = \frac{N * \sum_{i=1}^M di - \sum_{i=1}^M (\sum l(i) * \sum c(i))}{N^2 - \sum (\sum l(i) * \sum c(i))}} \quad (11)$$

Onde:

N: é número de pixels de verificação

M: é número de classes

MOREIRA (2001) adaptou a tabela do estudo de Landis e Koch (1977) como ilustra a tabela 3, onde o índice kappa é usado para avaliar o desempenho da classificação.

TABELA 3 - RELAÇÃO ENTRE OS VALORES DE ÍNDICE KAPPA E O DESEMPENHO DA CLASSIFICAÇÃO

Índice Kappa	Desempenho da classificação
<0	Péssimo
$0 < k \leq 0,2$	Mau
$0,2 < k \leq 0,4$	Razoável
$0,4 < k \leq 0,6$	Bom
$0,6 < k \leq 0,8$	Muito bom
$0,8 < k \leq 1,0$	excelente

3 MATERIAIS E MÉTODOS

3.1. A ÁREA DE ESTUDO

A área do estudo localiza-se no posto administrativo de Machipanda, na região fronteira com Zimbábue, no distrito de Manica, província de Manica em Moçambique. Denomina-se floresta de Inhamacari, nome proveniente do rio Inhamacari que atravessa a região. O posto administrativo de Machipanda localiza-se na parte Oeste do distrito de Manica como ilustra a figura 6.

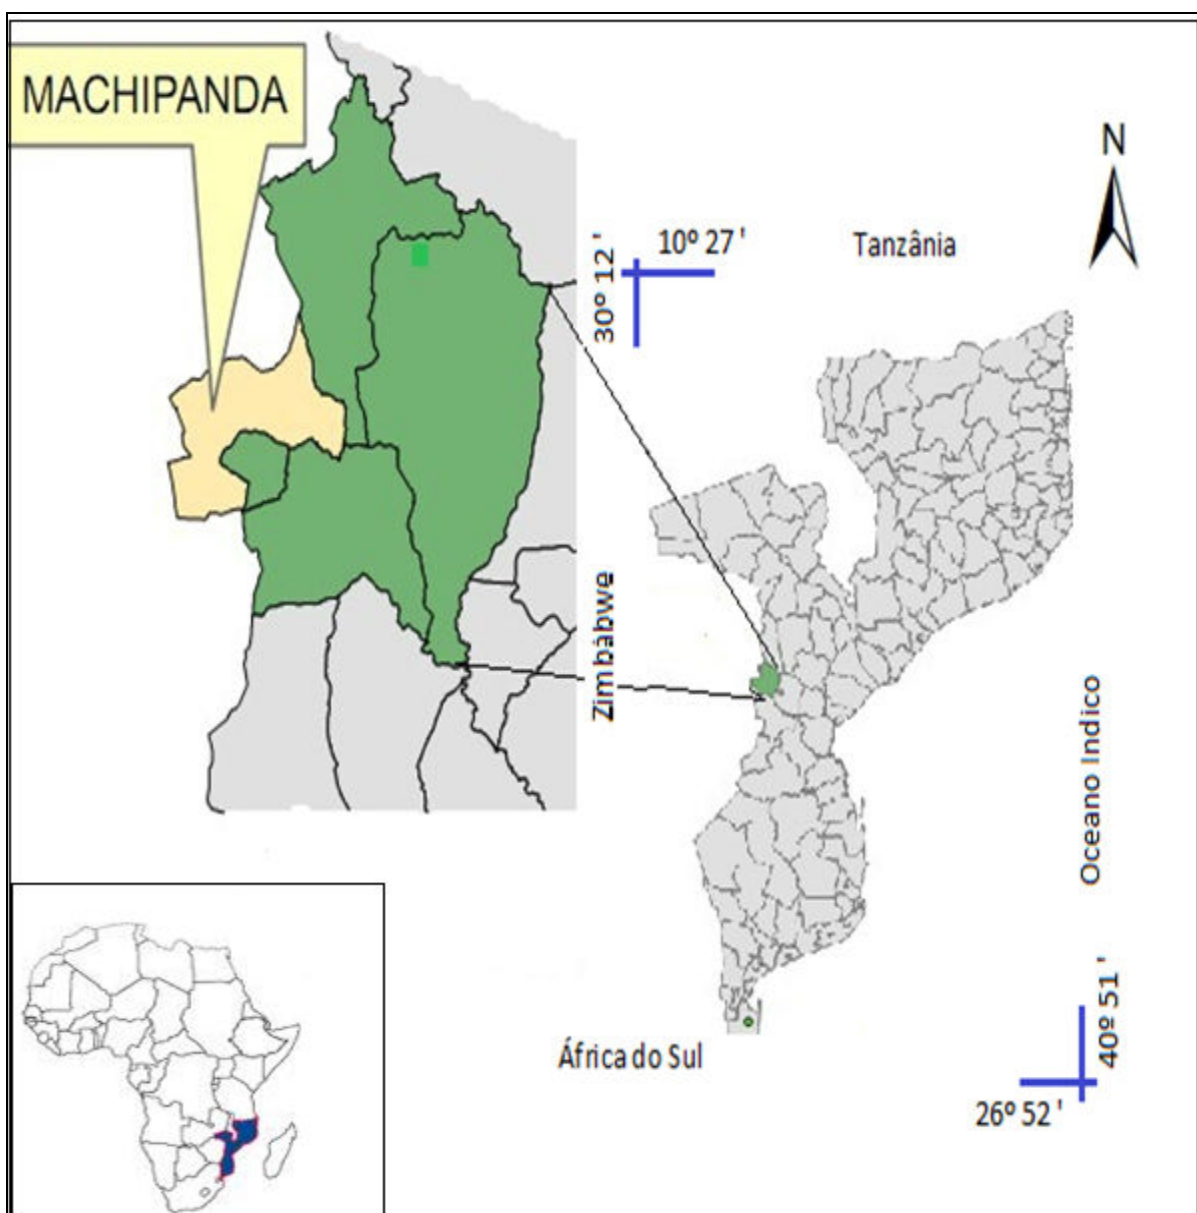


FIGURA 6 - LOCALIZAÇÃO GEOGRÁFICA DA ÁREA DE ESTUDO EM MOCAMBIQUE

FONTE: TUZINE et al. 2011.

Moçambique localiza-se a sudeste do continente africano. É limitado a leste pelo Oceano Índico, a norte pela Tanzânia, a noroeste pelo Malawi e Zâmbia. A oeste faz fronteira com o Zimbabwe, África do Sul e Swazilândia, e o sul com a África do Sul.

Em termos de coordenadas geográficas, Moçambique situa-se entre as latitudes 10° 27' Sul e 26° 52' Sul e entre as longitudes 30° 12' Este e 40° 51' Este (BARCA, 1992; MUCHANGOS, 1999).

O seu território enquadra-se no fuso horário 2 (dois), o que lhe confere duas horas de avanço em relação ao Tempo Médio Universal (MUCHANGOS, 1999). Moçambique tem uma superfície total de 799.380 km² dos quais 13.000 km² são ocupados pelas águas interiores que incluem os lagos, albufeiras e rios (BARCA, 1992).

O distrito de Manica localiza-se na parte central a Oeste da província de Manica, com o formato alongado e estreito, limitado a Norte pelo distrito de Barué, a sul pelo distrito de Sussendenga, a Este pelo distrito de Gôndola e a Oeste em toda sua extensão pela Republica de Zimbabwe.

O distrito está dividido em cinco postos administrativos Cidade de Manica (Manica sede), Machipanda, Messica, Mavonde, Vanduzi, além de albergar treze localidades. Com uma superfície de 4594 km² uma população de 199117 habitantes o que resulta numa densidade de 43,3 ha/km².

3.1.1.Clima

O clima no distrito de Manica, segundo classificação climática de Koppen(FERRO E BOUMAN,1987), é do tipo temperado úmido (Cw).

A região montanhosa de Manica registra valores médios anuais na ordem dos 1000 e 1200 mm de chuva. Em geral, a distribuição das chuvas é irregular ao longo do ano, observando-se claramente a existência de duas estações bem distintas, a estação chuvosa e seca. A estação das chuvas tem início no mês de Novembro e seu termino, no mês de Abril sendo que, a evapotranspiração média anual de cerca de 1220-1290mm. O balanço hídrico permite apurar que o período de maior volume

de água ocorre no mês de Novembro a Março, no qual a precipitação é maior em relação a quantidade da evapotranspiração.

A temperatura média anual do distrito é de 21,2^{oC}. A média anual no verão é de 28,4^{oC}, com valores extremos de 30,9^{oC} (Outubro) e 24,4^{oC} (Julho) e a média anual no inverno é de 14^{oC} com valores mensais extremos de 18,5^{oC} (Fevereiro) no verão e 7,3^{oC} (Julho).

3.1.2. Relevo e solos

O distrito de Manica é constituído por cadeia montanhosa ocorrendo de sul a norte da província numa faixa fronteiriça com Zimbabwe denominada “Cratão de Zimbabwe”. Esta formação compreende especialmente basaltos, riolitos e lavas alcalinas. A maior parte dos afloramentos forma cristas e cadeias montanhosas. Algumas montanhas chegam a atingir cerca de 1500-2000 m de altitude, Existe certa correlação entre a topografia, especialmente a altitude e condições climáticas. Geralmente, enquanto altitude for maior e a precipitação anual e com o período longo e chuvoso.

Os solos de Manica mostram uma estreita relação com a geologia e o clima da região e são localmente modificados pela topografia e regime hídrico. Em geral os solos são desenvolvidos sobre materiais de solo do Précambrio e rochas ácidas como granito e gnaisse. Sendo basicamente solos argilosos vermelhos óxidos ou castanhos avermelhados profundos, bem drenados, a topografia é suavemente ondulada; nos declives, nos cumes das montanhas e nos afloramentos rochosos os solos são líticos, com textura franco-arenosa, poucos profundos e drenagem excessiva. As principais limitações para a agricultura são a baixa fertilidade de solos, pouca profundidade e risco de erosão.

3.1.3. Vegetação

Os levantamentos efetuados na mata de Inhamacari indicaram a existência de seis tipos de uso e cobertura de solo, destacam-se as plantações de Pinus, plantações de Eucalipto, mistura de Pinus e Eucalipto, mistura de Pinus e mata nativa.

As espécies que constituem as plantações de Eucalipto são: *Eucalyptus cloeziana* com maior predominância, *Eucalyptus grandis*, *Eucalyptus saligna*, e em vários talhões mistura de *Eucalyptus grandis* e *Eucalyptus saligna*.

As plantações de Pinus são compostas de *Pinus taeda*, *Pinus patula* e mistura de *Pinus patula* e *taeda*.

A mata nativa enquadra ainda as classes de Florestas sempre verde de montanha (Mf2), matagal/miombo(T), vegetação degradada/mistura com agricultura(WG) e agricultura e casas(S). As espécies predominantes nesta mata são *Brachystegia spiciformis*, *Brachystegia bohemii*, *Acacia sp*, *Albizia adiatifolia*, *Khaya nhassica* nas nascentes e nas margens dos rios e riachos, *Julbernardia globiflora*, *Pterocarpus angolensis*, *Pericopsis Angolensis* *Maytenus acuminata*, *Uapaca kirkiana*, *Ficus sp*.

A composição e distribuição da flora terrestre estão relacionadas com a posição geográfica de Moçambique na zona sub-equatorial e tropical do Hemisfério Sul, na costa oriental e austral do continente africano. Também exercem influência sobre a composição e distribuição da flora terrestre as condições regionais e locais do clima, relevo, rios, lagos, rochas, solos e a distância em relação ao Oceano Índico.

A localização de Moçambique na região florística sudano-zambezíaca e as condições climáticas condicionam o desenvolvimento de variedades de associações vegetais hidrófilas, mesófilas e xerófilas de floresta e de savanas arbóreas e arbustivas.

As diferenças na distribuição, composição, densidade e variedade de espécies devem-se a fatores tais como latitude, alternância entre as terras altas e as depressões, continentalidade, natureza pedológica, condições de água, de solo e o grau de intervenção humana. Estes fatores provocam diferenças espaciais na distribuição da vegetação.

A área de dispersão da floresta está relacionada com o clima, continentalidade, altitude e as condições edáficas. Elas apresentam características mesófilas sub-equatoriais com grande diversidade e tamanho de árvores que atingem até 35 m de altura. Para esta floresta, o clima sub-equatorial do norte do país e de todo o litoral, propiciam as melhores condições, devido às características de unidade e

pluviosidade. A floresta desenvolve-se de preferência em áreas onde a pluviosidade é superior a 1000 mm por mais de 5 meses e tem o caráter de floresta sempre verde. Trata-se de uma floresta com grande densidade do estrato arbóreo, com árvores de tronco grosso, com amplas copas que se elevam até a uma altura de 10 a 20 m. Em geral as suas folhas são pequenas e caducas, raramente largas e perenes. O estrato herbáceo é pobre e constituído por gramíneas rasteiras .

A floresta sempre verde desenvolve-se sobretudo nas principais montanhas do país e a densidade em espécies é maior nas encostas voltadas para leste em altitudes compreendidas entre 1200 e 1600 m e onde a pluviosidade é superior a 1500 mm.

Nos planaltos de Chimoio e de Mossurize, particularmente em Espungabera, Abongo, Marongo, Sitatonga e Amatongas, onde a pluviosidade é de cerca de 1200 mm, desenvolve-se a floresta semi-decídua ou semi-caduca, em que as árvores dominantes atingem cerca de 20 m de altura..

Nas margens aluviais dos principais rios de Moçambique, em especial na parte norte, ocorre uma floresta adaptada às condições edáficas locais, cujas árvores podem ser dominadas por um estrato herbáceo de caniço, bambu e outros. Ela dispõe-se ao longo dos rios, parecendo cobri-los, sendo por isso designada por floresta-galeria.

De uma maneira geral a savana é uma formação baixa (plantas de altura até 10 m), por vezes degradada, com plantas espinhosas e outras de folha caduca. As espécies são de porte médio, variando de 10 a 15 m, e distribuem-se a norte da província de Manica, em Gaza, Inhambane e, em geral, nas margens dos principais cursos de água, onde a pluviosidade não ultrapassa os 600 mm .

3.2. MATERIAIS

3.2.1. Cartas e Mapas

Foram usadas cartas adquiridas na DINAGECA (Direção Nacional de Geografia e Cadastro) atualmente DNTF (Direção Nacional de Terras e Florestas). Mapas digitais de vegetação na escala 1:250.000, foram usados para auxiliar na

caracterização da cobertura vegetal e mapas topográficos, na escala 1:50.000 foram usados como base cartográfica e para registro das imagens.

Foi usada ainda uma mapa planimétrico disponibilizado pelo FAEF-DEF (Faculdade de Agronomia e Engenharia Florestal - Departamento de Engenharia Florestal) com escala de 1:10.000.

Para avaliação da classificação usou-se Mapa Planimétrico de Uso da Terra Floresta de Inhamacari, Ministério das Relações Exteriores do Brasil (MRE) e Agência Brasileira de Cooperação (ABC) com escala de 1:5000

3.2.2. Imagens de satélite Ikonos II

No estudo foram usadas imagens de satélites de alta resolução espacial nas quais a área utilizada da imagem correspondeu a da área cedida para o CEFLOMA (Centro Florestal de Machipanda) que foi recortada da imagem total.

Esta imagem foi orto e georretificada pela GeoEye tendo-se as seguintes especificações técnicas: projeção UTM Datum Horizontal WGS84; origem da quilometragem UTM em relação ao meridiano central de 39° WGR na zona 36 sul.

A imagem foi adquirida já fusionada pelo fornecedor com 1 m de resolução espacial e 11 bits de resolução radiométrica nas bandas multiespectrais (visível e infravermelho próximo), obtida no dia 13 de Março de 2008.

3.3. MÉTODOS

3.3.1. Pré-processamento

3.3.1.1. Extração de características estatísticas

Efetou-se o cálculo da média e o desvio padrão de cada banda e de cada tipo de cobertura para se usar como elemento (descriptor da classe) na classificação e pela lógica *fuzzy*.

3.3.1.2. Correção geométrica

A correção geométrica foi realizada usando-se o software Envi 3.5 a partir 17 pontos de controle obtidos de mapas planimétricos nas escalas 1:50 000 e 1:10 000 tendo-se realizado a correção através do polinômio de segundo grau.

3.3.2. Processamento

3.3.2.1. Segmentação

Com o objetivo de diminuir a variação dos valores de entrada (menor variância), foi executada a segmentação que gerou entradas uniformes uma vez que os valores de vegetação representam porções homogêneas do espaço físico, com características semelhantes. A seleção do método de segmentação foi baseada em aspectos práticos de implementação da metodologia de utilização do programa eCognition 4.0, que executa segmentação multi-resolução, baseada na forma e nos valores digitais dos objetos. O critério de semelhança foi usado para definir a uniformidade dos segmentos.

Os parâmetros de segmentação foram definidos fixando-se o fator de escala da segmentação das imagens para os valores de quarenta (40), oitenta (80), e cento e vinte (120).

Depois de várias tentativas e de análise visual dos segmentos resultantes definiu-se como padrão de segmentação os fatores (40, 80 e 120) para escala e valores 0,8 para a cor, 0,2 para a forma da qual derivou-se 0,5 de suavidade e 0,5 de compacidade, porque foi o resultado que melhor agrupa os elementos de interesse das imagens e seqüenciados conforme a tabela 4.

TABELA 4 - ARRANJOS DOS NÍVEIS PARA A SEGMENTAÇÃO.

Fator Escala	Fator cor	Fator de forma	Suavidade	Compacidade
40	0,8	0,2	0,5	0,5
80				
120				

Finalmente, diferentes parâmetros de escala foram utilizados para verificar a melhor segmentação (parâmetros de escala 40, 80 e 120). Na segmentação, a informação espectral foi a mais utilizada. Para isso, o peso dado à componente espectral foi maior com vista a ter maior relevância da informação espectral presente nas tipologias sendo de 0,8 e o fator de forma de 0,2 oferecendo pouca relevância a fator de forma dos objetos. Assim sendo, a segmentação foi controlada mais pelas variações de tonalidade (cor).

3.3.2.2. Classificação via vizinho mais próximo no eCognition

A classificação dos objetos foi feita utilizando-se o aplicativo eCognition que baseia-se na metodologia de dados orientados a objeto. O aplicativo eCognition permite que através da imagem segmentada na tela (agregada em regiões), sejam coletadas amostras para descrever cada classe a partir das regiões. Considerando os dados contidos nas bandas, foram processados os valores da média, desvio padrão, razão, as diferenças das médias e brilho entre o objeto e a sua vizinhança.

O classificador denominado “vizinho mais próximo” classifica a imagem num dado espaço da feição e com amostras dadas a classes de pertinência. O princípio é simples: primeiro, o software necessita de amostras representativas para cada classe. Como o eCognition é baseado numa abordagem orientada ao objeto para a análise das imagens, assim os objetos da imagens serão considerados amostras. Depois da declaração das amostras representativas de cada classe, o algoritmo procura as amostras próximas dos objetos no espaço da feição para cada imagem. Dependendo se os objetos da imagem forem próximos às amostras que pertencem a classe de Pinus, então, os objetos serão considerados da classe de Pinus. Os objetos mais próximos estão localizados no mesmo espaço da feição pertencentes as amostras da classe Pinus, que reúnam maior grau de associação desta classe. O eCogition calcula as distâncias do seguinte modo:

$$d = \sqrt{\sum_f \left(\frac{v_f^{(s)} - v_f^{(o)}}{\sigma_f} \right)^2} \quad (12)$$

Onde:

D: Distância entre amostras dos objeto "s" e objeto "o" da imagem;

$v_f^{(s)}$: O valor das amostras de objetos da feição "s" na feição f;

$v_f^{(o)}$: O valor dos objetos da imagem da feição "o" na feição f;

σ_f : O desvio padrão dos valores na feição f.

A distância no espaço da feição entre as amostras do objeto e objetos da imagem a serem classificados são normalizados (padronizados) pelo desvio padrão de todos os valores da feição.

3.3.2.3. A classificação *Fuzzy*

A classificação lógica *fuzzy* foi usada baseando-se nas características espectrais das amostras. Para isto foram usadas as médias, desvio padrão, o brilho e a textura. Aqui as classes foram consideradas dentro do intervalo [0-1] correspondendo ao intervalo [0-2047] de níveis de cinza. Foi considerada a média da banda na classe (\bar{X}) e os respectivos desvios padrão (s) e definiu-se como valores anômalos às classes aqueles cujos valores são superiores a $\bar{X} + 2s$.

Se a distribuição das classes obedece aos padrões da figura 4 (a), ter-se-ia o eixo das abscissas representando as classes e nas ordenadas, os membros *fuzzy*. A interpretação do conjunto fuzzy foi: todas as classes de 0 ate \bar{X} representam as classes correspondentes ao membro fuzzy 0 (zero). Todas a classes acima de $\bar{X} + 2s$ foram anômalas e correspondentes ao membro 1 (um).

Assim a zona de ambigüidade ou fuzzy foi aquela compreendida entre \bar{X} e $\bar{X} + 2s$ e estes pontos corresponderam aos pontos de inflexão da função. Assim, definiu-se a função da equação 13 como:

$$\mu(x) = \left\{ \begin{array}{l} 0 \text{ --- } \rightarrow x < \bar{X} \\ \frac{x - \bar{X}}{\bar{X} + s} \text{ --- } \rightarrow \bar{X} < x < (\bar{X} + 2s) \\ 1 \text{ --- } \rightarrow x > (\bar{X} + 2s) \end{array} \right\} \quad (13)$$

Onde :

$\mu(x)$: média amostral das classes que permitiu a separação

\bar{X} : média das classes

X: valores observados na classe

S: desvio padrão

Estes elementos também foram usados para a classificação usando o algoritmo vizinho mais próximo.

3.3.2.4. Classes da classificação

A escolha das classes procedeu-se de acordo com o nível de importância para o processo de segmentação e possível separabilidade pelo método, assim como pelas características provavelmente agrupáveis espectralmente. Os padrões de classificação de uso e cobertura da FAO, adotados por Moçambique foram considerados.

1) Reflorestamento de Pinus

São áreas contendo as plantações de Pinus com uma textura marcante pela aparente homogeneidade assim como está ilustrado na figura 7.




FIGURA 7 - CLASSE DE REFLORESTAMENTO DE PINUS

2) Reflorestamentos de Eucalipto.

As plantações de Eucalipto são regiões com textura rugosa com uma certa homogeneidade e continuidade, figura 8.



FIGURA 8 - CLASSE DE REFLORESTAMENTO DE EUCALIPTO

3) Solo

Esta classe refere-se a solo exposto contendo, por vezes, um pouco de grama. Estão inseridos nesta classe as estradas, caminhos e agricultura (machambas) recém abertas ou recém abandonadas, sem capim, que espectralmente refletem como o solo, conforme figura 9.



FIGURA 9 - CLASSE DE SOLO

4) Agricultura e capim

A dificuldade de separar estas duas classes fez com que se agrupassem. Esta classe retrata áreas agrícolas recém exploradas com surgimento de capim e áreas com agricultura (machambas) em pequenas propriedades no meio da floresta, sem organização em termos da forma e com árvores esparsas, assim como casas (cabanas), conforme a figura 10.




FIGURA 10 - CLASSE DE AGRICULTURA E CAPIM

5) Matagais

Esta classe contém as formações nativas de sub bosque e que por vezes tendem a serem bosques fechados, considerados em Moçambique como floresta aberta junto com matagais. As espécies predominantes são as *Brachystegia* sp, *Uapaca* sp, *Acácias* sp e *Tabernaemontana elegans*, ilustrado na figura 11.




FIGURA 11 - CLASSE DE MATAGAIS

6) Vegetação nativa

Esta classe surge como resposta a áreas de plantações que contem espécies de *Acácia* sp, e *Brachystegia* sp e que refletem espectralmente de uma forma diferente. Também estão inclusas nesta classe as árvores esparsas que não estão nas machambas que por vezes formam um aglomerado, conforme a figura 12.




FIGURA 12 - CLASSE DA VEGETAÇÃO NATIVA

3.3.3. Avaliação da classificação

A valiação da segmentação foi completamente visual. Vários estudos dentre eles DLUGOSZ (2005) e ANTUNES (2003) apontam que a classificação quantitativa não apresenta maiores ganhos sobre a qualitativa (visual), contudo permite criar um ranking dos vários limiares.

Neste estudo utilizou-se a avaliação quantitativa da acurácia como uma forma de identificar e quantificar os erros nos mapas gerados. A classificação foi avaliada a partir de matriz de confusão gerando o índice Kappa e a acurácia global assim com o do usuário e do produtor para cada classe.

Para o efeito foram gerados amostras a partir de um mapa classificado visualmente e com a checagem em campo efetuado em Março e Abril de 2010. Este mapa tem a escala de 1:5000 favorecendo a escolha das amostras assim como o mapeamento com imagem Ikonos.

A partir do mapa interpretado visualmente foram gerados centróides de todas as classes mapeadas, tendo-se obtido 384 centróides, distribuídos em: agricultura e capim 81, Eucalipto 20, matagal 80, nuvem 3, pinus 60, solo 54, vegetação nativa 86.

As amostras encontram-se distribuídas em toda área conforme ilustra a figura 13. Depois foi feita a sobreposição no Arcgis 9.1 com as classificações dos níveis 1; 2 e 3 separadamente, gerando assim regiões comuns ou contidas nos centróides e nas classes.

A classe solo da classificação digital foi comparada com as classes solo, edificação, erosão e estradas e caminhos agrupados. As classes machamba e capim também foram agrupadas e comparadas com a classe agricultura e capim. A vegetação nativa foi comparada com a classe proveniente da junção das classes floresta nativa e regeneração nativa oriunda do mapa classificado visualmente.

Foram excluídos da análise os Pinus esparsos que na segmentação enquadra-se em outras classes, o viveiro, o Pinus com Eucalipto que no total constituíam 7 centróides (amostras).




FIGURA 13 - AMOSTRAS (CENTRÓIDES DAS CLASSES - INTERPRETAÇÃO VISUAL)

4. RESULTADOS E DISCUSSÕES

4.1. CORREÇÃO GEOMÉTRICA

O Erro Médio Quadrático Total (RMS) descreve o erro de posicionamento característico de todos os pontos de controle, indicando a probabilidade com a qual uma posição mapeada poderá variar em relação à sua localização verdadeira, (ROSOT, 2001). Observou-se um RMS total de 0,97m inferior a um pixel, isto é, inferior a um metro que é o tamanho do pixel da imagem Ikonos. OKIDA *et al* (2003), testaram o sistema de ortoretificação para imagens IKONOS II *OrthoEngine Ikonos Models*, analisando a precisão do produto ortoretificado. Os resultados obtidos mostraram-se satisfatórios (RSM = 0,73m), apesar dos vetores da restituição apresentarem uma diferença de 0,82 m entre vetor e imagem ortoretificada.

4.2. SEGMENTAÇÃO

Nesta fase, foram examinados os parâmetros de segmentação. Baseado na análise visual da segmentação foi possível detectar a separação de diferentes regiões, contendo classes espectralmente próximas entre si, que, provavelmente, não poderiam ser discriminadas pela classificação tradicional, uma vez que esta leva em consideração apenas o valor individual de cada pixel.

Os diferentes parâmetros de escala utilizados na segmentação das imagens geraram objetos de tamanhos variados, com isto algumas regiões visualmente distintas não foram separadas ao utilizar um parâmetro de escala maior. Neste caso, fica evidente que os parâmetros de escala que proporcionam segmentos médios são mais apropriados para a segmentação da área em questão, uma vez que somente utilizando segmentos médios foi possível captar a heterogeneidade espectral das diferentes classes de tipologias.

4.2.1. Segmentação de nível 1

Segmentação do nível 1 referiu-se aquele que tinha os seguintes parâmetros de segmentação: fator de escala 40 , fator de cor 0,8 , fator de forma 0,2 , com suavidade a 0,5 e compacidade de 0,5.

No nível 1 foram gerados segmentos menores, algumas áreas que visualmente pareciam ter uma informação espectral similar foram desagregadas, assim geraram-se segmentos que separaram áreas que visualmente se considerariam homogêneas e conseqüentemente seriam classificadas na mesma classe. Por outro lado os segmentos pequenos facilitaram a seleção das amostras para a classificação. Contudo a diferenciação espectral, mesmo em regiões homogêneas, criava médias espectrais e de brilho nos segmentos, o que resultou na distinção inadequada das classes.

Visualmente a figura 14 mostra ainda que regiões que posteriormente foram definidas na classe de solo apresentaram segmentos regulares.




FIGURA 14 - SEGMENTAÇÃO DE NÍVEL 1, FATOR DE ESCALA 40, FATOR DE COR 0,8 ,FATOR DE FORMA 0,2 ,COM SUAVIDADE A 0,5 E COMPACIDADE DE 0,5.

4.2.2. Segmentação de nível 2

Os parâmetros de segmentação do nível 2 foram os seguintes: fator de escala 80 , fator de cor 0,8 fator de forma 0,2 com suavidade a 0,5 compacidade de 0,5, conforme figura 15.

Neste nível foram gerados segmentos que foram considerados com sendo médios e já começava a identificar-se regiões que apresentavam agregações similares, isto é, as classes começavam a evidenciar-se. Mesmo sem classificação os objetos facilmente eram detectados e notava-se uma aparência visual da segmentação diferente do nível 1, onde os segmentos se pareciam mais com a imagem original (não segmentada).

Apesar de a diferenciação ser visual os segmentos apresentam-se melhores na segmentação, neste nível começa generalizar a informação gerando segmentos com tipologias distintas na mesma região.




FIGURA 15 - SEGMENTAÇÃO DE NÍVEL 2, FATOR DE ESCALA 80, FATOR DE COR 0,8 , FATOR DE FORMA 0,2 ,COM SUAVIDADE A 0,5 E COMPACIDADE DE 0,5.

4.2.3. Segmentação de nível 3

Neste nível os parâmetros usados foram: fator de escala 120, fator de cor 0,8 , fator de forma 0,2 , com suavidade a 0,5 e compacidade de 0,5.

No nível de segmentação 3 os segmentos gerados foram bastantes grandes. A partir deste nível quando se aumentava o parâmetro de escala, os segmentos tendiam a fundir-se mesmo em regiões em que visualmente as áreas podiam se distinguir.

A região na figura 16 marcada, pela elipse (em vermelho), contem 3 tipos florestais, duas espécies de eucalipto e uma espécie de Pinus mas neste parâmetro foi gerado

um segmento apenas o que levará a classificar-se como uma única tipologia e que na realidade são 3.

Pequenos detalhes espectrais foram ignorados no nível 3 e começam a realçar-se os parâmetros de forma mesmo tendo sido mantidos como os definidos na metodologia como padrão. Em contraste, regiões com mesma tipologia e que eram separadas nos nível 1 e 2 agora se agregaram.




FIGURA 16 - SEGMENTAÇÃO DE NÍVEL 3 FATOR DE ESCALA 120 , FATOR DE COR 0,8 , FATOR DE FORMA 0,2 , COM SUAVIDADE A 0,5 E COMPACIDADE DE 0,5.

4.4. CLASSIFICAÇÃO

Uma maneira de tornar a interpretação das imagens mais simples consiste em separar grupos de pixels, segmentos, regiões, com características espectrais semelhantes em classes de uso e cobertura, partindo da hipótese de que pixels cobrindo um mesmo alvo devem ter características espectrais semelhantes. Assim,

os algoritmos computacionais podem ser usados para “unir” pixels de uma imagem em grupos com características semelhantes.

O uso da segmentação foi eficiente, uma vez que permitiu a discriminação de objetos que possuem a mesma aparência espectral, porém pertencem a diferentes classes. Em cada imagem e para cada parâmetro de escala foi utilizado um conjunto diferente de atributos. No entanto foi possível observar que certos atributos são comuns nas imagens apesar da mudança no parâmetro de escala.

Os resultados da classificação estão apresentados nas figuras 17, 18 e 19. A textura rugosa presente nas tipologias de eucalipto, Pinus, matagais e vegetação nativa ajudou a separar uso solo, agricultura, *capim* e solo exposto. A textura em imagem foi definido como critério importante, porque segundo CENTENO, (2009), muitos elementos que não tem apresentado diferenças espectrais significativas podem ser diferenciados por sua textura, como o caso de campos de cultivos , solo nu, áreas urbanas e áreas florestais.

A média e o brilho foram usados também para separar os objetos e classificar a imagem. Contudo as classes de matagal e agricultura tinham características espectrais similares e de difícil discriminação.

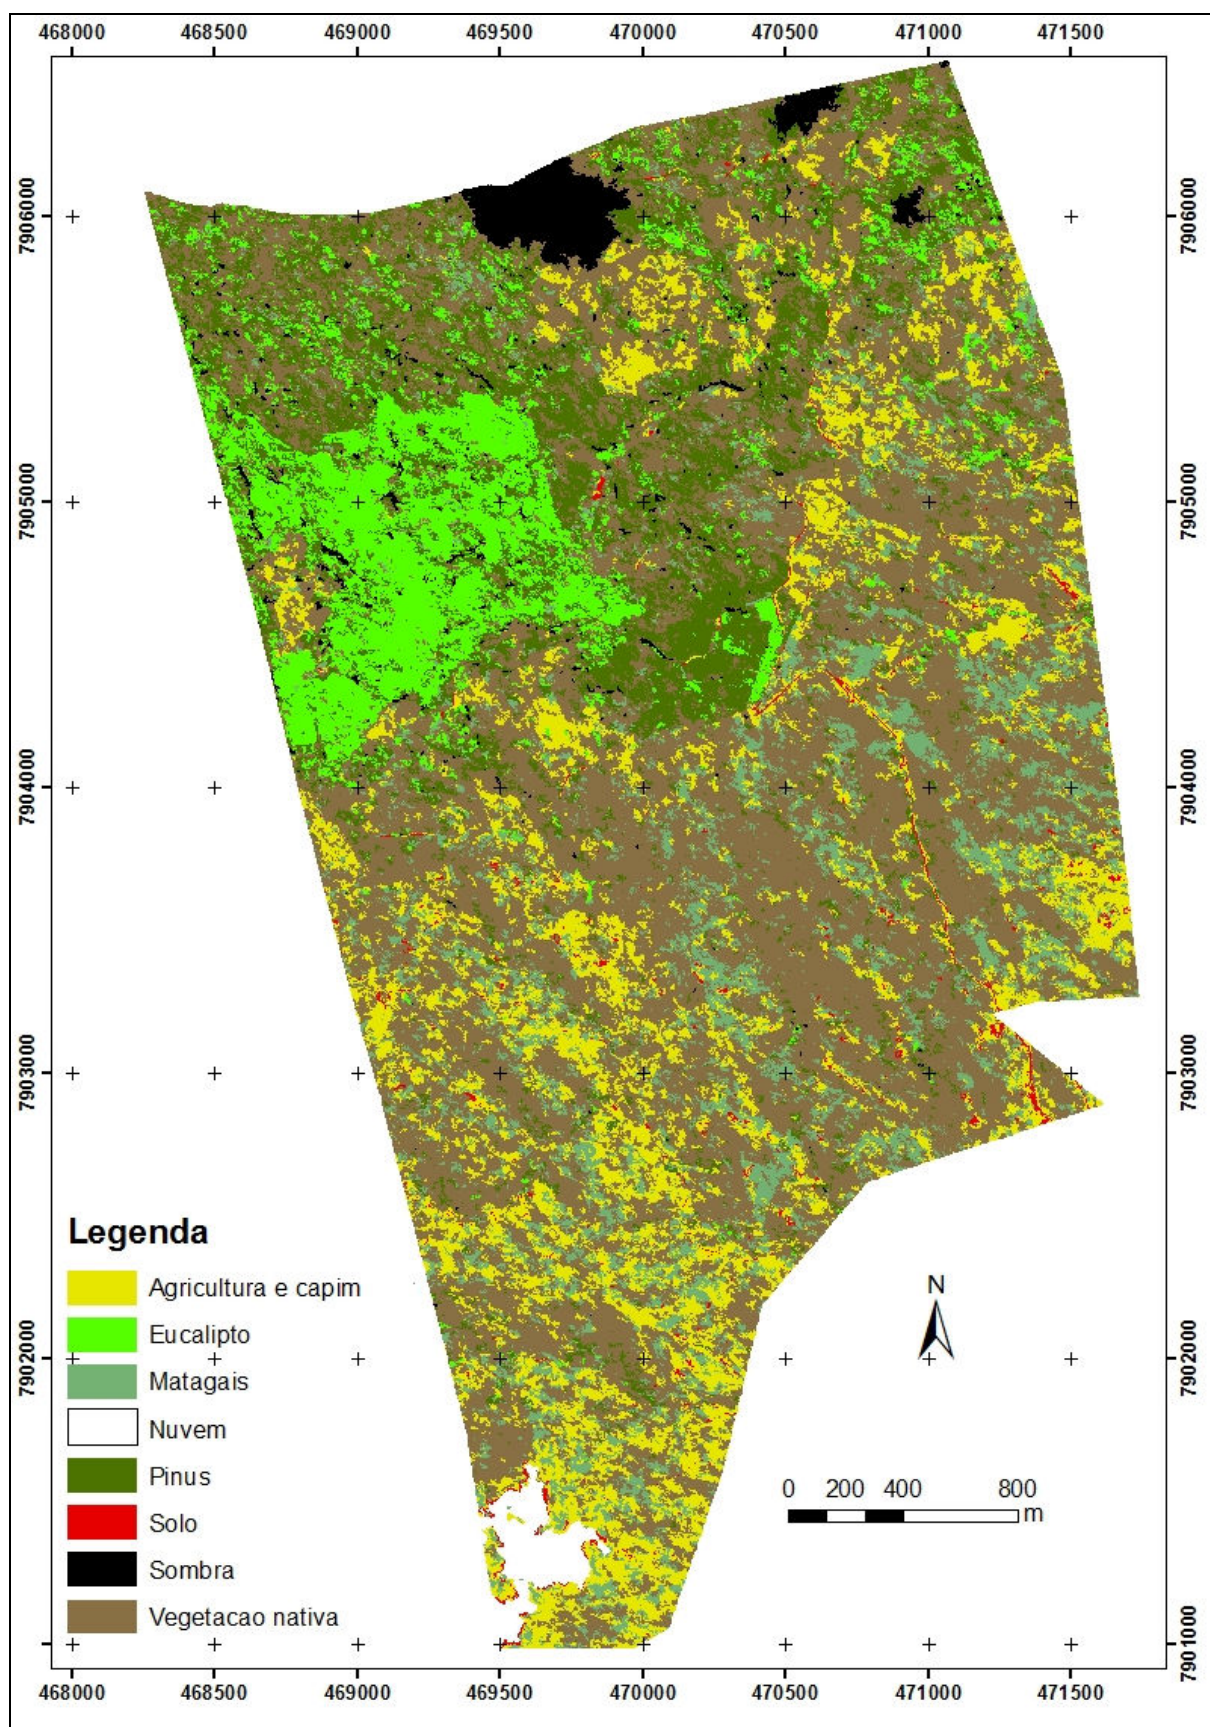


FIGURA 17 - IMAGEM DA CLASSIFICAÇÃO DA SEGMENTAÇÃO DO NÍVEL 1

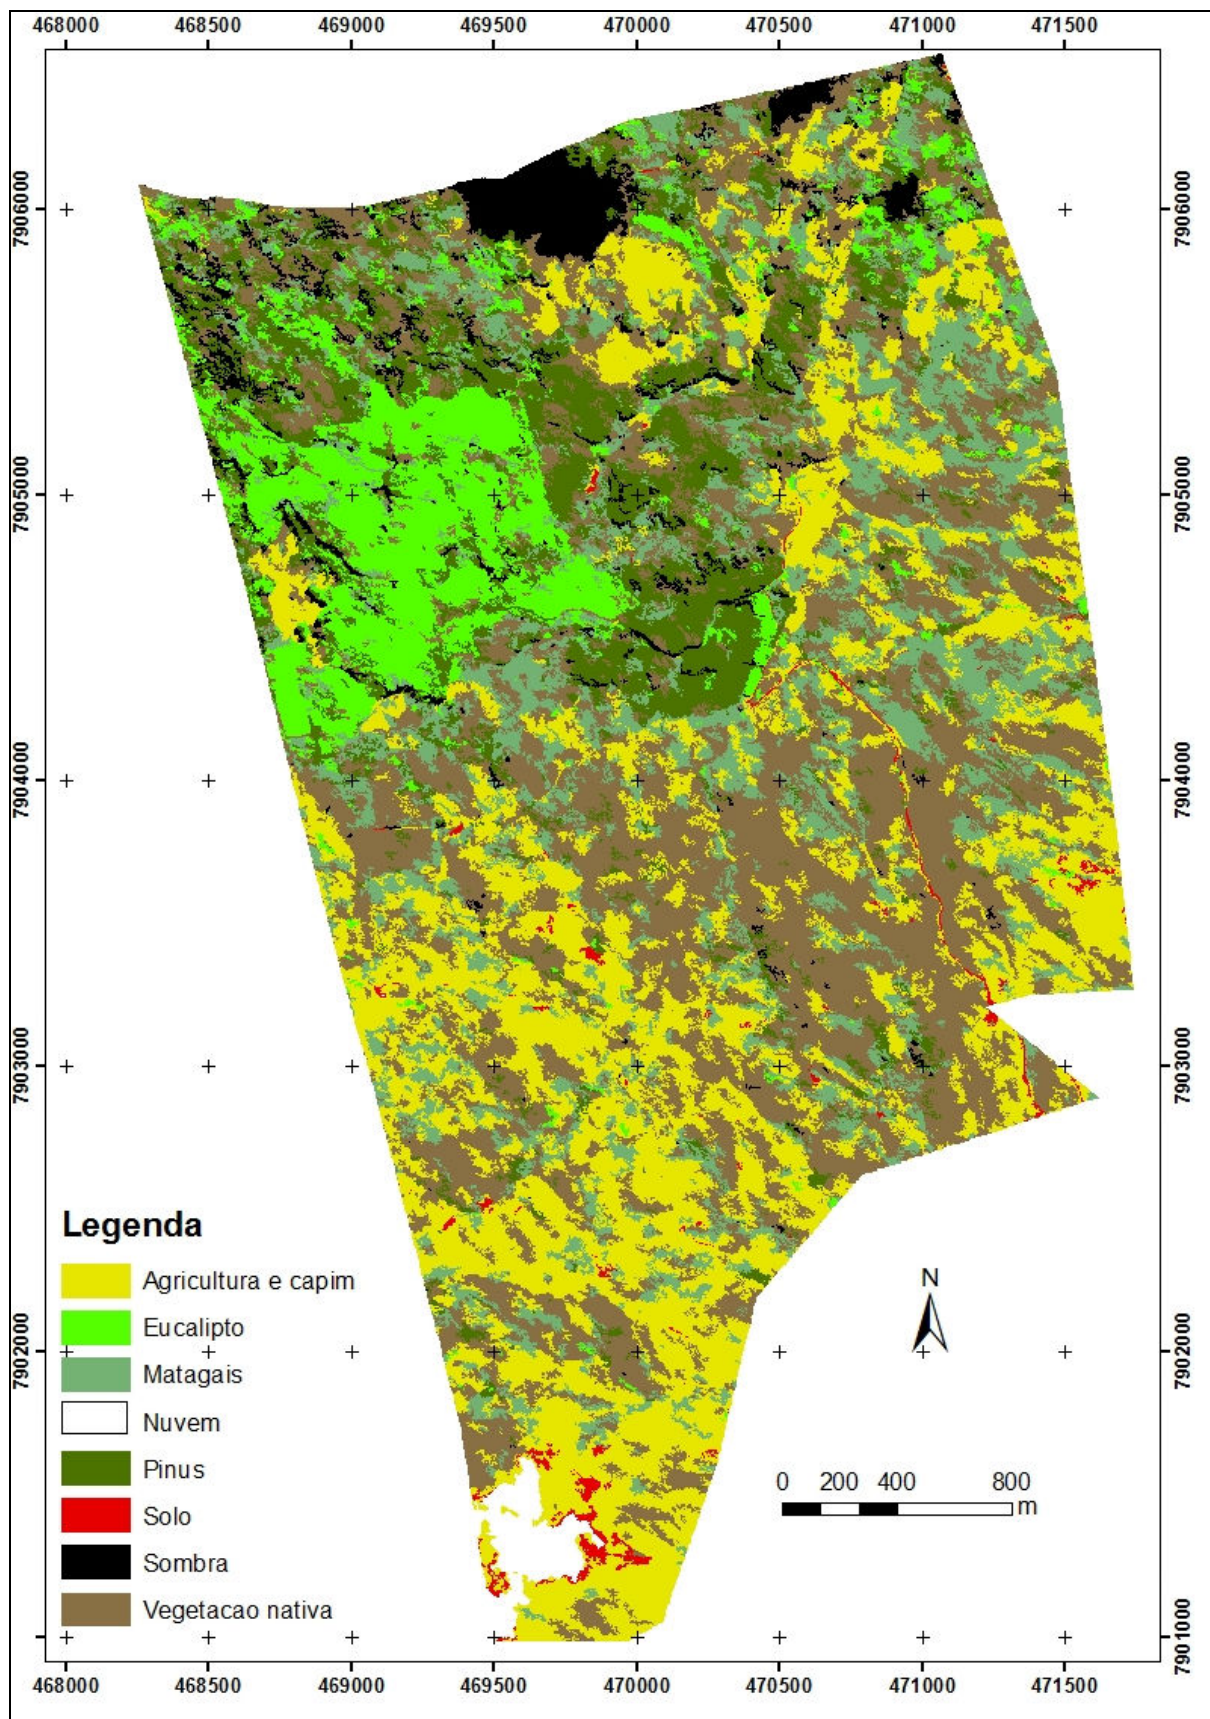


FIGURA 18 - IMAGEM DA CLASSIFICAÇÃO DA SEGMENTAÇÃO DO NÍVEL 2.

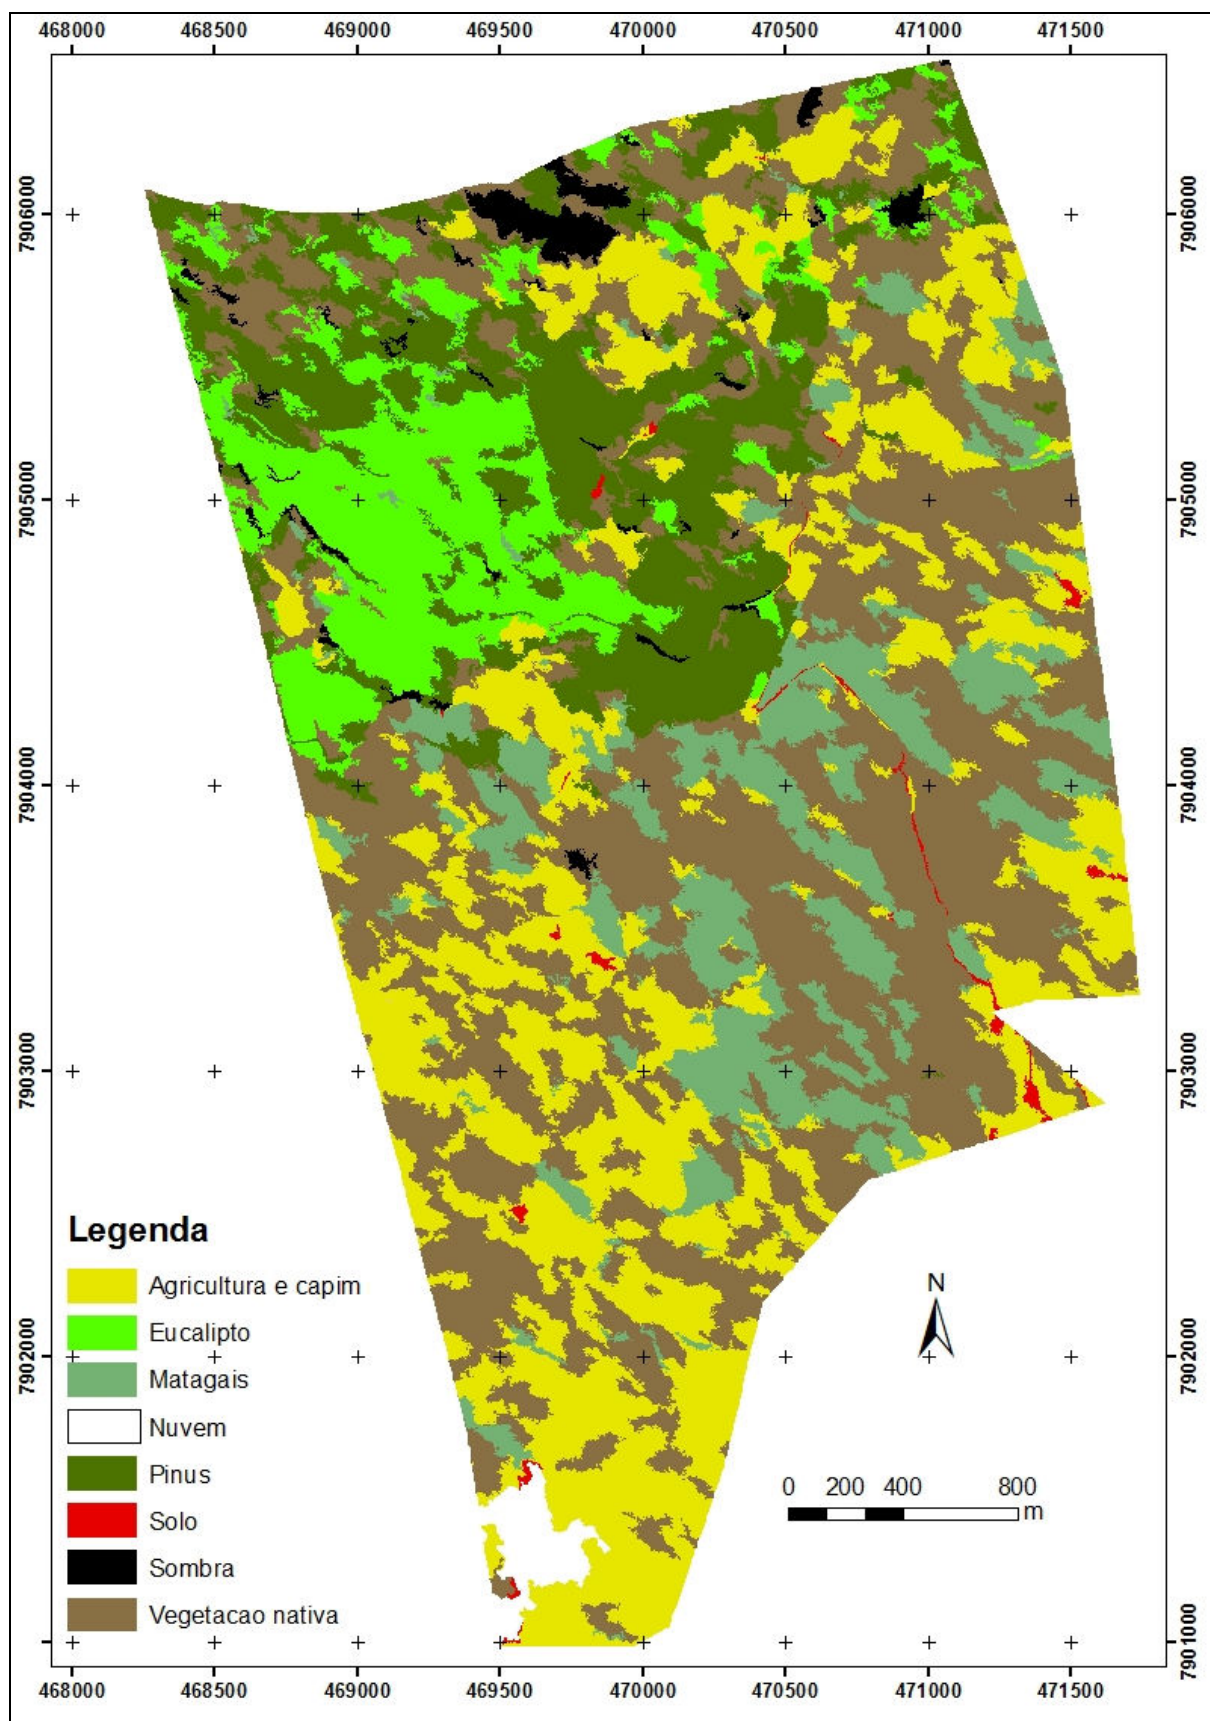


FIGURA 19 - IMAGEM DA CLASSIFICAÇÃO DA SEGMENTAÇÃO DO NÍVEL 3.

4.3.1. Quantificação das áreas

A tabela 5 mostra que, da área total de cerca de 1175 ha, a maioria está coberta por vegetação nativa com 576,489 ha na classificação de nível 1 de segmentação, 385,139 ha na classificação de nível 2 de segmentação e 439,584 ha na classificação de nível 3, seguida de áreas com agricultura e capim em mesmo níveis respectivamente, cobrindo uma área de 164,677 ha, 302,856ha e 289,688 ha .

Estas duas classes, agricultura-capim e vegetação nativa, são as que mais sofreram o efeito dos parâmetros da segmentação. Aparentemente são as que tornaram a classificação da segmentação ruim no fator de escala de 40, porque na classificação do nível 1 a agricultura e *capim* ocupavam apenas 165 ha e a vegetação nativa 577 ha, porém nos níveis subseqüentes a agricultura ganhou cerca de 150 ha enquanto a vegetação nativa perdia cerca 160 ha.

TABELA 5 - ÁREAS OCUPADAS PELOS DIFERENTES TIPOS DE USO DE SOLO E COBERTURA

Tipo	Área Nível1E:40 (ha)	Área Nível2 E:80 (ha)	Área Nível3 E:120 (ha)
Agricultura e capim	164,677	302,856	289,688
Eucalipto	107,473	101,759	116,865
Matagais	121,553	184,579	130,357
Nuvem	10,642	11,148	11,261
Pinus	162,184	136,553	164,972
Solo	7,016	7,907	4,558
Vegetação nativa	576,489	385,139	439,584
Sombra	24,213	44,267	16,917
Não classificada	0,004	0,009	0,007
Total	1174,251	1174,217	1174,210

Maior motivo que possa ter influenciado na classificação destas duas classes deve-se ao tipo de agricultura praticada na região de Inhamacari, onde os campos agrícolas são abertos no meio da floresta, e deixando-se muitas árvores em pé nas machambas. Some-se a esta constatação que a agricultura é do tipo *shifting*

cultivation onde a produção é feita por um período, abandona-se o campo após alguns anos e este passa a uma fase sucessional na qual a vegetação em pé tende a fechar o dossel e retorna às florestas, mesmo degradadas.

As árvores isoladas ou agrupadas nos campos agrícolas se faziam confundir espectralmente com a vegetação nativa e isto teve como consequência a geração de segmentos pequenos.

As classes de Pinus, Eucalipto, matagais, solo e nuvem mantiveram-se em todos os níveis de segmentação e consequentemente na classificação. Assim as áreas classificadas são ilustradas na figura 20 e na tabela 5 onde a tipologia de Pinus e Eucalipto tiveram uma ligeira queda de 30 ha e 5 ha respectivamente na segmentação e classificação, sendo considerada a melhor classificação.

As classes foram as que tiveram mais amostras de treinamento assim como descritores. Contudo a falta de conhecimento espectral inicial fez gerar confusão nas duas classe principalmente na análise de Pinus jovem e misturas de *Eucalyptus saligna* e *grandis* que se confundem mesmo no infra-vermelho próximo e provavelmente se separariam apenas no infravermelho médio. Mesmo assim, as classes se distinguiram usando-se mais amostras de cada classe na forma pura, isto é, áreas sem mistura de Eucalipto e com Pinus no estado avançado.




FIGURA 20 - ÁREAS OCUPADAS POR CADA CLASSE DE USO E COBERTURA EM CADA NÍVEL RESULTANTE DA CLASSIFICAÇÃO.

Assim as áreas de Pinus sp e Eucalyptus sp de 136,553 ha e 101,759 ha respectivamente apresentadas são as que melhor representam a área real e aproximam-se às encontradas por MRE e ABC (2010), que na classificação visual da mesma imagem obtiveram 113,800 ha de Pinus sp e 101,710 ha para Eucalyptus sp. Estes autores definiram uma classe denominada “floresta mista” representada pela mistura de Pinus, Eucalipto e vegetação nativa, que neste estudo foi espectralmente separada e realocada nas três classes separadamente e sucessivamente nas classes de Pinus, Eucalipto e vegetação nativa.

As classes de nuvem e sombra foram também de difícil separação das amostras, pois, na imagem havia uma zona de convergência com as outras classes e para o caso de sombra ela criava uma sobreposição às outras classes, contudo a área representada por esta classe foi 44,267 ha.

A região não classificada em todos os níveis de segmentação é totalmente desprezível e não chegou a atingir um centésimo de hectare tendo ficado com as seguintes marcas: nível 1 de 0,004 ha; nível 2 de 0,009 ha e nível 3 de 0,007 ha.

4.3.2. Avaliação da classificação

O resultado da classificação gerou uma acurácia global (geral) de 55,5% e um valor do índice Kappa de 0,46 para a classificação da segmentação no nível 1; uma acurácia global (geral) de 76,6% e um valor do índice Kappa de 0,71 para a classificação na segmentação do nível 2 e uma acurácia global (geral) de 61,5% com um valor do índice Kappa de 0,53 para a classificação na segmentação do nível 3.

Estes resultados quando comparados com os da tabela 3 referentes ao estudo de Landis Koch adaptado por MOREIRA (2001), permitiu afirmar que a classificação teve o desempenho bom para os níveis de segmentação 1 e 3, tendo-se obtido ainda melhor desempenho para a classificação do nível 2 de segmentação, sendo considerado como muito bom.

Outros estudos, com as imagens Ikonos a partir de segmentação avaliando-se a classificação com redes neurais, obtiveram resultados relativamente menores como é o caso da ANDRADE e CENTENO (2003) que introduziram no modelo neural as bandas Infravermelho próximo, vermelho e verde e obtiveram uma acurácia global de 61,1%. ALVES VERGARA (2005) na identificação de alvos urbanos em imagens Ikonos, aplicou a classificação orientada a segmentos e obteve uma acurácia global de 88,5% e um valor global de índice Kappa de 0,86 e quando analisou a vegetação obteve resultados de 76,9% para acurácia global e 0,74 de valor de índice Kappa sendo similares aos encontrados neste estudo.

As matrizes de confusão apresentadas nas tabelas 6, 7 e 8 ilustram as contradições entre a verdade de campo produzida a partir do centróide de mapa gerado visualmente e confrontado em campo e o resultado de processo de classificação. Aqui foi confrontado as linhas que correspondem à classe correta e as colunas estimadas no processo de classificação.

Analisando-se a tabela 5 referente à classificação da segmentação do nível 1 verificou-se que a agricultura e capim geraram maior confusão com matagais e vegetação nativa, provavelmente pelo mesmo justificado e explanado no item 4.3.1 referente ao tipo de agricultura e as formações florestais que são montanha com

árvores esparsas se confundindo com áreas agrícolas. Os matagais são formações com árvores esparsas e com muita vegetação rasteira que pode-se confundir facilmente com culturas agrícolas. Na tabela 6, ainda pode ser verificado a confusão resultante de Eucalipto e Pinus, Matagais e Vegetação Nativa. As formações jovens de Pinus tem uma resposta espectral próxima com a de mistura de Eucalipto, gerando assim confusão na classificação. Quanto à vegetação nativa e matagais, algumas espécies como é o caso das *Brachystegia sp* que no período que foi obtida a imagem apresentavam-se vigorosas e confundidas facilmente com Eucalipto.

A classe de matagal gerou também confusão na classificação com as classes de agricultura e vegetação nativa. As espécies presentes na classe de vegetação nativa, isoladamente em alguns casos, são similares às dos matagais diferindo apenas no estágio sucessional. Contudo podem possuir reflectância semelhante e conseqüentemente gerar erros na classificação.

A vegetação nativa gerou confusão com quase todas as outras classes, exceto com as classes de nuvem e solo.

TABELA 6 - MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO PELO VIZINHO MAIS PRÓXIMO E LÓGICA FUZZY PARA NÍVEL 1 DE CLASSIFICAÇÃO

Classe	Agricul.	Euc	Matagal	Nuvem	Pinus	Solo	Veg. Nat	Total
Agricul.	28	1	15	0	5	4	7	60
Euc.	0	11	0	0	3	1	10	25
Matagal	15	1	53	0	1	6	5	81
nuvem	0	0	0	2	0	0	0	2
Pinus	4	2	4	0	37	2	18	67
Solo	14	0	0	0	0	36	0	50
Veg. Nat	20	5	8	1	14	5	46	99
Total	81	20	80	3	60	54	86	384

A tabela 7 mostra também que a classe de agricultura gerou confusão com as classes de matagal, vegetação nativa, pinus, eucalipto e solo. A classe eucalipto mostrou-se estável na classificação da segmentação do nível 2 tendo apresentado confusão com Pinus, provavelmente devido à região das plantações estar concentrada no mesmo local e misturas destas espécies em alguns casos.

A classe de matagal comportou-se como era de se esperar, a partir dos resultados verificados na classificação da segmentação do nível 1, gerou maior confusão com as classes de agricultura pinus e vegetação nativa.

TABELA 7 - MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO PELO VIZINHO MAIS PRÓXIMO E LÓGICA FUZZY PARA NÍVEL 2 DE CLASSIFICAÇÃO

Classe	Agricul	Euc	Matagal	Nuvem	Pinus	Solo	Veg. Nat	Total
Agricul	62	1	8	0	2	7	2	82
Euc.	1	15	0	0	3	0	1	20
Matagal	8	1	58	0	4	4	3	78
Nuvem	0	0	0	3	0	0	0	3
Pinus	3	2	3	0	44	0	8	60
Solo	1	0	0	0	0	40	0	41
Veg. Nat	6	1	11	0	7	3	72	100
Total	81	20	80	3	60	54	86	384

A tabela 8 mostra certa confusão na classificação de agricultura, matagais e vegetação nativa e solo exposto, percebendo-se facilmente esta confusão pelo fato de existência, nas áreas agrícolas, locais sem cobertura por culturas que foram englobados no processo de geração de segmentos como agricultura pela generalização do processo de segmentação e conseqüentemente classificados como solo. Analogamente o mesmo sucede-se com a vegetação nativa e os matagais que não são formações muito compactas tendo uma lacuna com capim, mas sendo incluída no processo de segmentação a uma destas classes.

A vegetação nativa apresentou maior confusão com as classe de agricultura, eucalipto, matagal e curiosamente com maior destaque com a classe de Pinus. As espécies *Uapaca* sp quando observadas na composição Infravermelho próximo – vermelho- verde (IVP-R-G), assim como na composição RGB mostram semelhanças de resposta espectral com Pinus o que poder levar a geração de confusão.

TABELA 8 - MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO PELO VIZINHO MAIS PRÓXIMO E LÓGICA FUZZY PARA NÍVEL 3 DE CLASSIFICAÇÃO

Classe	Agricul.	Euc	Matagal	Nuvem	Pinus	Solo	Veg. Nat	Total
Agricul.	28	1	1	0	6	2	17	55
Euc.	0	9	1	0	6	0	11	27
Matagal	15	1	76	0	2	0	7	101
Nuvem	0	0	0	3	0	0	0	3
Pinus	4	5	0	0	35	0	17	61
Solo	14	0	0	0	0	52	1	67
Veg. Nat	20	4	2	0	11	0	33	70
Total	81	20	80	3	60	54	86	384

Analogamente foi avaliada a acurácia do produto e do usuário e os resultados estão apresentados nas tabelas 9, 10 e 11.

A tabela 9 mostra baixa exatidão tanto do ponto visto do usuário assim como do produtor, tendo-se obtido valores abaixo de 75% quando a acurácia for observada do ponto de vista de produtor para todas as classes. Nas classes de nuvem, solo e matagal apresentaram relativamente valores mais altos de 100%, 96,3% e 95% respectivamente. Do ponto de vista do usuário, a classe nuvem foi a que melhor acurácia apresentou com 100%. Estes resultados também foram observados quando foram analisados os erros de omissão e erros de comissão onde a classe de agricultura e capim obteve erros altos de 65,4% e 66,7%.

TABELA 9 - ACURÁCIA DO PRODUTOR E DO USUÁRIO PARA A CLASSIFICAÇÃO DO NÍVEL 1 DE SEGMENTAÇÃO

	Exat. Produtor (%)	Exat. Usuário (%)	Erro omissão (%)	Erro comissão (%)
Agricultura e capim	34,6	50,9	65,4	49,1
Eucalipto	45,0	33,3	55,0	66,7
Matagal	95,0	75,2	5,0	24,8
Nuvem	100,0	100,0	0,0	0,0
Pinus	58,3	57,4	41,7	42,6
Solo	96,3	77,6	3,7	22,4
Vegetação Nativa	38,4	47,1	61,6	52,9

A tabela 10 apresentou melhores resultados sendo quase todos eles acima dos 75% sob ponto de vista do usuário assim como sob ponto de vista de produtor, exceto as classes de matagal e vegetação nativa que tiveram valores relativamente baixos de 74,4% e 72,0% respectivamente e também quando se observa a acurácia do usuário e as classes de Matagal e Solo com respectivamente 72,5%; 73,3% e 74,1%. Os melhores resultados da classificação foram obtidos nas classes de nuvem com 100,0% e vegetação com 83,7% do ponto de vista do produtor. Analisando do ponto de vista do usuário as classes que se destacaram foram de nuvem, solo, eucalipto e agricultura-capim com 100%, 97,6%, 75,0% e 75,6% de exatidão respectivamente.

No nível 2 obteve-se a maior acurácia global. Também na imagem apresentada na figura 18 pode-se observar a melhor aparência visual destes melhores resultados.

TABELA 10 - ACURÁCIA DO PRODUTOR E DO USUÁRIO PARA A CLASSIFICAÇÃO DO NÍVEL 2 DE SEGMENTAÇÃO

	Exat. Produtor (%)	Exat. Usuário (%)	Erro omissão (%)	Erro comissão (%)
Agricultura e capim	76,5	75,6	23,5	24,4
Eucalipto	75,0	75,0	25,0	25,0
Matagal	72,5	74,4	27,5	25,6
Nuvem	100,0	100,0	0,0	0,0
Pinus	73,3	73,3	26,7	26,7
Solo	74,1	97,6	25,9	2,4
Vegetação Nativa	83,7	72,0	16,3	28,0

A tabela 11 apresenta acurácia do produtor e do usuário para a classificação do nível 3 de segmentação onde se observa que as classes de Agricultura e *capim* assim como a do Eucalipto tiveram péssima classificação sob ponto de vista do produtor assim como do usuário sendo de 34,6% e 45% de exatidão do produtor respectivamente e para a acurácia de 33,3% e 50,9% para o usuário. A mesma tabela apresenta ainda que as classes de Nuvem e Matagal obtiveram melhores resultados sob ponto de vista de usuário com 100% e 75,2%, e quanto ao produtor as mesmas classes destacaram-se conjuntamente com classe de solo sendo as percentagens de 100% para a classe de nuvem, 96,3 % para classe de solo e 95% para a classe de matagal.

TABELA 11 - ACURÁCIA DO PRODUTOR E DO USUÁRIO PARA A CLASSIFICAÇÃO DO NÍVEL 3 DE SEGMENTAÇÃO

	Exat. Produtor (%)	Exat. Usuário (%)	Erro omissão (%)	Erro comissão (%)
Agricultura e capim	34,6	50,9	65,4	49,1
Eucalipto	45,0	33,3	55,0	66,7
Matagal	95,0	75,2	5,0	24,8
Nuvem	100,0	100,0	0,0	0,0
Pinus	58,3	57,4	41,7	42,6
Solo	96,3	77,6	3,7	22,4
Vegetação Nativa	38,4	47,1	61,6	52,9

Os resultados obtidos também foram encontrados por TUZINE et al. (2011) na identificação de tipologias florestais em Machipanda, Moçambique a partir da segmentação de imagens IKONOS, onde foi verificado que o número de segmentos

não depende apenas do parâmetro de escala. Os experimentos comprovam que a quantidade de segmentos depende também da informação espectral utilizada e dos pesos atribuídos a cada banda espectral. Quando se usa o NDVI e a banda do azul, os objetos tendem a serem maiores e não ocorrem regiões extremamente pequenas, o que comprova que a discriminação de tipologias depende muito da informação presente na banda do infravermelho próximo.

5. CONCLUSÕES E RECOMENDAÇÕES

A análise qualitativa da segmentação permitiu concluir que o parâmetro de escala, mantendo fixo o parâmetro de forma, é a ferramenta que auxilia na identificação de tipologias florestais.

Foram identificadas 6 tipologias florestais de uso e cobertura de solo. Agricultura e Capim, Eucalipto, Matagal, Pinus, Vegetação Nativa e Solo.

A floresta encontra-se coberta majoritariamente pela vegetação nativa ocupando 385,139 ha seguida de agricultura e capim 302,856 ha e matagais com 184,579 ha.

Os povoamentos de Pinus e Eucalipto ocupam uma área de 238,312 ha perfazendo conjuntamente 20,3% da área total. O Pinus ocupa uma área de 136,553ha e o Eucalipto 101,759 ha.

A classificação nos níveis 1 e 3 (com parâmetro de escala de 40 e 120 respectivamente) teve o desempenho bom. O desempenho da classificação foi muito bom para o nível 2 de segmentação, correspondendo a segmentação de 80 para fator de escala; 0,8 de fator de cor e 0,2 de fator de forma.

Para as condições da floresta de Inhamacari a melhor combinação de limiares foi de 80 para fator de escala 0,8 de fator de cor e 0,2 de fator de forma subdividida em compacidade de 0,5 e 0,5 de suavidade.

Realizado estudo em concordância com as conclusões, recomenda-se:

Realizar a segmentação hierárquica com o eCognition para verificar a separabilidade dos tipos florestais e melhorar o desempenho da classificação.

Testar outros parâmetros de cor e forma e avaliar quantitativamente a segmentação utilizando outras ferramentas e índices de avaliação

REFERÊNCIAS BIBLIOGRÁFICAS

- ALVES, R. DE A. L. e VERGARA, O.R. Identificação de alvos urbanos em imagens Ikonos, aplicando classificação orientada a segmentos. **In Anais**. SBSR, Goiânia, Brasil, 16-21 de Abril de 2005, INPE, P2573-2580
- ANDRADE, A. F. e CENTENO, J. A. S. Integração de informações espectrais e de forma na classificação de imagens com redes. **Boletim de Ciências Geodésicas**, sec. Artigos, Curitiba, v. 9, no 2, p.217-231, jul-dez, 2003
- ANTUNES, A. F. **Classificação de ambiente ciliar baseada em orientação a objetos em imagens de alta resolução**. Curitiba, 2003. Tese (Pós Graduação em Ciências Geodésicas) - Universidade Federal do Paraná.
- BAATZ M. AND SCHAPE A., **Multiresolution Segmentationan Optimization Approach for High Quality Multi-scale Image Segmentation**. 2007. <http://www.definiens-imaging.com> (acesso 22-08-2010).
- BAUER, T.; STEINNOCHER, K. Per-parcel land use classification in urban areas applying a rule-based technique. **Journal for Spatial Information and Decision Making**. 2001. n. 6/01, pp. 24 - 27
- BARCA, A. **Perfil Físico**: Coleção “Conhecer Moçambique 1”. Editora Escolar. . 1992
- BENZ, U. C., HOFMANN, P., WILLHAUCK, G., LINGENFELDER, I., HEYNEN, M. Multi-resolution, object-oriented *fuzzy* analysis of remote sensing data for GIS-ready information. **Journal of Photogrammetry & Remote Sensing** 58, p. 239-258, 2004.
- BLASCHKE, T.; STROBL, J. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. In: GeoBIT/GIS 6: 12-17. 2001 : <<http://www.definiens.com>>. Acesso em Novembro de 2010.
- CENTENO, J. A. S. **Sensoriamento e Processamento de Imagens Digitais**. Curitiba Ed. Curso de Pós Graduação em Ciências Geodésicas UFPR, 2003.

CENTENO, J. A. S. **Sensoriamento e Processamento de Imagens Digitais**. Curitiba Ed. Curso de Pós Graduação em Ciências Geodésicas UFPR, 2ª edição, 2009.

CHAMBA, E., **Inventario florestal das plantações de Inhamacari**, trabalho de culminação de licenciatura em engenharia florestal. Universidade Eduardo Mondlane (UEM-DEF), Maputo. 1994. Não publicado

CONGALTON, R. A review of assessing the accuracy of classifications of remotely sensed data. **Remote Sensing of Environment**, v.37, n.1, p.35-46, jul.1991.

CROSTA, Á. P. **Processamento Digital de Imagens de Sensoriamento Remoto** Ed. Rev. –Campinas, SP: IG/UNICAMP, 1993.

DEF. **Relatório das AJU's de 1999** Universidade Eduardo Mondlane (UEM-DEF), Maputo. 1999. Não publicado

DEFINIENS IMAGING. **User Guide 4.0**. eCognition, 468p 1994.

DLUGOSZ, F. L. **Classificação orientada a regiões na discriminação de tipologias de floresta ombofila mista usando imagens orbitais IKONOS**. Curitiba: Dissertação (Mestrado em Ciências Florestais – Manejo Florestal). Universidade Federal do Paraná. 152p. 2005

ENGESAT, **IKONOS II** http://www.engesat.com.br/index.php?system=news&news_id=494&action=read (acesso 24-10-2010).

FERRO, B.P., & BOUMAN, D. *Hydrogeological map of Mozambique*. Ministry of Construction and Water of Mozambique /UNICEF. 1987 Maputo

FORD, G .E.; ZANELLI, C. I. Analysis and quantification of errors in the geometric correction of satellite images. **Photogrammetric Engineering and Remote Sensing**. v.51, n.11. p. 1725-1734. 1985.

GONÇALVES, L.; FONSECA, A.M.; CAETANO, M. **Exploração de imagens de alta resolução do satélite IKONOS**. LISBOA: ESIG. 1-22p.2001.

GATES,D.M. **Biophysical ecology**. New York: Springer-Verlag. 611p. 1980.

GATES,D.M.;KEEGAN,H.J.; SCHLETER,J.C.; WEIDER,V.R. **Spectral properties of plants**. Applied Optics, v.4, n.1. 1-20p. 1965.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. São Paulo: Ed. Edgard Blücher. 509p. 2000.

GOWARD,S.; TOWNSHEND, J.; DAVIS, P.; FLAMING,D. **Radiometric Comparison of IKONOS e Landsat 7 ETM+ Observations: Implications for Science Applications**. High Spatial Resolutions Commercial Imagery Workshop. Maryland: Greenbelt. 2001.

GUYOT, G. **Optical Properties of vegetation canopies** – applications of Remote Sensing in Agriculture. Ed. Butterworths. France. Pág 427. 1990.

GUYOT, L. A.; GUYON, D.; RIOM, J. Factors affecting the spectral response of forest canopies: a review. **Geocarto International**, v. 4, n. 3, p. 3-18, Set. 1989.

HOFFER, R.M. **Biological and Physical Considerations in Applying Computer-aided Analysis Techniques to Remote Sensor Data**. In: SWAIN, P.H.; DAVIS, S.M., Ed. Remote Sensing the Quantitative Approach, New York: McGraw Hill, cap 5, pág. 89-228. 1978.

HOFMANN, P. **Detecting building and roads from IKONOS and DEM data with eCognition**. eCognition Application Note. Vol. 2, No. 5, August 2001. Disponível em: <<http://www.definiens-imaging.com>> Acesso em: Outubro de 2010.

JACKSON, R.D.;HUETE, A.R. Interpreting vegetation indices. **Preventive Veterinary Medicine**, v.11,n. 3-4,p.185-200,1991.

JENSEN, J.R.; **Introductory Digital Image Processing: A Remote Sensing Perspective**, 2nd ed. Upper Saddle River, NJ: Prentice-Hall, 1996.

KOFFER, N.F. Técnicas de sensoriamento remoto orbital aplicadas ao mapeamento da vegetação e uso da terra. **Geografia**. V.17,n.2. 14-17p. 1992.

LILLESAND, T.M.& KIEFER, R.W. **Remote Sensing and Image Interpretation**. John Wiley & Sons, Inc. 4th ed., New York: Wiley, 2000 721 p.

LUIZ, S.; OLIVEIRA, C. G.; OKIDA, R. Comparação entre diferentes métodos de correção geométrica em imagem RADARSAT-1 no Flona Tapajós, **In: Anais XI SBSR**, Belo Horizonte, Brasil. 2003, INPE, p. 325-33.

LUZ, N. B. **Análise espacial como subsídio à recuperação de ecossistemas apoiada na ecologia de paisagens e imagens ikonos**. Curitiba: Dissertação (Mestrado em Ciências Florestais – Manejo Florestal). Universidade Federal do Paraná. 126p. 2002.

MASCARENHAS, N. D. A.; VELASCO, F. R. D. **Processamento Digital de Imagens**. Editora Kapelusz. Buenos Aires, 1989.

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

MARZOLI, A. **Inventário florestal nacional** - Avaliação integrada das florestas de Moçambique-DNTF edição Ebanó Lda, Maputo 2008.

MINISTÉRIO DAS RELAÇÕES EXTERIORES DO BRASIL (MRE) e AGÊNCIA BRASILEIRA DE COOPERAÇÃO (ABC) **Mapa Planimétrico de Uso da Terra Floresta de Inhamacari** PROJECTO - BRA/04/044 SUB-PROJECTO - S162. Maputo 2010. Não publicado

MOIK, J. G. **Digital processing of remotely sensed images**. Washington: NASA, 1980, 330 p.

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

MOREIRA, M. A. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 3 edição. 2005. Editora UFV.320p.

MUCHANGOS, A. dos. Moçambique, **Paisagens e Regiões Naturais**. Maputo Edição: do Autor. 1999.

NOVO, E.M.L.M. **Sensoriamento remoto: princípios e aplicações**. São Paulo: Edgard Blucher, 1993. 308p.

OKIDA, R.; LUIZ,S.; OLIVEIRA, C.G. Avaliação da precisão de orto-imagens IKONOS **Anais XI SBSR**, Belo Horizonte: 05-10 abril 2003. INPE. 285-292p. 2003.

PEREIRA, C. R. **Inventario do Eucaliptal de Inhamcari**. Maputo, Universidade Eduardo Mondlane (UEM-DEF). 1998. Não publicado

PONZONI, F.J. e SHIMABUKURO,Y.E. **Sensoriamento Remoto no estudo da vegetação** são Jose doa campos, SP: A . Silva Vieira Ed., 2009 127 p

RIBEIRO, S. A.; SANTOS, D. R.; CENTENO, J. S.; Aplicação da Metodologia de Dados Orientado a Objeto na Classificação de uma Área Urbanizada, Utilizando uma Imagem Digital obtida por meio da Tecnologia do Laser Scanner. In: Simpósio Brasileiro de Geomática. Presidente Prudente, S.P., 2002. **Anais**. CD.

RICHARDS, J.A.; **Remote Sensing Digital Image Analysis : An Introduction**, 4th ed, Springer, 1993 ISBN: 3540251286.

ROLIM, F. A. **Análise de classificação orientada ao objeto em imagens de alta resolução para o auxílio ao monitoramento ambiental em uma microbacia hidrográfica**. Curitiba, 2003. 107 f. Dissertação de Mestrado, Universidade Federal do Paraná.

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 (Doutorado em Engenharia de Produção). Universidade Federal de Santa Catarina-UFSC, Florianópolis-SC. 2001.

SCHOWENGERDT,R.A. **Remote Sensing: Models and Methods for Image Processing**. 2nd Edition, Academic Press, Inc, 1997.

SILVA, D. A. DA **Técnicas de segmentação de imagens multiespectrais no espaço decores**. São José dos Campos: INPE. 1995. 33 p. (INPE-5639-PUD/071).

SOUSA, A. M. O.; MESQUITA, P.; GONÇALVES, A. C.; SILVA, J. R. M. DA; segmentação e classificação de tipologias florestais a partir de imagens QUICKBIRD **IX Seminário de Atualização em Sensoriamento Remoto e Sistemas de Informações Geográficas Aplicados à Engenharia Florestal** Curitiba, 2010 CD-ROM.

STURM, U.; ANTUNES, A.F.; LINGNAU, C.; BAHR, H.P.; Análise da ocupação em áreas de preservação permanente (APP) na área urbana do município de Matinhos utilizando a imagem IKONOS II. **In: Anais do II Colóquio Brasileiro de Ciências Geodésicas**. 2003, Curitiba: Anais do III colóquio Brasileiro de ciências geodésicas, v.1 1-15p. 2003.

SWAIN, P.H.; DAVIS, S.M. **Remote Sensing: The quantitative approach**. New York McGraw-Hill, 396p. 1978.

TUZINE, M. S.; ROSOT, N. C, E CENTENO J. A. S. Identificação de tipologias florestais em Machipanda, Moçambique, a partir da segmentação de imagens IKONOS, XV Simpósio Brasileiro de Sensoriamento Remoto **Anais** Curitiba 2011

U. S Geological Survey (USGS). **Geographic Information System**. [on line] < <http://www.usgs.gov/research/gis/tittle.html>.> Acesso 23 Outubro 2010

VAN DER SANDE, C. J., DE JONG, S. M., DE ROO, A. P. J. A segmentation and classification approach of IKONOS-2 imagery for land cover mapping to assist flood risk and flood damage assessment. **International Journal of Applied Earth Observation and Geoinformation**, 4 (3), p 217-229, 2003.

VINCENT, S. P. R.; METCALFE, R. E.; TONG, D.P. Practical application of satellite remotesensing as a source of information for civil engineering projects and GIS. **Proceedings of the Institution of Civil Engineers-Civil Engineering**, v. 114, p. 35-43, Dec. 1996.

WARNER, A.S.; ASNER, G.P. Canopy shadow in IKONOS satellite observations of tropical forests and savannas. *Remote Sensing of Environmental*. v.87. 521-533p. 2003.

WATZLAWICK, L.F. **Análise e estimativa de biomassa e carbono em floresta ombrófila mista e plantações florestais a partir de dados de imagens do satélite Ikonos II**. Curitiba: TESE. (Doutorado em Ciências Florestais – Setor de Ciências Agrárias – UFPR). 2003.