



**RENNAN DE FREITAS BEZERRA MARUJO**

**AVALIAÇÃO DE MÉTODOS DE  
SEGMENTAÇÃO DE IMAGENS APLICADAS  
NA CLASSIFICAÇÃO DE CULTURAS  
CAFEEIRAS**

**LAVRAS – MG**

**2013**

**RENNAN DE FREITAS BEZERRA MARUJO**

**AVALIAÇÃO DE MÉTODOS DE SEGMENTAÇÃO DE IMAGENS  
APLICADAS NA CLASSIFICAÇÃO DE CULTURAS CAFEIEIRAS**

Monografia apresentada ao Colegiado do Curso  
de Ciência da Computação, para a obtenção do  
título de Bacharel em Ciência da Computação.

Orientadora  
Dr. Margarete Marin Lordelo Volpato

Co-orientador  
Dr. Wilian Soares Lacerda

LAVRAS –MG  
2013

**RENNAN DE FREITAS BEZERRA MARUJO**

**AVALIAÇÃO DE MÉTODOS DE SEGMENTAÇÃO DE IMAGENS  
APLICADAS NA CLASSIFICAÇÃO DE CULTURAS CAFEIRAS**

Monografia de graduação apresentada ao Departamento de Ciência da Computação da Universidade Federal de Lavras como parte das exigências do curso de Ciência da Computação para obtenção do título de Bacharel em Ciência da Computação.

APROVADA em 10 de abril de 2013.

Dr. André Vital Saúde UFLA

Dra. Helena Maria Ramos Alves UFLA

  
Dra. Margarete Marin Lordelo Volpato  
Orientadora

LAVRAS –  
2013

## DEDICATÓRIA

A minha mãe Elizete, que mesmo não presente no plano dos mortais, foi quem me proporcionou continuar estudando, com seu olhar, carinho e cuidados de uma mãe.

A meus irmãos Renata e Rafael, que mostraram que é no momento mais frágil que uma família deve manter-se unida e supera as adversidades.

Aos amigos Nicolas, Vinicius, Bruno, Sidão, Willy, Diego, Valério, Felipe, Fubu e Frodo que tive que manter a distância para poder cursar a universidade e que me mostraram que amizades são mantidas independentes da distância.

As pessoas que conheci pela internet, Camila bakinha, Silas, Ana e Sama que hoje são parte integrante dos melhores amigos com quem pude conhecer novos lugares, compartilhar momentos tanto em vida real quanto em mundos virtuais, explorando ou ganhando exp.

A minha grande família em especial minha vó Teresa por seus cuidados comigo quando mais precisei.

Aos amigos que fiz como consequência de mudar para Lavras, Tamis, Kato, Jéssica, Heider, Alexsandro, Jecão, Marlon, Pig, Pão, Miguel que providenciaram minha “amineração” e apresentaram o gostinho do “Uai”.

Aos companheiros animais que mesmo não falando o idioma comum foram grandes companhias: Hina, Celeste, Nagini, Salazar, Cachaça e Barney.

Ao pai Félix, Tio Rene, primo Gordo, menino Buzina, Lú e todos os outros membros da família Hakuna Matata que acolheram o jovem XD.

A senhorita Frida pelos momentos de carinho e as diversas refeições realizadas em conjunto, as histórias contadas, criaturas inventadas e amor.

A todos os que contribuíram para a formação da pessoa que sou.

## AGRADECIMENTOS

A Universidade Federal de Lavras e ao Departamento de Ciência da Computação, assim como todos seus funcionários pela oportunidade de cursar bacharelado em ciência da computação e as ótimas condições proporcionadas.

A Empresa de Pesquisa Agropecuária de Minas Gerais (EPAMIG) e a equipe do Laboratório Geossolos, pela convivência e momentos partilhados, em especial a minha orientadora Dra. Margarete Marin Lordelo Volpato pela paciência apoio profissional, pessoal e orientação constante.

Aos professores da UFLA pelo conteúdo apresentado, dúvidas esclarecidas e incentivo ao conhecimento.

A Fundação de Amparo a Pesquisa de Minas Gerais (FAPEMIG) pelo financiamento do projeto e concessão da bolsa PIBIC-EPAMIG e o apoio do Consórcio Brasileiro de Pesquisa e Desenvolvimento do Café (CBP&D Café).

## RESUMO

O presente trabalho avalia métodos de segmentação em imagens de satélite visando a construção de uma árvore de processos automatizada para a classificação de áreas cafeeiras. As imagens passaram por diferentes métodos de segmentação, caracterização de atributos espaciais, espectrais, forma e textura, uma vez que este tipo de cultivo, devido as suas características intrínsecas é facilmente confundido com a mata nativa em processos de classificação automática onde consideram-se apenas as variações espectrais. Foram usados algoritmos segmentadores de imagens, algoritmos de aprendizagem supervisionada e imagens do satélite *Rapideye*, que possuem alta resolução espacial e radiométrica. A avaliação da segmentação foi feita comparando 3 algoritmos: *Chess board*, *Quad tree* e *Multi-resolution segmentation*, em 2 níveis hierárquicos, utilizando o algoritmo do vizinho mais próximo para a classificação da imagem através das amostras coletadas. As acurácias foram comparadas com o algoritmo de classificação pixel a pixel de máxima verossimilhança que é um método baseado puramente em valores espectrais, O método mais preciso foi *Multi-resolution segmentation* com um índice global e índice Kappa de 80,7616% e 0,7115 respectivamente. Utilizou-se como avaliadores específicos a acurácia de produtor para a classe café que apresentou 78,97% e a acurácia de usuário também para a classe café, com acerto de 77,35%. Estes expressam uma boa qualificação, mas requerem uma pós classificação feita por interprete humano para obter valores mais precisos.

**Palavras-chave:** Classificação automática, Cafeicultura, Segmentação, Classificação Orientada a segmento, Sensoriamento Remoto.

## LISTA DE FIGURAS

Figura 1 – Relação hierárquica da segmentação em diversos níveis.....	13
Figura 2 – Curvatura típica da reflectância espectral da água, vegetação e solo.....	15
Figura 3 - Espectro eletromagnético e suas nomenclaturas mediante alteração do comprimento de onda.....	16
Figura 4 - Segmentação de imagem através do algoritmo <i>ChessBoard Segmentation</i> .....	20
Figura 6 - Decomposição de uma árvore quaternária.....	21
Figura 7 - Segmentação de imagem através do algoritmo <i>quadtrees Segmentation</i> .....	22
Figura 8 - Segmentação de imagem através do algoritmo <i>Multi-resolution Segmentation</i> .....	23
Figura 9 - Matriz de confusão.....	25
Figura 10 - imagem rapidez da área de estudo: Três Pontas.....	29
Figura 11- Pseudo-código da árvore de processos para classificação de áreas cafeeiras.....	31
Figura 12 - Níveis hierárquicos de classes para classificação do uso e ocupação da terra.....	32
Figura 13 - Hierarquia das classes utilizadas para classificação do uso e ocupação da terra.....	32
Figura 14 - Matriz de separabilidade de classes.....	33
Figura 15. Classificação pixel a pixel de máxima verossimilhança da área de estudo.....	35
Figura 16 - Árvore de processos da metodologia adotada.....	37
Figura 17 - Segmentação de imagem dos três algoritmos da presente metodologia: <i>chessboard (A)</i> , <i>quadtrees (B)</i> e <i>multi-resolution Segmentation (C)</i> .....	38
Figura 18 - Classificação orientada a segmentos da área de estudo através de <i>chessboard segmentation</i> .....	39
Figura 19 - Classificação orientada a segmentos da área de estudo através de <i>quadtrees segmentation</i> .....	41
Figura 20 - Classificação orientada a segmentos da área de estudo através de <i>multi-resolution segmentation</i> .....	42

## LISTA DE TABELAS

Tabela 1. Principais sensores multiespectrais em operação. ....	17
Tabela 2 - Exemplo de Matriz de confusão .....	26
Tabela 3. Matriz de confusão e de acurácias para a comparação entre o mapeamento da classificação pixel a pixel de máxima verossimilhança e a imagem referência.....	35
Tabela 4. Matriz de confusão e acurácias para a comparação entre o mapeamento da classificação utilizando o segmentador <i>chessboard</i> e a imagem referência. ....	40
Tabela 5. Matriz de confusão e acurácias para a comparação entre o mapeamento da classificação utilizando o segmentador <i>quadtree</i> e a imagem referência. ....	41
Tabela 6. Matriz de confusão e acurácias para a comparação entre o mapeamento da classificação utilizando o segmentador <i>multi-resolution</i> e a imagem referência.....	43
Tabela 7. Índices de exatidão obtidos com as classificações automáticas e a imagem referência.....	43

## LISTA DE ABREVIATURAS

CONAB	Companhia Nacional de Abastecimento
EPAMIG	Empresa de Pesquisa Agropecuária de Minas Gerais
FAPEMIG	Fundação de Amparo à Pesquisa de Minas Gerais
GLCM	<i>Grey Level Co-occurrence Matrix</i>
INPE	Instituto Nacional de Pesquisas Espaciais
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	<i>Near Infrared</i>
NN	<i>Nearest Neighbor</i>
RAM	<i>Random Access Memory</i>
REIS	<i>RapidEye Imaging System</i>
REM	Radiação Eletromagnética
SR	Sensoriamento Remoto
UFLA	Universidade Federal de Lavras

## SUMÁRIO

1	Introdução .....	10
1.1	Justificativa .....	10
1.2	Objetivo.....	11
1.2.1	Objetivo Geral.....	11
1.2.2	Objetivos Especificos.....	11
2	Revisão de Literatura .....	12
2.1	Fundamentos sobre imagens .....	12
2.2	Segmentação de imagens .....	12
2.3	Atributos.....	14
2.4	Sensoriamento Remoto .....	15
2.5	Classificação de imagens de satélite .....	18
2.6	Algoritmos classificadores .....	19
2.6.1	Máxima verossimilhança.....	19
2.6.2	Vizinho mais próximo ( <i>Nearest Neighbor</i> ) .....	20
2.7	Algoritmos segmentadores.....	20
2.7.1	<i>ChessBoard Segmentation</i> .....	20
2.7.2	<i>Quad Tree Segmentation</i> .....	21
2.7.3	<i>Multi-resolution Segmentation</i> .....	22
2.8	Validação das classificações .....	24
2.9	Métodos de Classificação automática aplicados a áreas cafeeiras.....	27
3	Materiais e métodos.....	29
3.1	Área de Estudo .....	29
3.2	Imagens de satélite utilizadas .....	29
3.3	Ferramentas computacionais utilizadas no processamento de imagens 30	
3.4	Procedimento metodológico.....	30
3.5	Validação dos resultados.....	34
4	Resultados e Discussões.....	35

4.1	Classificação pixel a pixel de máxima verossimilhança .....	35
4.2	Segmentação.....	36
4.2.1	Classificação utilizando <i>Chessboard Segmentation</i> .....	39
4.2.2	Classificação utilizando <i>quadtree Segmentation</i> .....	40
4.2.3	Classificação utilizando <i>Multi-resolution Segmentation</i> .....	42
5	Conclusão.....	44
6	Referências Bibliográficas .....	45

## **1 Introdução**

O processamento digital de imagens, constitui hoje ferramenta essencial de extração de dados para a interpretação humana, sendo aplicado as mais diversas finalidades.

Uma imagem pode ser representada em um computador através de uma matriz, sendo uma coordenada de um ponto e seu valor. Nas partes mais claras da imagem é atribuído um valor maior enquanto que nas áreas escuras um valor menor.

Segmentar consiste em agrupar partes da mesma imagem com propriedades comuns. Em muitas análises de imagens, a segmentação das mesmas consiste em uma etapa necessária para extração de informação excedente as informações de valor de pixel, como a identificação do objeto de interesse, bem como de informações quantitativas deste, como área, textura, perímetro, volume e forma (CHAGAS; RODRIGUES; TAVARES, 2009).

Imagens de satélite são muito utilizadas para mapeamento do uso da terra, pois tais imagens abrangem uma grande área e possuem grande quantidade de dados a serem explorados, o que possibilita a aplicação de metodologias como classificações automáticas que embora não tão eficientes quanto a interpretação visual feita por uma pessoa experiente, constituem métodos rápidos.

### **1.1 Justificativa**

Segundo Souza et al. (2009) o café é importante para a economia brasileira, sendo o segundo produto na pauta das exportações agrícolas, constituindo uma das mais importantes fontes de renda para a economia brasileira. Minas Gerais se destaca no cenário brasileiro como o maior produtor de café do país, com uma participação em torno de 50% do café produzido, estando 25% deste montante no sul de Minas Gerais (CONAB, 2012).

Conhecer a distribuição espacial da atividade cafeeira é vital para prever e planejar sua distribuição em escala municipal, estadual e federal, vide seu valor socioeconômico (MOREIRA, 2008). Uma forma de realizar essa tarefa é o uso de técnicas de processamento de imagens que segundo Venturieri (1996) constituem ferramentas poderosas para classificar imagens de satélites, sendo considerado por Moreira (2007) a melhor forma de mensurar áreas de ocupação e uso da terra desde que um analista interprete os resultados obtidos.

O mapeamento pode ser realizado por classificação automática e/ou interpretação visual. A classificação visual é mais precisa porém demorada, pois requer interprete experiente para classificar a imagem em questão, ao passo que

a classificação automática é rápida, porém esta mais propensa a ruídos e confusão entre as classes.

Souza et al. (2009) e Epiphany et al. (1994) afirmam que para o mapeamento de cultivos cafeeiros ferramentas de classificação automática raramente são utilizadas. Isto ocorre, porque a resposta espectral deste cultivo é complexa e muito semelhante a resposta espectral de áreas de mata, necessitando mais atributos além dos espectrais para uma boa separação destas classes. Desta maneira, métodos com maior precisão e processos automatizados se fazem necessários.

A utilização de segmentação em imagens de satélite busca amenizar os erros das classificações automáticas baseadas apenas em pixels, pois permite a extração de atributos além dos espectrais, possibilitando uma maior separabilidade em classificações automáticas, uma vez que a automatização dos processos de classificação é de grande auxílio aos interpretes.

## **1.2 Objetivo**

### **1.2.1 Objetivo Geral**

O objetivo deste trabalho é avaliar métodos de segmentação em imagens de satélite para mapeamento do uso da terra, e criar uma árvore de processos parcialmente automatizada.

### **1.2.2 Objetivos Especificos**

Realizar a avaliação dos métodos de segmentação: *Chessboard Segmentation*, *quadtree Segmentation* e *Multi-resolution Segmentation*;

Comparar os resultados dos métodos orientados a segmentos e os métodos de classificação automática supervisionada baseados apenas em variação espectral (pixel a pixel);

Obter a árvore de processos automatizada visando a classificação do uso e ocupação da terra;

## **2 Revisão de Literatura**

### **2.1 Fundamentos sobre imagens**

Matematicamente uma imagem pode ser representada por uma função  $f(x,y)$  da intensidade luminosa, sendo seu valor em qualquer coordenadas  $(x,y)$  referente ao nível de cinza (ou brilho) da imagem naquele ponto (FILHO; NETO, 1999).

Banon (2000) demonstra imagens em escala de cinza que são compostas por dois conjuntos: o conjunto E, representado por quadrados adjacentes dispostos em linhas e colunas (matriz); e o conjunto K formado pelos níveis de cinza, valores que normalmente variam entre 0 e 255. Um pixel consiste em um par ordenado  $(a,b)$ , onde “a” é uma coordenada em E, enquanto “b” o seu valor em K. Ou seja, uma imagem digital pode ser considerada uma matriz onde os índices das linhas e colunas representam um ponto.

### **2.2 Segmentação de imagens**

A segmentação de imagem é o processo no qual ela é subdividida, a partir de propriedades como valor de pixel, nível de cinza ou textura, em regiões ou partes constituintes (HUSSAIN, 1991).

Os algoritmos de segmentação são usados para subdividir a imagem inteira, representada pelo domínio no nível do pixel ou de segmentos, em segmentos de imagem menores, ou juntar segmentos menores para formar “novos” maiores, onde cada segmento possui seu próprio conjunto de informações qualitativas como a identificação do objeto de interesse (DEFINIENS, 2008).

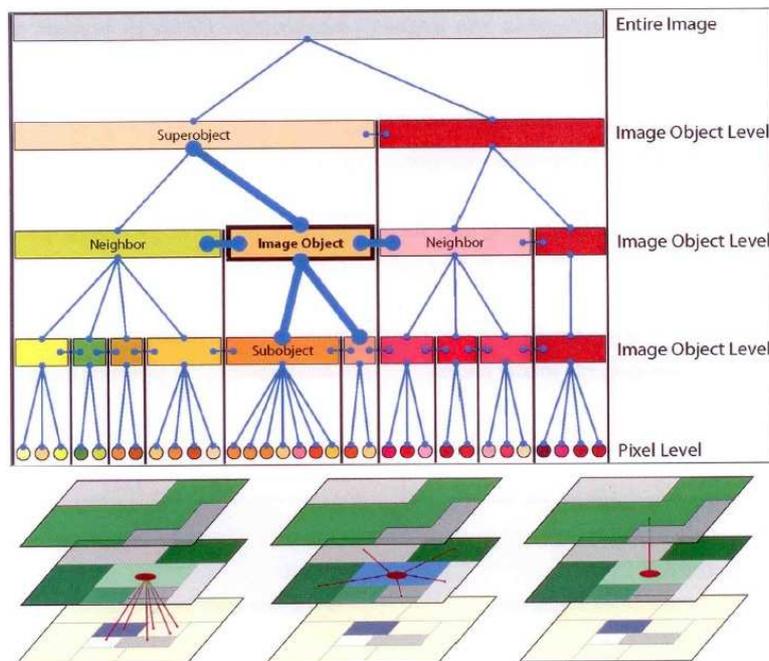
Oliveira (2009) afirma que segmentação de imagem é o processo no qual uma imagem é sub-dividida em regiões menores, os chamados objetos de imagem, podendo-se fazer uso de atributos como forma e textura além dos já contemplados atributos espectrais para a separação destas classes e criação de padrões de classificação.

Segundo Jong e Meer (2006), tradicionalmente os métodos de segmentação têm sido divididos em três abordagens: pixel, borda e métodos de segmentação baseados em região. No método pixel, cada unidade espacial tem uma identificação única, não atendendo assim, necessariamente, a definição de

segmentação. A abordagem do método borda consiste em procurar bordas de segmentos e assim delimita-los quando os valores dos atributos sofrerem mudanças. O método baseado em região pode ser dividido em algoritmos de crescimento, fusão e divisão. A segmentação por crescimento de região começa sorteando um pixel e agregando a este os vizinhos capazes, dependendo de tamanho ou homogeneidade, a região cresce até que pixels não possam mais ser incluídos, repetindo este procedimento para toda a imagem. Em fusão de região ou divisão, a imagem é dividida em sub regiões e estas são fundidas ou divididas de acordo com suas propriedades.

Definiens (2008) informa que as diversas técnicas de segmentação podem ser utilizadas para estabelecer uma relação hierárquica topológica de segmentos, representando a informação da imagem em diferentes escalas, relacionando a vizinhança do segmento, seus sub-segmentos (também chamados filhos) e seus super-segmentos (também chamados pais), onde a área de um segmento equivale à soma das áreas de seus sub-segmentos

A Figura 1 representa os diversos níveis hierárquicos de uma segmentação de imagem, e as relações possíveis com os segmentos filhos (sub-segmentos), segmentos vizinhos e segmentos pais (super-segmentos).



**Figura 1 – Relação hierárquica da segmentação em diversos níveis.**

**Fonte: Definiens (2008).**

A segmentação em diferentes níveis segundo Molenaar (1998, apud SILVA, 2009, p.7) permite inserir relacionamento entre os segmentos de níveis diferentes facilitando a introdução do conhecimento à classificação.

Os algoritmos que realizam a segmentação, são chamados algoritmos segmentadores.

### 2.3 Atributos

Witten, Frank e Hall (2011) definem um atributo como cada componente, de valor numérico ou nominal que caracteriza uma instância. No caso de uma imagem estes atributos seriam: brilho, média na escala de cinza para uma determinada banda, texturas, entre outros.

O brilho refere-se à claridade de uma imagem, tanto das partes iluminadas quanto dos contornos. O contraste refere-se à diferenciação das partes escuras das partes claras da imagem, onde cada pixel apresenta um valor na escala de cinza para cada uma das bandas de comprimentos de ondas da imagem. O atributo média pode ser a média dos valores de pixels nas diferentes bandas, assim como pode ser também a média do valor dos pixels contidos em um segmento (neste caso temos a média da escala de cinza do segmento). O desvio padrão é uma medida de dispersão estatística que mostra a variação existente em relação à média (em imagens geralmente calcula-se o desvio padrão dos níveis de cinza).

Compacidade e suavidade são atributos complementares, sendo que a compacidade é a razão do comprimento da borda de um segmento pelo número total de pixels deste, enquanto que a suavidade é a razão entre a borda do segmento e o comprimento de um retângulo que o envolve (RIBEIRO; CENTENO, 2005).

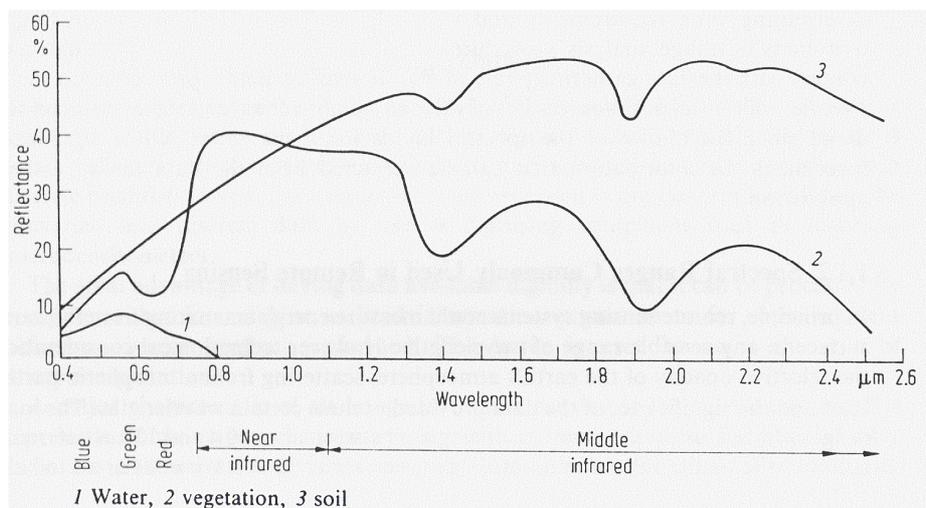
A segmentação permite analisar e utilizar a textura dos segmentos, uma propriedade inata de todas as superfícies, contendo importantes informações sobre o arranjo estrutural destas e sua relação com o ambiente em volta. Uma vez que a textura é útil para discriminação, Haralick et al. (1973) desenvolveram diversas medidas de textura: homogeneidade (segundo momento angular): medida da homogeneidade local dos níveis de cinza em uma imagem. Contraste: medida da quantidade de variação local de níveis de cinza em uma imagem; Dispersão (entropia): medida do grau de dispersão de ocorrências de níveis de cinza em uma imagem. Concentração (momento de diferença inverso): mede a concentração das ocorrências de níveis de cinza na diagonal da matriz de coocorrência. Ordenação (correlação): representa uma ideia de linearidade de dependências de tons de cinza em uma imagem (HARALICK, 1973).

## 2.4 Sensoriamento Remoto

Segundo Novo (1992) o sensoriamento remoto consiste em utilizar equipamentos, dentre eles aeronaves e satélites para monitorar superfícies terrestres. Os registros de informação são obtidos de maneira digital e são processados para que seja possível a interpretação dos mesmos.

A definição utilizada por Jong e Meer (2006) retrata que o sensoriamento remoto refere-se à utilização de instrumentos, técnicas e métodos, usados para observar, ou medir, a superfície da terra resultando em imagens.

A radiação eletromagnética ao atingir um objeto na superfície da Terra, pode ser transmitida, absorvida ou refletida. A magnitude desses processos é determinada pelas propriedades do objeto. A reflectância é a energia refletida dos objetos da superfície da terra. A Figura 2 ilustra a reflectância espectral de alguns objetos típicos. Observa-se por exemplo que a água, vegetação e solo podem ser facilmente diferenciados por exemplo nos comprimentos de onda 0,6 e 1,6  $\mu\text{m}$ .

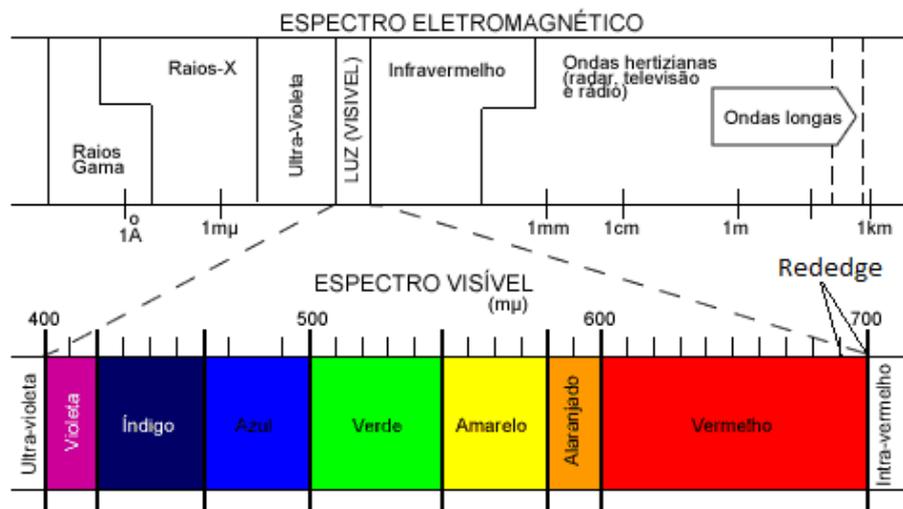


**Figura 2 – Curvatura típica da reflectância espectral da água, vegetação e solo.**

**Fonte: Adaptado de Moraes (1999).**

De acordo com Moreira (2001) os sensores podem ser caracterizados pelas resoluções espectral, espacial, radiométrica e temporal. A resolução espectral pode ser definida pela capacidade que o sensor apresenta para diferenciar alvos sobre a superfície terrestre em função da largura da banda

espectral em que o sensor opera. A Figura 3 ilustra o espectro eletromagnético ao longo do comprimento de onda e seus respectivos nomes. A resolução espacial, também chamada resolução geométrica, consiste no campo de visada instantâneo, a quantidade de metros quadrados ou unidade de medida representada pelo comprimento de um pixel. A resolução radiométrica de um sensor refere-se à capacidade que este sensor tem de poder discriminar, numa área imageada, alvos com pequenas diferenças de radiação refletida e/ou emitida. E a resolução temporal indica o intervalo de tempo que o satélite leva para voltar a recobrir a área de interesse.



**Figura 3 - Espectro eletromagnético e suas nomenclaturas mediante alteração do comprimento de onda.**

**Fonte: Adaptado de Teng (2008).**

Oliveira (2009) afirma que através de imagens de alta resolução abrem-se novas possibilidades para a classificação de imagens digitais, particularmente nas classes espectralmente similares, permitindo análises e descobertas de padrões antes não possíveis com dados apenas espectrais, uma vez que nesta maior resolução, as imagens apresentam uma maior heterogeneidade.

A Tabela 1 mostra os principais sensores multiespectrais em operação utilizados para análise de uso e ocupação da terra, representando suas resoluções espaciais, radiométricas e temporais, assim também como o comprimento de onda utilizado em cada banda.

Tabela 1. Principais sensores multiespectrais em operação.

Satélite/ Sensor	Resolução Espectral (bandas – faixa espectral)	Resolução Espacial	Resolução radiométrica	Resolução Temporal
<b>Landsat TM</b>	1 (0,45 – 0,52 $\mu\text{m}$ )	30m	8 bits	16 dias
	2 (0,52 – 0,60 $\mu\text{m}$ )	30m		
	3 (0,63 – 0,69 $\mu\text{m}$ )	30 m		
	4 (0,76 – 0,90 $\mu\text{m}$ )	30m		
	5 (1,55 – 1,75 $\mu\text{m}$ )	30m		
	6 (10,4 – 12,5 $\mu\text{m}$ )	120 m		
	7 (2,08 – 2,35 $\mu\text{m}$ )	30 m		
<b>SPOT HRG</b>	B1 (0,50 – 0,59 $\mu\text{m}$ )	10 m	8 bits	26 dias
	B2 (0,61 – 0,68 $\mu\text{m}$ )	10m		
	B3 (0,78 – 0,89 $\mu\text{m}$ )	10m		
	B4 (1,58 – 1,75 $\mu\text{m}$ )	20 m		
	PAN (0,48 – 0,71 $\mu\text{m}$ )	2,5 a 5 m		
<b>IKONOS II</b>	MS1 (0,45 – 0,53 $\mu\text{m}$ )	4m	11 bits	1,5 dias (visada lateral)
	MS2 (0,52 – 0,61 $\mu\text{m}$ )	4m		
	MS3 (0,64 – 0,72 $\mu\text{m}$ )	4 m		
	MS4 (0,77 – 0,88 $\mu\text{m}$ )	4m		
	PAN (0,45 – 0,90 $\mu\text{m}$ )	1 m		
<b>QuickBird</b>	GSD1 (0,45 – 0,52 $\mu\text{m}$ )	2,44m	11 bits	1 – 3.5 dias
	GSD2 (0,52 – 0,60 $\mu\text{m}$ )	2,44m		
	GSD3 (0,63 – 0,69 $\mu\text{m}$ )	2,44 m		
	GSD4 (0,76 – 0,90 $\mu\text{m}$ )	2,44m		
	PAN (0,45 – 0,90 $\mu\text{m}$ )	0,61 m		
<b>CBERS CCD</b>	PAN (0,51 – 0,73 $\mu\text{m}$ )	20m	8 bits	26 dias
	AZUL (0,45 – 0,52 $\mu\text{m}$ )	20m		
	VERDE (0,52 – 0,59 $\mu\text{m}$ )	20 m		
	VERMELHO (0,63 – 0,69 $\mu\text{m}$ )	20m		
	NIR (0,77 – 0,89 $\mu\text{m}$ )	20m		
<b>Rapideye</b>	BLUE (440 - 510 $\mu\text{m}$ )	5m	12 bits	Programad o
	GREEN (520 – 590 $\mu\text{m}$ )	5m		
	RED (630 – 685 $\mu\text{m}$ )	5 m		
	RED-EDGE (690 – 730 $\mu\text{m}$ )	5m		
	NIR (760 – 850 $\mu\text{m}$ )	5m		

A energia registrada pelo sensor é transmitida de maneira eletrônica para uma estação de recepção e processamento, onde os arquivos são transformados em imagem com diferentes níveis de correção e disponibilizada ao usuário.

O processamento digital de imagens é uma técnica que utiliza funções matemáticas para alterar os valores de pixel desta. De posse das imagens o usuário necessita realizar algumas correções. A correção radiométrica pode ser

necessária devido a iluminação da cena. A correção geométrica visa a inserção da imagem em uma projeção, uma vez que imagens de satélite estão sujeitas a uma série de distorções espaciais como a variação na altitude, na velocidade do satélite e na rotação da Terra (CRÓSTA, 1992). A correção atmosférica ocorre para calibrar os dados de radiação ou reflectância para facilitar a comparação entre dados (JONG; MEER, 2006).

De acordo com Moraes (1999) o usuário inicia o processamento da imagem utilizando técnicas de realce para discernir um número maior de sombreamentos, dito que a vista humana é limitada podendo causar confusão quando os níveis são próximos. Um recurso utilizado para maior diferenciação dos níveis de sombreamento é o da falsa cor, que permite colorir a imagem com tonalidades diferentes, independentes das cores originais, sem alterar os valores reais da imagem.

## 2.5 Classificação de imagens de satélite

Carvalho (2001) afirma que a classificação de imagens visa mapear unidades relacionando as propriedades extraídas de amostras com um conjunto de classes e isolá-las usando alguns critérios de decisão.

A classificação digital de imagens consiste no processo de atribuir pontos a uma determinada classe. Basicamente existem três tipos de classificação em imagens de satélite: visual, *pixel a pixel*, orientada a segmentos.

A classificação visual, também chamada interpretação, consiste na técnica de verificar manualmente a qual classe os pixels da imagem pertencem, geralmente formando polígonos sobre as áreas de interesse e atribuindo-os as classes determinadas. Este método requer atenção dos interpretes, uma vez que esta análise está sujeita ao erro humano. Apresenta-se como uma técnica precisa, porém demorada necessitando interpretes treinados para a classificação.

A classificação pixel a pixel segundo Bernardi (2007) é a classificação que utiliza atributos espectrais isolados de cada pixel componente da imagem, de forma a atribuir cada pixel à classe mais provável, entretanto os resultados destes métodos não geram classificações consistentes, já que apresentam muito ruído.

Vasconcelos e Novo (2004) demonstram que algoritmos de segmentação têm sido utilizados e apresentado resultados mais precisos do que as classificações pixel a pixel, pois consideram agrupamentos de pixels semelhantes chamados segmentos e as relações existentes com os segmentos próximos.

## 2.6 Algoritmos classificadores

Os algoritmos de classificação pixel a pixel são baseados principalmente nos valores espectrais da imagem. Para a realização de uma classificação pixel a pixel, antes da classificação em sí, é necessário realizar o processo de amostragem para cada classe definida, onde amostras bem definidas devem ser coletadas visando pureza das classes para que estas não sofram influência das classes vizinhas, o que poderia acarretar em ruído nos resultados. Assim, os pixels a ser classificados são comparados aos amostrados e atribuídos a uma classe. Alguns exemplos são: o algoritmo do paralelepípedo, algoritmo da distância mínima, distancia Mahalanobis, Isoseg, Bhattacharya e da máxima verossimilhança.

### 2.6.1 Máxima verossimilhança

O método mais tradicional que apresenta bons resultados em sensoriamento remoto segundo Ribeiro (2007) é o da máxima verossimilhança, pois parte do princípio que a classificação errada de um pixel não tem significado maior que a classificação errada de qualquer outro pixel na imagem (RICHARDS, 1993).

Lillesand e Kiefer (2000) afirmam que para cada classe durante a classificação de um pixel ainda não classificado, o método da máxima verossimilhança avalia quantitativamente a variância e covariância dos padrões de resposta espectral, calculando a probabilidade de um dado pixel pertencer a uma classe através de uma função de densidade probabilística (VIEIRA JUNIOR, 2011).

Segundo Cerqueira e Alves (2010), a equação reduzida do algoritmo de classificação máxima verossimilhança é dada por:

$$L_i = P(R / C_i) \cdot (M_i) \quad (1)$$

Onde  $P(R/C_i)$  representa a probabilidade de se ter uma radiometria  $R$ , conhecida a classe  $C_i$  estimada com base na estatística bayesiana. A função de máxima verossimilhança, maximiza uma função dependente da informação radiométrica, representado por  $(M_i)$  (Cerqueira e Alves, 2010).

## 2.6.2 Vizinho mais próximo (*Nearest Neighbor*)

Proposto por Cover e Hart (1996) o algoritmo do vizinho mais próximo (*Nearest Neighbor* ou NN) é uma técnica bem simples dividida basicamente em duas partes: a primeira refere-se à amostragem, onde as diversas amostras são inseridas em um plano n-dimensional de acordo com seus atributos. A segunda parte consiste na classificação, onde os padrões a serem classificados são comparados com os amostrados e inseridos na classe do objeto com menor distância euclidiana até ele.

## 2.7 Algoritmos segmentadores

### 2.7.1 *ChessBoard Segmentation*

*ChessBoard Segmentation* consiste em fundir os pixels de uma imagem formando agrupamentos quadrados (lembrando a distribuição de um tabuleiro de xadrez) onde o tamanho pode variar, mas a forma será sempre quadrada, não delineando muito bem os dados que serão classificados. A Figura 4 ilustra uma imagem segmentada através do algoritmo *ChessBoard Segmentation*. No caso de quadrados de tamanho 1 pixel, a segmentação vai equivaler a uma análise pixel a pixel da imagem.

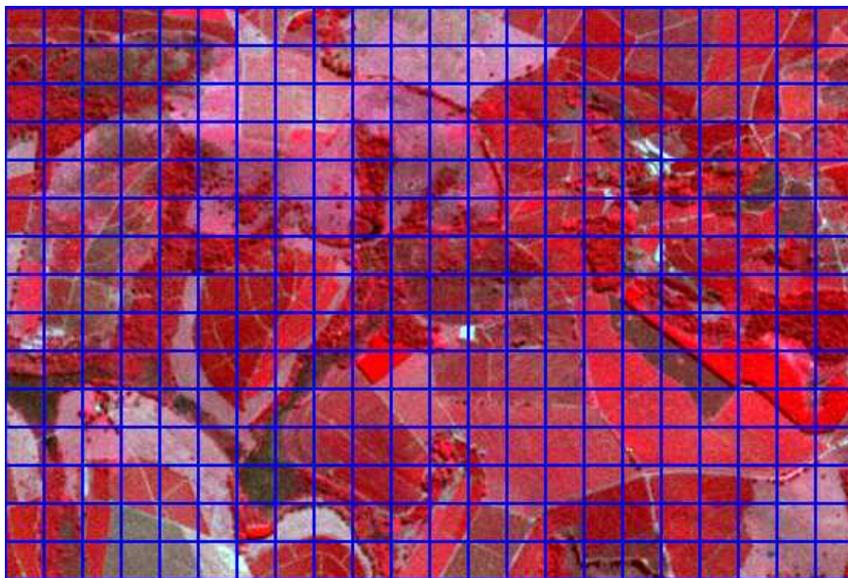


Figura 4 - Segmentação de imagem através do algoritmo *ChessBoard Segmentation*.

### 2.7.2 Quad Tree Segmentation

O algoritmo *Quad Tree Segmentation*, semelhante ao *Chessboard Segmentation* divide a imagem em quadrados. O diferencial deste algoritmo, consiste em analisar a textura dos quadrados gerados verificando sua homogeneidade e caso não sejam homogêneos, continua a dividi-los.

Inicialmente a imagem é o primeiro nó da *quadtree* (árvore com quatro filhos, também chamada quaternária). Smith e Chang (1994) afirmam que iterativamente a imagem é dividida em quatro blocos que são comparados entre si. Cada bloco (segmento) da *quadtree* tem seus atributos das diversas bandas extraídos (homogeneidade de Haralick) e são avaliados. Caso apresentem-se homogêneos entre si e os segmentos vizinhos, são fundidos estabelecendo um segmento e o processo de extração de atributo, avaliação e divisão se repete nos outros blocos, como ilustrado na Figura 5. A Figura 6 ilustra a segmentação em uma imagem orbital através do algoritmo *Quad Tree Segmentation*.

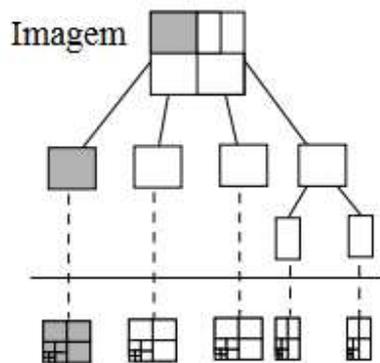
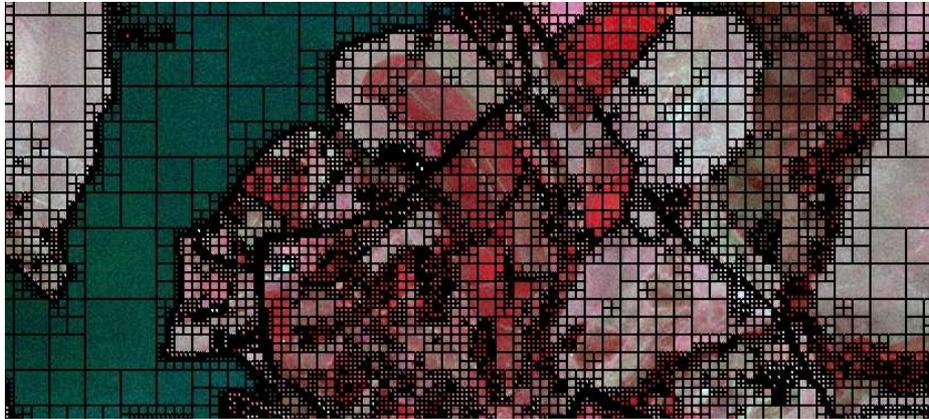


Figura 5 - Decomposição de uma árvore quaternária.

Fonte: Adaptado de Smith & Chang (1994).

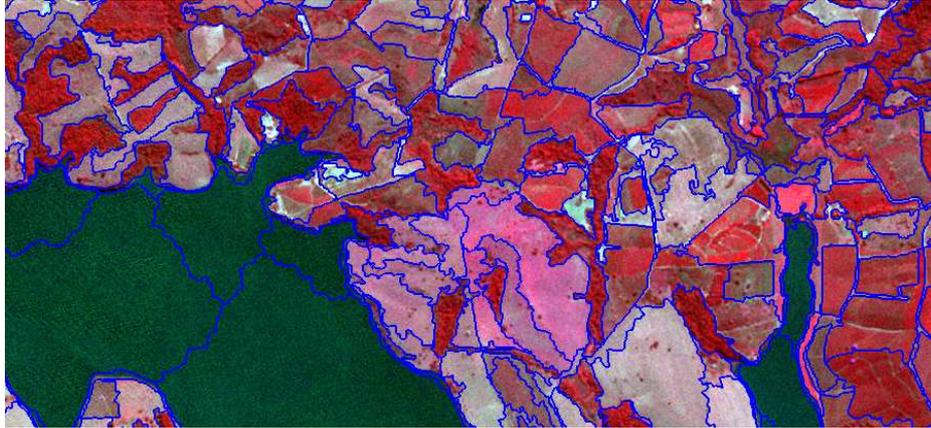


**Figura 6 - Segmentação de imagem através do algoritmo *quadtree Segmentation*.**

### **2.7.3 *Multi-resolution Segmentation***

O algoritmo *Multi-resolution Segmentation* segundo Bernardi et al. (2007) funde regiões em sentido *bottom-up* (baixo para cima, ou múltiplas pequenas regiões em regiões maiores). Inicialmente cada pixel é um segmento da imagem, e através dos critérios escalares definidos para o algoritmo (cor, forma, compacidade, suavidade e escala) analisados na imagem em cada uma das bandas espectrais, os segmentos semelhantes são fundidos formando um segmento maior com as características dos menores.

Segundo Baatz e Schape (2000), a fusão dos segmentos ocorre em pares, podendo variar de acordo com a implementação do algoritmo. Seja A um segmento inicial arbitrário e B um segmento adjacente para fusão, os métodos para decisão de fusão são: *fitting* (encaixe): funde A arbitrariamente com um segmento vizinho B que cumpra os critérios de homogeneidade. *Best fitting* (melhor encaixe): funde A com o segmento vizinho B de maior critério de homogeneidade. *Local mutual best fitting* (melhor encaixe local mutuo): busca o vizinho B de A com maior critério de homogeneidade e o vizinho C de B com maior critério de homogeneidade, para comparar os valores de C com A e caso sejam os mais similares dentre os examinados, ocorre a fusão de A com B. Esta heurística permite encontrar o melhor pareamento na vizinhança de A. *Global mutual best fitting* (melhor encaixe global mutuo): Funde os segmentos A e B com maior homogeneidade encontrados na imagem. Esta heurística não segue os padrões de escala definidos no algoritmo para definir tamanho de segmentos. A Figura 7 ilustra uma segmentação de imagem através do algoritmo *Multi-resolution Segmentation* por *local mutual best fitting*.



**Figura 7 - Segmentação de imagem através do algoritmo *Multi-resolution Segmentation*.**

Dado um certo espaço de atributos, dois segmentos são similares quando estão próximos (BAATZ; SCHAPE, 2000). A comparação entre dois segmentos para união em um novo segmento utiliza os atributos do segmento em cada banda e é dada pela equação (2) segundo Baatz e Schape (2000):

$$h = \sqrt{\sum_d (f1d - f2d)^2} \quad (2)$$

Onde:

h é a similaridade;

d são as diversas dimensões também chamadas bandas espectrais da imagem;

f1d e f2d são os atributos dos segmentos em comparação na dimensão d;

Podendo ser padronizadas pelo desvio padrão como na equação:

$$h = \sqrt{\sum_d \left(\frac{f1d - f2d}{\sigma}\right)^2} \quad (3)$$

$\sigma$  é o desvio padrão;

## 2.8 Validação

Para avaliação dos segmentos gerados assim como seus algoritmos segmentadores, utilizou-se a interpretação visual que segundo Baatz e Schape (2000) é uma fonte experiente para avalia-los, sendo dois importantes requisitos para atender a meta de boa avaliação: a consistência no contraste dos segmentos e a união de regiões similares.

Outro critério para avaliação dos segmentos ainda segundo Baatz e Schape (2000) é a informação que pode ser extraída dos segmentos. Sendo assim realizou-se classificações automáticas através dos mesmos atributos e metodologias, porém com diferentes algoritmos segmentadores.

A imagem adotada como referência foi interpretada manualmente e como toda classificação manual esta sujeita ao erro humano. A acurácia de uma imagem interpretada manualmente é de 95%, sendo considerada neste estudo 100% para que assim fosse possível comparar os métodos de segmentação e suas respectivas classificações que fizeram uso dos mesmos atributos e da mesma imagem referência.

Para avaliar o desempenho dos classificadores, utiliza-se matriz para analisar e extrair os índices Global, Kappa e as acurácias individuais de cada classe. Uma matriz de confusão segundo Bernardes (2006) constitui uma maneira de representar a acurácia de um conjunto de dados simulados ou estimados, em relação a um conjunto de dados de referência (BERNARDES, 2006).

Ramos (2013, não publicado) define matematicamente a matriz de confusão como um conjunto  $S$  de dados com  $N$  observações e  $Y$  uma variável dependente com duas categorias, Classe A e Classe B. Dado  $X$  uma observação cuja classificação seja desconhecida e pretende-se classificá-la nas categorias de  $Y$ , diz-se que é verdadeiro positivo quando pertence a Classe A e é classificado como Classe A, falso negativo quando pertence a Classe A e é classificado como Classe B, falso positivo quando pertence a Classe B e é classificado como Classe A e verdadeiro negativo, quando pertence a Classe B e é classificado como Classe B, conforme a matriz de confusão disposta na

		Classe verdadeira		
		Classe A	Classe B	TOTAL
Classe A	Verdadeiro Positivo	Falso Positivo	Total classificado como classe A	
Classe B	Falso Negativo	Verdadeiro Negativo	Total classificado como classe B	

Classificado como	TOTAL	<div style="display: flex; justify-content: space-around;"> <span>Total observado na referência como classe A</span> <span>Total observado na referência como classe B</span> </div>		
	Classe A	Verdadeiro Positivo	Falso Positivo	Total classificado como classe A
	Classe B	Falso Negativo	Verdadeiro Negativo	Total classificado como classe B
TOTAL	Total observado na referência como classe A	Total observado na referência como classe B	TOTAL	

Figura 8.

**Figura 8 - Matriz de confusão.**

**Fonte: Adaptado de Ramos (não publicado).**

A matriz de confusão também possibilita a identificação do erro global, e como ocorreu a confusão entre as diversas classes, podendo ser verificados os erros de comissão e omissão. Um erro de comissão consiste na inclusão de uma classe em outra a qual ela não pertencia na realidade. Um erro de omissão consiste na exclusão de uma classe a qual ela pertence de fato. Sendo assim, a acurácia do produtor faz relação ao erro de omissão, enquanto a acurácia do consumidor refere-se ao erro de comissão (VIEIRA, 2009).

O índice global, também chamado de exatidão avalia a porcentagem de acerto de um mapa. De acordo com Rennó (1999), é obtido através da equação 2:

$$\frac{\sum_{i=1}^c X_{ii}}{n} \quad (4)$$

Onde:

c representa a ultima classe;

n representa o total de classes;

i representa o índice na matriz de confusão;

Caso as classes sejam independentes umas das outras é possível calcular o índice global independente dado pela equação 5 (Rennó, 1999):

$$\frac{\sum_{i=1}^c \frac{totalLinha(i) * totalColuna(i)}{total}}{total} \quad (5)$$

O índice Kappa ainda segundo Rennó (1999) também é uma medida de acurácia muito aplicada em matriz de confusão. Seu diferencial quanto ao índice global é utilizar todos os valores da matriz de confusão e não somente os da diagonal principal. O índice Kappa é dado pela equação 6 segundo Rennó (1999):

$$K = \frac{\Theta_1 - \Theta_2}{1 - \Theta_2} \quad (6)$$

Onde:

$\Theta_1$  é o índice global;

$\Theta_2$  é o índice global independente;

A Tabela 2 ilustra uma matriz de confusão para ilustrar o calculo dos índices.

**Tabela 2 - Exemplo de Matriz de confusão**

	Classe A	Classe B	Classe C	Classe D	TOTAL
Classe A	13	0	24	6	43
Classe B	8	10	5	6	29
Classe C	8	4	27	4	43
Classe D	0	0	1	34	35
Total	29	14	57	50	150

O índice global é obtido através da soma dos valores da diagonal principal divididos pela área total. Neste caso:

$IG = (13+10+27+34) / 150 = 84/150 = 0,56$ . O equivalente a 56% de acurácia global.

O índice Kappa é calculado usando os valores do índice global e do índice global independente. Desta forma necessita-se calcular ainda o índice global independente. Abaixo é apresentada a representação simplificada da matriz para calculo do índice global independente:

$$IGi = \frac{(29 * 43) + (14 * 29) + (57 * 43) + (50 * 35)}{150 * 150} = \frac{39,03}{150} = 0,26$$

$$K = \frac{0,56 - 0,26}{1 - 0,26} = 0,4053$$

A acurácia de produtor para cada classe é obtida dividindo o total de itens corretamente classificados naquela classe pelo total de itens reais desta classe. No caso da matriz de confusão da **Erro! Fonte de referência não encontrada.** para a classe B, a acurácia de produtor resultaria em:  $(10/14) = 0,7143$ . Uma acurácia equivalente a 71,43%.

A acurácia de usuário para cada classe é obtida dividindo o total de itens corretamente classificados em uma classe pelo total de itens classificados nesta classe. No caso da matriz de confusão da **Erro! Fonte de referência não encontrada.** a acurácia de usuário para a classe B resultaria em:  $(10/29) = 0,3448$ . Uma acurácia baixa equivalente a 34,48%.

## 2.9 Métodos de Classificação automática aplicados a áreas cafeeiras

Diversos métodos automáticos tem sido implementados e aplicados como forma de melhorar a realização dos mapeamentos cafeeiros, dentre eles Bernardes (2007) que fez uso de três algoritmos de classificação pixel a pixel aplicados em imagem de satélite Landsat para a região da bacia hidrográfica do

Alto Paranaíba através do software livre *SPRING* para classificação do complexo Serra Negra, sendo estes algoritmos e seus respectivos resultados de índice global e índice Kappa: Iseseg (48%; 0,31); Bhattacharya (55%; 0,38); Máxima Verossimilhança (52%; 0,28).

Merello et al. (2010) afirmam que a classificação orientada a segmentos é robusta para análise de imagens de alta resolução espacial, pois envolve o contexto espacial e temporal, mas ainda permite o conhecimento do interprete para avaliação dos atributos e classificação. Em seu trabalho realizado no Alto do Santo Anastácio, SP através de imagens coloridas obtidas por câmera Hasselblad, foram feitas classificações em uma imagem específica relativamente homogênea onde foram separadas classes agrícolas, vegetação nativa, sombras, lagos, estradas e áreas urbanas, obtendo-se bons resultados, porém não entrando em maiores detalhes sobre o tipo de segmentação utilizada e seus atributos, mas que demonstram que a classificação orientada a segmentos é capaz de produzir resultados similares aos obtidos por interpretação visual.

O uso de redes neurais artificiais multilayers perceptrons por Andrade et al. (2012), em uma imagem de satélite SPOT da região de Guaxupé, MG através do software *IDRISI* obteve índice Kappa de 0,7185, demonstrando que redes neurais é uma metodologia promissora para a classificação de áreas cafeeiras.

Vieira Junior (2011) utilizou imagem de satélite SPOT 5 para a região de São Felix do Xingu (PA) para avaliar dois métodos pixel a pixel, a máxima verossimilhança e a distância de Bhattacharya obtendo índices Kappa de 0,636 e 0,717 respectivamente, resultados acima do esperado para uma classificação pixel a pixel. Também utilizou um método orientado a segmentos obtendo índice Kappa de 0,741 o que demonstrou avanço da metodologia quando comparada ao método puramente espectral.

### 3 Materiais e métodos

#### 3.1 Área de Estudo

A área de estudo compreende uma área de 510 km<sup>2</sup> com coordenadas 21°17'10,07" S a 21°27'57,41" S de latitude e 45°30'4,69" O a 45°45'3,33" O de longitude, na região de Três Pontas, estado de Minas Gerais.

#### 3.2 Imagens de satélite utilizadas

Os dados multiespectrais foram adquiridos do sensor RE-4, acoplado aos satélites REIS (*RapidEyeimaging system*) para a região de Três Pontas e municípios vizinhos, com data de passagem 12 de Agosto de 2009, podendo ser visualizada na A Figura 9. Essas imagens pertencem ao banco de dados geográficos do Governo do estado de Minas Gerais.

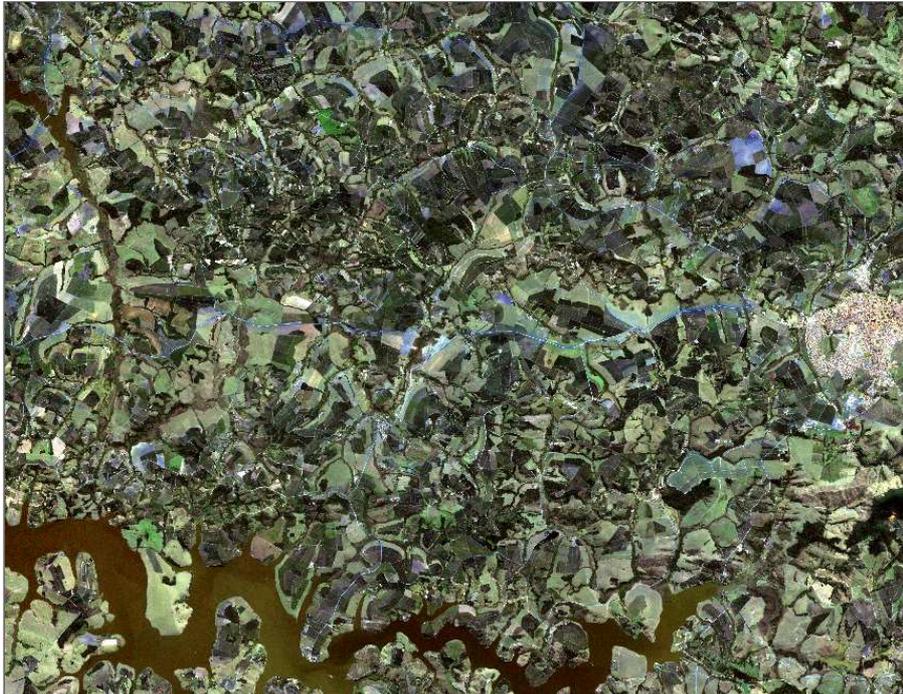


Figura 9 - imagem rapideye da região de Três Pontas.

### 3.3 Ferramentas computacionais utilizadas no processamento de imagens

Para processamento e análise digital dos dados, foi utilizado um computador com processador *Intel Xeon X5450* de 3.0Ghz com 3.25 GB de memória RAM utilizando *Windows XP Professional Service pack 3* como sistema operacional.

Os *softwares* utilizados foram: *Definiens 8.7* para segmentação de imagens e classificação; *ENVI 4.7* para classificação pixel a pixel e pós-processamento (validação das classificações).

### 3.4 Procedimento metodológico

As imagens utilizadas neste estudo foram adquiridas com pré-processamento de correções geométricas e radiométrica realizados pela *RapidEye™*.

As classes em uso foram definidas seguindo os mapas de uso e ocupação da terra do laboratório de geoprocessamento da EPAMIG e são estas: “Água” representa os corpos d’água como lagos, represas, rios e afins; a classe “Urbano” representa as áreas urbanas; a classe “Café” representa os objetos de culturas cafeeiras; a classe “Mata” representa as matas nativas; e a classe “Outros”, que por sua vez representa todas as outras classes não nomeadas como pastagens, solos expostos e estradas.

Elaborou-se um pseudo-código dos processos a serem realizados para o processamento de classificação automática demonstrado na Figura 10.

Segmentação (nível 1; escala: 150; forma: 0,9; cor: 0,1; compacidade: 0,5; suavidade: 0,5);  
 Segmentação (nível 2; escala: 50; forma: 0,1; cor: 0,9; compacidade: 0,5; suavidade: 0,5);

\*\*\*amostragem de segmentos\*\*\* (etapa manual);

Definir atributos ({Espectrais, Texturiais, Água, Outros, Urbano}, {NDVI, brilho, média, desvio padrão, forma});  
 Definir atributos ({Café, Mata, Fundir a outros}, {NDVI, brilho, média, desvio padrão, forma, GLMC Homogeneity});

```

Nearest Neighbor (nível 1, {Espectrais, Texturiais});
Quando (nível 1 == espectrais);
    Nearest Neighbor (nível 2, {Água,Outros, Urbano});
Quando (nível 2 == texturiais)
    Nearest Neighbor (nível 2, {Café, Mata, Fundir a outros});
Fundir (Outros, {Fundir a outros}); // inserir a classe "fundir a outros" na classe
"outros"

```

**Figura 10- Pseudo-código da árvore de processos para classificação de áreas cafeeiras.**

A primeira etapa do processo de segmentação constituiu-se da escolha de melhor algoritmo segmentador aplicado à classificação de áreas cafeeiras. Utilizou-se três algoritmos sendo eles *Chess Board Segmentation*, *Quad Tree Segmentation* e *Multi-Resolution Segmentation*. Visando extrair segmentos ajustados as futuras classes. Buscou-se evitar a confusão de duas ou mais das futuras classes no mesmo segmento.

Utilizou-se dois níveis de segmentação. No “Nível 1” deu-se prioridade ao atributo forma, uma vez que plantações de café são feitas em talhões que geralmente apresentam formato regular. Utilizou-se de segmentos grandes a serem separados em duas classes: “Espectrais” e “Texturiais” onde a classe “Espectrais” representa os objetos que podem ser facilmente separados apenas com atributos espectrais como pastos, estradas, corpos d’água, áreas urbanas, enquanto que a classe “Texturiais” engloba as áreas ocupadas por café, matas nativas, áreas de reflorestamento e os demais usos da terra.

O “Nível 2” representa a classificação em nível final para validação. O atributo cor teve prioridade, o que implica em uma menor prioridade ao atributo forma, assim obtendo segmentos com uma maior separabilidade em níveis espectrais. Tal estratégia foi adotada, pois para o tamanho definido neste nível de segmentação não observa-se o formato regular do plantio. Este nível contém segmentos menores, de maneira a não ocorrer misturas entre as futuras classes: “Água”, “Urbano”, “Outros”, “Café”, “Mata” e “Fundir a outros” onde a classe “Fundir a outros” representa as vegetações densas que não sejam café ou mata, que não são foco deste estudo e que serão fundidas à classe “Outros”.

A Figura 11 demonstra os níveis hierárquicos utilizados nos níveis 1 e 2 e suas respectivas classes, enquanto a Figura 12 ilustra a hierarquia de classes utilizada.

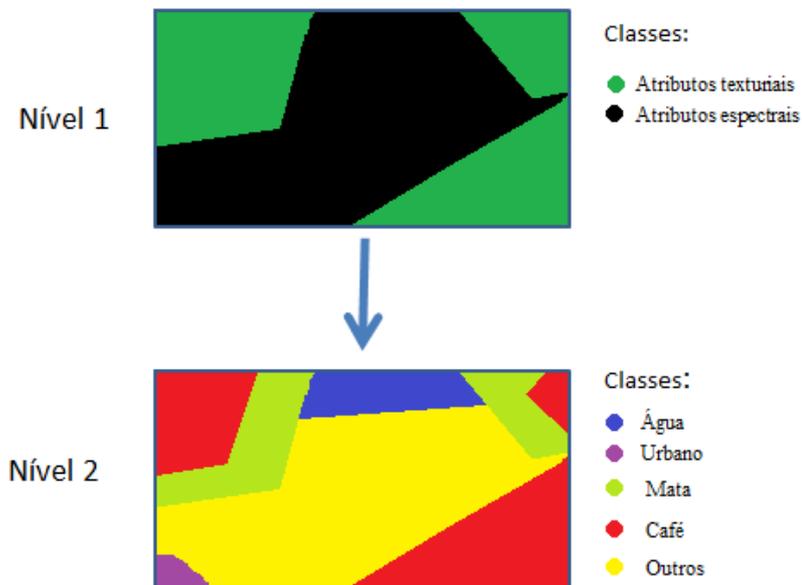


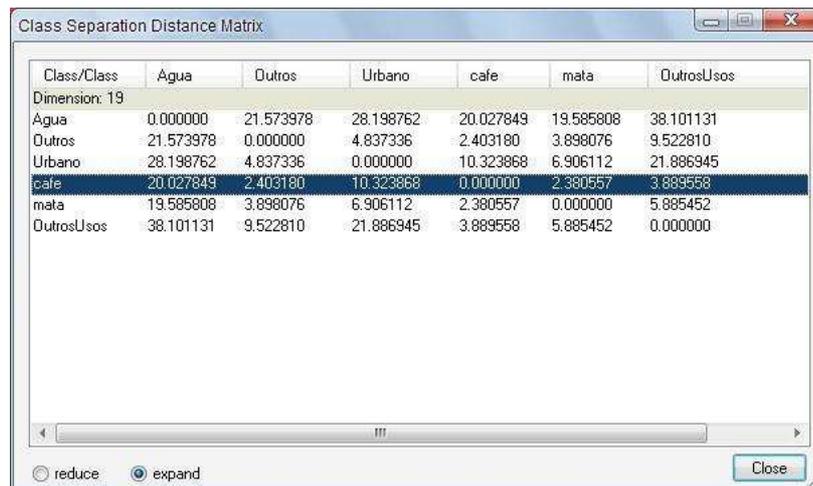
Figura 11 - Níveis hierárquicos de classes para classificação do uso e ocupação da terra.



Figura 12 - Hierarquia das classes utilizadas para classificação do uso e ocupação da terra.

A avaliação da qualidade dos diversos parâmetros e de segmentações foi feita através de uma ferramenta chamada otimizador de atributos contida no software *Definiens Ecognition*. Tal ferramenta monta uma matriz de separabilidade utilizando os atributos definidos e as classes escolhidas. Esta matriz pode ser observada na Figura 13. Também comparou-se visualmente os resultados obtidos até então, buscando formatos que viessem atender as necessidades da classificação com precisão. Devido a não implicância em

grandes variações nos segmentos ao alterar os valores de suavidade e compacidade, estes valores tiveram prioridades iguais.



Class/Class	Água	Outros	Urbano	cafe	mata	OutrosUsos
Dimension: 19						
Água	0.000000	21.573978	28.198762	20.027849	19.585808	38.101131
Outros	21.573978	0.000000	4.837336	2.403180	3.898076	9.522810
Urbano	28.198762	4.837336	0.000000	10.323868	6.906112	21.886945
cafe	20.027849	2.403180	10.323868	0.000000	2.380557	3.889558
mata	19.585808	3.898076	6.906112	2.380557	0.000000	5.885452
OutrosUsos	38.101131	9.522810	21.886945	3.889558	5.885452	0.000000

Figura 13 - Matriz de separabilidade de classes.

Utilizou-se um máximo de 20 dimensões para a otimização dos atributos visando a distinção das classes.

Depois de segmentado, todas as classes tiveram amostras coletadas para serem utilizadas como base de dados para a classificação automática. A classificação foi realizada através do algoritmo do vizinho mais próximo (*Nearest Neighbour*). A classificação no nível 1 foi realizada utilizando os atributos: NDVI<sup>1</sup> (*Normalized Difference Vegetation Index*), brilho, média e desvio padrão das bandas espectrais: vermelha, verde, azul, infra vermelho próximo e limite do vermelho (*rededge*). A classificação do nível 2 foi feita através da hierarquia de segmentos onde os segmentos classificados como “Espectrais” no nível 1 foram classificados no nível 2 em: “Água”, “Urbano” e “Outros”, enquanto que os segmentos classificados no nível 1 como “Texturiais” foram classificados no nível 2 como: “Café”, “Mata” e “Fundir a Outros”, através dos mesmos atributos espectrais acrescidos dos atributos texturiais GLMC Homogeneity (*Gray Level Co-Occurrence*).

<sup>1</sup> NDVI (*Normalized Difference Vegetation Index*) desenvolvido por Rose *et al.* (1974), é muito utilizado, expressando a diferença entre as faixas do infra-vermelho próximo e do vermelho, normalizada pela soma das mesmas (Thiam e Eastman, 1999).

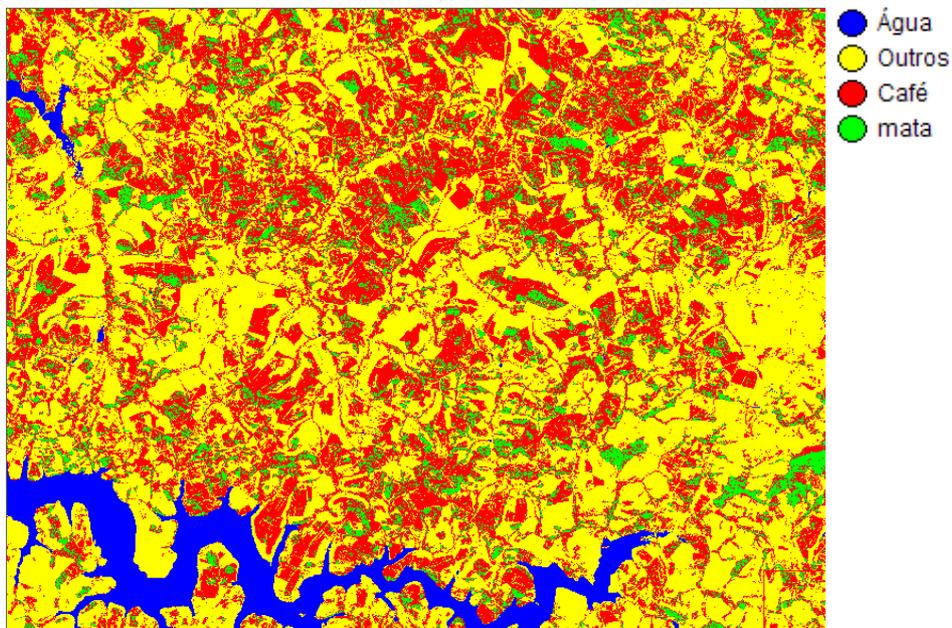
### **3.5 Validação dos resultados**

Para validar as classificações realizadas, foram feitas comparações entre as imagens geradas pela presente metodologia, com a imagem de referência classificada através de interpretação visual, conferida em campo pela equipe do laboratório Geosolos da EPAMIG. A validação foi feita através de matriz de confusão, índice Kappa, índice Global, acurácia de produtor (referente ao café) e acurácia de usuário (referente ao café).

## 4 Resultados e Discussões

### 4.1 Classificação pixel a pixel de máxima verossimilhança

Realizou-se uma classificação pixel a pixel da área de estudo utilizando as classes: Água, café, mata, outros e outros usos. Não foi classificada a área urbana uma vez que ocorreu pouca separabilidade desta com a classe “outros”. Desta forma, a fim de comparar as duas metodologias, a área urbana foi *mergeada* a classe outros. A Figura 14 mostra o resultado da classificação pixel a pixel.



**Figura 14. Classificação pixel a pixel de máxima verossimilhança da área de estudo.**

Após classificada, esta imagem foi validada através da mesma imagem classificada visualmente e conferida em campo, com a classe urbano fundida à classe outros. Os resultados podem ser observados nas matrizes de confusão, erros de comissão e omissão, acurácia do produtor e consumidor, apresentados na Tabela 3.

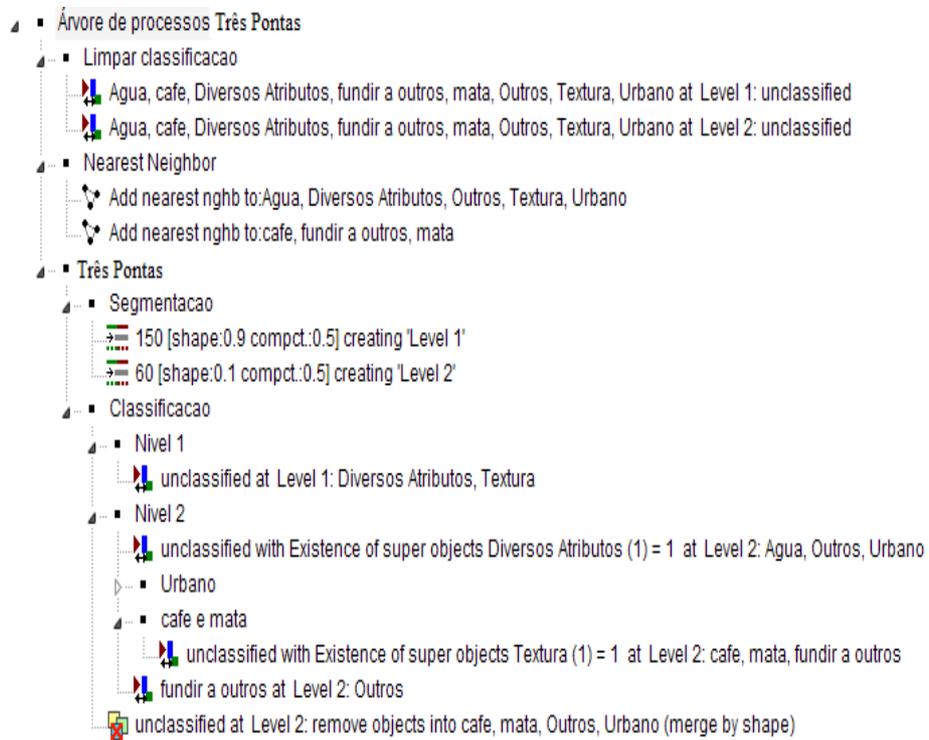
Tabela 3. Matriz de confusão e de acurácias para a comparação entre o mapeamento da classificação pixel a pixel de máxima verossimilhança e a imagem referência.

Classe	Café (%)	Mata (%)	Água (%)	Outros (%)	TOTAL (%)
<b>Café</b>	78,06	56,14	0,73	13,35	35,53
<b>Mata</b>	13,03	33,36	0,36	0,36	8,84
<b>Água</b>	0,01	0,06	96,85	0,1	5,72
<b>Outros</b>	8,90	10,44	2,06	86,19	49,91
<b>TOTAL</b>	100,00	100,00	100,00	100,00	100,00
<b>Comissão (%)</b>	38,82	1,09	45,72	8,04	100,00
<b>Omissão (%)</b>	66,64	3,15	21,94	13,81	100,00
<b>Acc. Produtor (%)</b>	33,36	96,85	78,06	86,19	100,00
<b>Acc. Usuário (%)</b>	61,18	98,91	54,28	91,96	100,00

Para os valores da classificação pixel a pixel o índice Global e o índice Kappa apresentaram valores de 76,2481% e 0,6222 respectivamente. Valores com acurácia menores que as acurácias obtidas por Junior (2011) e maiores que os apresentados por Bernardes (2006) que também utilizaram classificação pixel a pixel para o algoritmo de máxima verossimilhança. Bernardes também demonstra os valores encontrados para a acurácia do produtor e usuário para a classe café, obtendo respectivamente 45,64% e 38,59% para café em formação e 80,26% e 88,01% para café em produção, demonstrando que a confusão ocorre principalmente quando o café esta em formação. A acurácia de produtor para a classe café apresenta valores menores que os citados por Bernardes (2006) enquanto a acurácia de usuário apresenta-se aceitável.

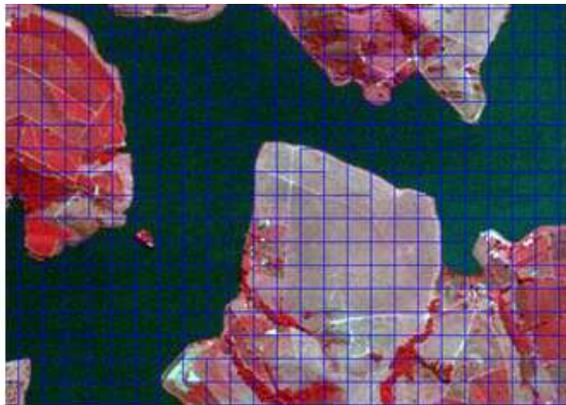
## 4.2 Segmentação

Obteve-se uma árvore de processos automatizada com exceção da parte de amostragem, capaz de segmentar uma imagem em dois níveis e classificá-la automaticamente nas classes definidas. A Figura 15 ilustra essa árvore de processos.

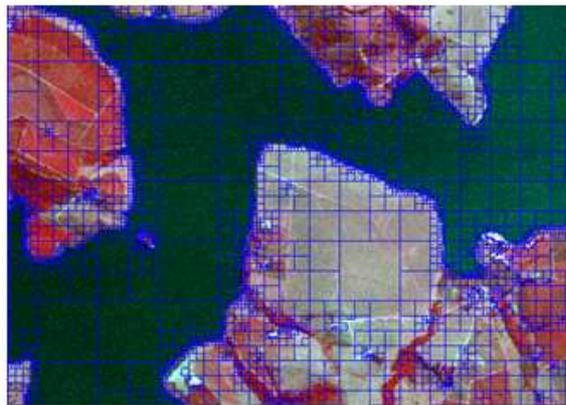


**Figura 15 - Árvore de processos.**

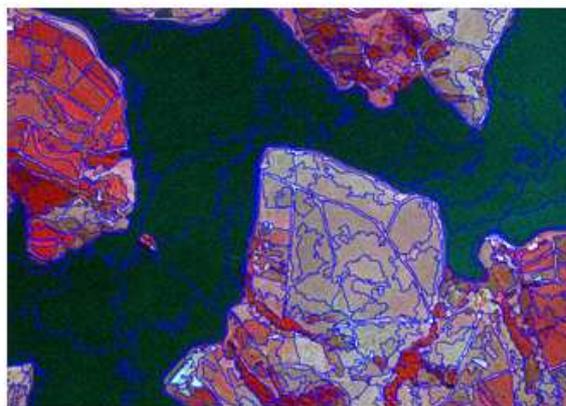
A segmentação realizada para cada algoritmo a partir da árvores de processos pode ser observada na Figura 16 A, B e C.



*Chess Board Segmentation*



*QuadTree Segmentation*



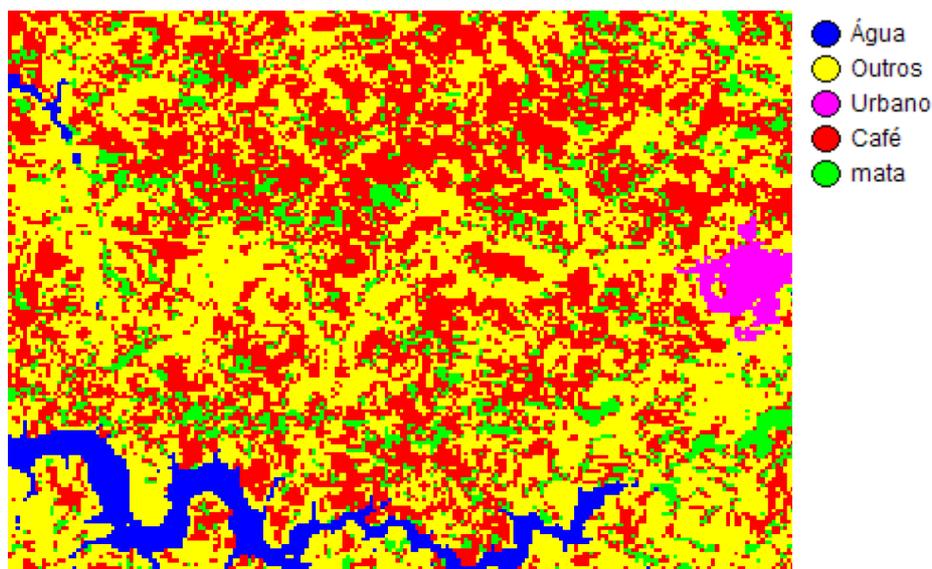
*Multi-resolution Segmentation*

**Figura 16 - Segmentação de imagem pelso algoritmos: *chessboard* (A), *quadtree* (B) e *multi-resolution Segmentation* (C).**

Observa-se na Figura 16, que a segmentação por *chessboard* não possui critérios para inclusão de um pixel nos segmentos, o que acaba gerando grande quantidade de ruídos. Já a segmentação por *quadtree* é mais criteriosa porém acaba gerando um número muito grande de segmentos, dificultando o processamento dos mesmos, pois faz-se necessário uma máquina com maior poder computacional para processamento. O algoritmo *multi-resolution* por sua vez faz um ótimo enquadramento das classes nos segmentos, mostrando-se o melhor dentre estes para a classificação de áreas cafeeiras.

#### 4.2.1 Classificação utilizando *Chessboard Segmentation*

Através do algoritmo de segmentação *chessboard*, das amostras e da classificação através do algoritmo do vizinho mais próximo, obteve-se a imagem classificada da Figura 17.



**Figura 17 - Classificação orientada a segmentos da área de estudo através de *chessboard segmentation*.**

A segmentação através do *chessboard segmentation* acaba incluindo diversas classes no mesmo segmento, equivalendo a utilizar pixels de tamanho maior com atributos adicionais a serem medidos (textura e forma). Os resultados da validação utilizando *chessboard segmentation* podem ser observados nas matrizes de confusão erros de comissão e omissão acurácia do produtor e consumidor da Tabela 4.

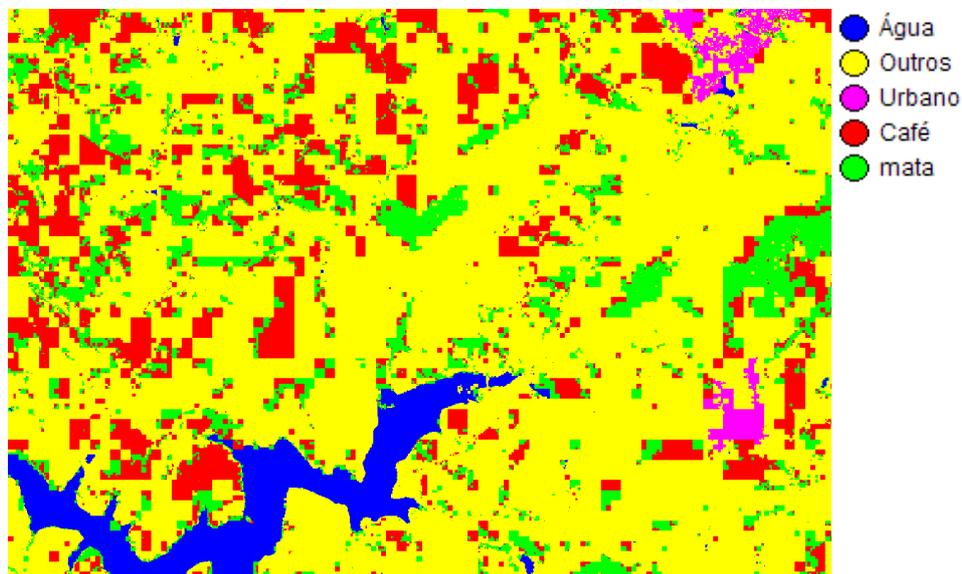
Tabela 4. Matriz de confusão e acurácias para a comparação entre o mapeamento da classificação utilizando o segmentador *chessboard* e a imagem referência.

<b>Classes</b>	<b>Café (%)</b>	<b>Mata (%)</b>	<b>Água (%)</b>	<b>Outros (%)</b>	<b>Urbano (%)</b>	<b>TOTAL (%)</b>
<b>Café</b>	80,01	40,57	2,85	23,88	0,76	38,95
<b>Mata</b>	3,22	39,16	0,89	3,41	0,08	8,97
<b>Água</b>	0,01	0,12	81,31	0,14	0,00	4,84
<b>Outros</b>	16,71	19,85	14,95	72,18	5,43	45,87
<b>Urbano</b>	0,06	0,30	0,00	0,39	93,73	1,37
<b>Total</b>	100,00	100,00	100,00	100,00	100,00	100,00
<b>Comissão (%)</b>	49,24	29,28	1,91	18,06	19,41	100,00
<b>Omissão (%)</b>	19,99	60,84	18,69	27,82	6,27	100,00
<b>Acc. Produtor (%)</b>	80,01	39,16	81,31	72,18	93,73	100,00
<b>Acc. Usuário (%)</b>	50,76	70,72	98,09	81,94	80,59	100,00

Para os valores da classificação utilizando *chessboard segmentation* o índice Global e o índice Kappa obtiveram valores de 69,55% e 0,5298 respectivamente. Os valores são menores que a classificação pixel a pixel através de máxima verossimilhança. Este resultado ocorre uma vez que a segmentação por *ChessBoard* inclui muitas classes diferentes no mesmo segmento, gerando resultados com grande quantidade de ruído. Especificamente para a classe café foi possível obter uma acurácia de produtor de 80,01% e uma acurácia de usuário de 50,76%, valores muito acima do esperado, uma vez que ocorre grande confusão das classes devido ao mal enquadramento das classes nos segmentos.

#### 4.2.2 Classificação utilizando quadtree *Segmentation*

Para realizar a classificação utilizando a segmentação por quadtree, foi necessário realizar a redução do tamanho da área de estudo. Isto ocorreu pois este algoritmo acaba gerando muitos segmentos e a máquina utilizada não foi capaz de processar todos os dados. Desta forma optou-se em utilizar um quarto da cena, onde todas as classes estivessem presentes, obtendo a imagem classificada da Figura 18.



**Figura 18 - Classificação orientada a segmentos da área de estudo através de *quadtree segmentation*.**

A classificação fazendo uso do *quadtree* apresenta melhores resultados quando comparado ao algoritmo *chessboard*, pois a inserção de diversas classes no mesmo segmento ocorre com menor frequência. Os resultados da validação utilizando *quadtree* podem ser observados nas matrizes de confusão, erros de comissão e omissão, acurácia do produtor e consumidor (Tabela 5).

Tabela 5. Matriz de confusão e acurácias para a comparação entre o mapeamento da classificação utilizando o segmentador *quadtree* e a imagem referência.

Classes	Café (%)	Mata (%)	Água (%)	Outros (%)	Urbano (%)	TOTAL (%)
<b>Café</b>	71,57	16,05	0,19	13,33	0,23	21,64
<b>Mata</b>	17,32	68,69	1,77	7,18	0,57	20,02
<b>Água</b>	0,00	0,05	95,92	0,14	0,00	5,14
<b>Outros</b>	11,10	15,18	3,12	78,81	16,96	51,63
<b>Urbano</b>	0,00	0,03	0	0,54	82,24	1,58
<b>Total</b>	100,00	100,00	100,00	100,00	100,00	100,00
<b>Comissão (%)</b>	50,64	34,68	1,77	9,63	20,61	100,00
<b>Omissão (%)</b>	28,43	31,31	5,08	21,19	17,76	100,00
<b>Acc. Produtor (%)</b>	71,57	68,69	94,92	78,81	82,24	100,00
<b>Acc. Usuário (%)</b>	49,36	65,32	98,23	90,37	79,39	100,00

Para os valores da classificação utilizando *quadtree segmentation* o índice Global e o índice Kappa apresentaram valores de 76,7145% e 0,6250 respectivamente, valores mais precisos do que os obtidos com segmentação *chessboard*, especificamente para a classe café foi possível obter uma acurácia de produtor de 71,57% e uma acurácia de usuário de 49,36% valores menores aos encontrados através de *chessboard segmentation* porém muito próximos destes. Pode-se observar que este método de segmentação supera o *chessboard segmentation* e o método pixel a pixel da máxima verossimilhança devido a forma como realiza a segmentação, porém aumenta consideravelmente o custo computacional.

#### 4.2.3 Classificação utilizando Multi-resolution Segmentation

Através do algoritmo de segmentação *Multi-resolution Segmentation*, das amostras e da classificação através do algoritmo do vizinho mais próximo, obteve-se a imagem classificada da Figura 19.

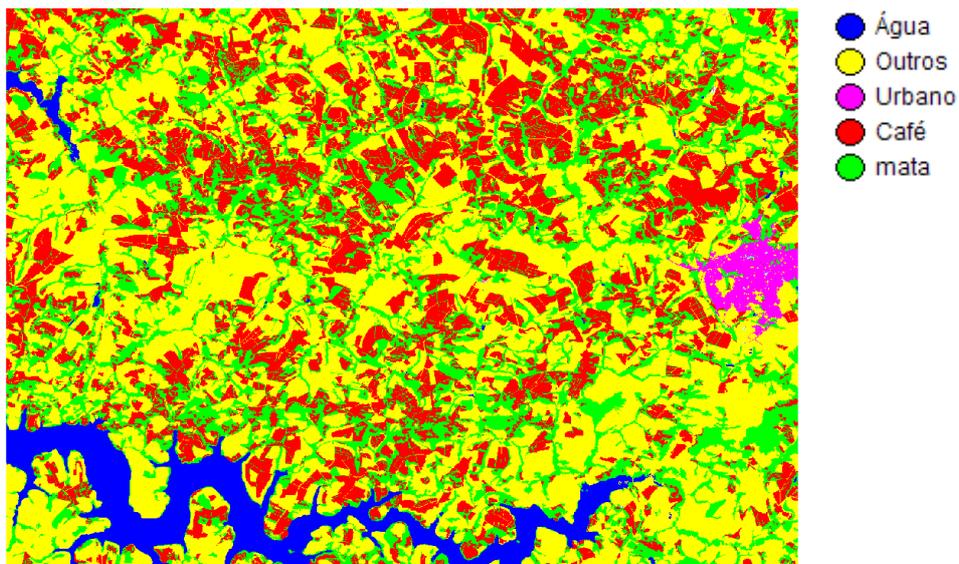


Figura 19 - Classificação orientada a segmentos da área de estudo através de multi-resolution segmentation.

Os segmentos através do *multi-resolution segmentation* adequaram-se muito bem aos contornos dos usos e ocupações da terra, mostrando-se uma boa escolha para classificação, sendo para esta aplicação o melhor algoritmo dentre os aplicados. Os resultados da validação utilizando *Multi-resolution* podem ser

observados nas matrizes de confusão, de comissão e omissão, acurácia do produtor e consumidor (Tabela 6).

Tabela 6. Matriz de confusão e acurácias para a comparação entre o mapeamento da classificação utilizando o segmentador *multi-resolution* e a imagem referência.

Classes	Café (%)	Mata (%)	Água (%)	Outros (%)	Urbano (%)	TOTAL (%)
<b>Café</b>	78,97	4,22	0,01	9,66	0,12	25,23
<b>Mata</b>	7,95	90,78	2,11	13,68	0,79	23,92
<b>Água</b>	0,00	0,02	97,76	0,11	0,01	5,77
<b>Outros</b>	13,08	4,88	0,12	76,39	9,43	43,91
<b>Urbano</b>	0,01	0,09	0,00	0,16	89,65	1,16
<b>Total</b>	100,00	100,00	100,00	100,00	100,00	100,00
<b>Comissão (%)</b>	22,65	38,54	1,09	9,43	8,53	100,00
<b>Omissão (%)</b>	21,03	9,22	2,24	23,61	10,35	100,00
<b>Acc. Produtor (%)</b>	78,97	90,78	97,76	76,39	89,65	100,00
<b>Acc. Usuário (%)</b>	77,35	61,46	98,91	90,57	91,47	100,00

Para os valores da classificação utilizando *multi-resolution segmentation* o índice Global e o índice Kappa apresentaram valores de 80,7616% e 0,7115 respectivamente. Especificamente para a classe café foi possível obter uma acurácia de produtor de 78,97% e uma acurácia de usuário de 77,35%. Acurácias maiores que as apresentadas por Andrade (2011) que fizeram uso de redes neurais artificiais, demonstrando que existe a possibilidade de obtenção de uma maior acurácia caso sejam usadas redes neurais em classificações automáticas supervisionadas que fazem uso de segmentação de imagem.

Os principais resultados obtidos neste trabalho podem ser observados na Tabela 7.

Tabela 7. Índices de exatidão obtidos com as classificações automáticas e a imagem referência.

Algoritmos	Índice Global (%)	Índice Kappa	Acurácia produtor (café) (%)	Acurácia usuário (café) (%)
<b>Máxima verossimilhança</b>	76,25	0,62	33,36	61,18
<b>Chess Board e KNN</b>	69,55	0,53	80,01	50,76
<b>quadtree e KNN</b>	76,72	0,63	71,57	49,36
<b>Multi-resolution e KNN</b>	80,76	0,71	78,97	77,35

## 5 Conclusão

Para imagens orbitais de alta resolução espacial como a *Rapideye*, é recomendado o uso de classificação orientada a segmentos, uma vez que esta apresenta índices globais, índices kappas, acurácias de produtor e usuário com maior acerto do que classificações pixel a pixel, podendo chegar a níveis próximos da classificação visual com eficiência e redução de tempo.

A segmentação utilizando *chessboard segmentation* apresenta grandes erros de inclusão e omissão. Já a segmentação através de *quadtree Segmentation* demonstra melhor inclusão dos segmentos nas classes, porém acaba gerando muitos segmentos, o que dificulta o processamento dos dados, principalmente quando os atributos de textura são analisados. O método *Multi-Resolution Segmentation* gerou segmentos bem adequados aos objetos analisados, raramente ocorrendo mistura de classes no mesmo segmento, sendo avaliado, assim, como o melhor algoritmo segmentador para a classificação de áreas cafeeiras dentre os estudados.

Mesmo com uma boa taxa de acerto ainda é recomendado a realização de correção visual, uma vez que o acerto da imagem pode ser melhorado por interpretação visual, incrementando a acurácia, além de utilizar conhecimento prévio da região favorecendo a amostragem e o processo de segmentação que mostra-se como parte importante da classificação orientada a segmentos.

Existe a possibilidade de melhor segmentação fazendo uso de outros algoritmos segmentadores e escolha de diferentes prioridades para cor, forma, suavidade e compacidade. Também é possível molhar as acurácias da classificação escolhendo atributos que separem melhor as classes de uso, dentre eles diferentes medidas de texturas que mostrou-se importante na classificação das áreas cafeeiras. Também seria uma boa abordagem o treinamento de rede neural artificial utilizando uma imagem segmentada e os diversos atributos de seus segmentos.

## 6 Referências Bibliográficas

ANDRADE, L. N., VIEIRA, T. G. C., LACERDA, W. S., JUNIOR, C. A. D., VOLPATO, M. M. L., ALVES, H. M. R. 2010. **Identificação automática de áreas cafeeiras em imagens de satélites utilizando redes neurais artificiais.** In: Congresso de Pós-Graduação da UFLA, 27., Setembro., 2010, Lavras. 6p. Disponível em: < [www.sbpnet.org.br/livro/lavras/resumos/1962.pdf](http://www.sbpnet.org.br/livro/lavras/resumos/1962.pdf) >. Acesso em : 12 MAIO. 2012.

ANDRADE, L. N. 2011. **Redes Neurais Artificiais na classificação de áreas cafeeiras da região de Guaxupé.** Trabalho de Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Minas Gerais, UFMG, Belo Horizonte, 2011.

BAATZ, M., SCHAPE A. 2000. **Multiresolution segmentation: na optimization approach for high quality multi-scale image segmentation.** In: In Angewandte Geographische Informationsverarbeitung XII Symposium . 2000, Karlsruhe, p. 12-23. Disponível em: < [http://www.ecognition.cc/download/baatz\\_schaepe.pdf](http://www.ecognition.cc/download/baatz_schaepe.pdf) >. Acesso em: 20 MARÇO. 2013.

BERNARDES, T., ALVES, H. M. R., VIEIRA, T. G. C., ANDRADE, H. **Avaliação da acurácia do mapeamento do uso da terra no complexo Serra Negra, Patrocínio, MG, por interpretação visual e classificação automática de imagens Landsat.** In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 13., 2007, Florianópolis. **Anais.** São José dos Campos : INPE, 2007. Artigos, 21-26 abril, p. 5587-5594. Disponível em: < <http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.14.10.39/doc/5587-5594.pdf> >. Acesso em: 30 ABRIL.2012.

BERNARDES, T. **Caracterização do ambiente agrícola do complexo serra negra por meio de sensoriamento remoto e sistemas de informação geográfica.** 2006. Trabalho de Dissertação (Mestrado em Ciência do solo) – Universidade Federal de Lavras, UFLA, Lavras, 2006.

BERNARDI, H. V. F., DZEDZEJ, M., CARVALHO L. M. T., ACERBI, F. W. Classificação digital do uso do solo comparando os métodos “pixel a pixel” e orientado ao objeto em imagem QuickBird. Universidade Federal de Lavras, UFLA. 2007. In: Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 21-26

Abril. 2007, Florianópolis. **Anais**. São José dos Campos: INPE, p. 5595-5602. Disponível em: <  
<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.16.02.01.41/doc/5595-5602.pdf>>. Acesso em: 13 MAIO. 2012.

BEZERRA, M. E. R. **Métodos baseados na regra do vizinho mais próximo para reconhecimento de imagens**. 2006. Trabalho de Conclusão de curso (Bacharel em Engenharia da Computação) – Escola politécnica de Pernambuco – Universidade de Pernambuco. Pernambuco, 2006.

BRITES, R. S., SOARES, V. C., RIBEIRO, C. A. A. S. Comparação de três índices de exatidão aplicados a classificação de imagens orbitais. 1996. In: VIII Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 14-19 Abril. 1996, Salvador. **Anais**. São José dos Campos: INPE, p. 813-821. Disponível em: <  
<http://marte.dpi.inpe.br/col/sid.inpe.br/deise/1999/02.01.15.33/doc/T51.pdf>>. Acesso em: 29 JANEIRO. 2013.

CERQUEIRA, J. A. C. & ALVES, A. O. **Classificação de imagens de alta resolução espacial para mapeamento do tipo de pavimento urbano**. 2010. In: III Simpósio Brasileiro de Ciência Geodésicas e Tecnologias da Geoinformação, 27-30 Julho. 2010, Recife.

CHAGAS, E. M. P. F., RODRIGUES, D. L., TAVARES, J. M. R. S. **Método de Segmentação de Objectos em Imagens Baseado em Contornos Activos e Algoritmo Genético**. 2009. In: Congresso de Métodos Numéricos em Ingeniería 2009, ISBN: 978-84-96736-66-5, pag. 491, 16 pag., 29 Junho - 2 Julho 2009, Barcelona, Espanha.

CONAB, C. N. D. A. **Acompanhamento da safra Brasileira - café**. 2012. Disponível em: <  
[http://www.conab.gov.br/OlalaCMS/uploads/arquivos/12\\_12\\_20\\_16\\_01\\_51\\_bol\\_etimcafe\\_dezembro\\_2012.pdf](http://www.conab.gov.br/OlalaCMS/uploads/arquivos/12_12_20_16_01_51_bol_etimcafe_dezembro_2012.pdf)>. Acesso em: 04 Outubro. 2012.

CRÓSTA, A. P. Processamento Digital de imagens de Sensoriamento Remoto. Ed. rev, Campinas-SP: IG/UNICAMP, 1993. 170p.

Definiens Imaging. eCognition: user guide. 2008, 305 p.

EPIPHANIO, J. C. N., GLERIANI, M. J., FORMAGGIO, A. R., RUDORFF, B. R. T. **Índices de vegetação no sensoriamento remoto da cultura do feijão**. 1994.

FELIX, I. M., KAZMIERCZAK, M. L., ESPINDOLA, G. M. RapidEye: a nova geração de satélites de Observação da Terra. In: XIV Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 25-30., Abril., 2009, Natal. **Anais**. São José dos Campos : INPE, 2009. Artigos, p. 7619-7622. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.17.14.18/doc/7619-7622.pdf>>. Acesso em: 28 MARÇO.2012.

HARALICK, R. M., SHANMUGAM, K. e DINSTEN, I. H. **Textural Features for Image Classification**. Systems, Man and Cybernetics, IEEE Transactions on, v.3, n.6, p.610-621, 1973.

HUSSAIN, Z. 1991. **Digital Image Processing: practical applications of parallel processing techniques**. Ellis Horwood. 406p.

LILLESAND, T.M.; KIEFER, R.W. 2000. Remote sensing and image interpretation. 4<sup>th</sup> edition, 750p.

JONG, S. M.; MEER, F. D. V. 2000. Remote sensing image analyses. Kluwer Academics, 359p.

MACHADO, M. L. et al. **Mapeamento de áreas cafeeiras (Coffea Arabica L.) da zona da mata mineira usando sensoriamento remoto**. 2010. Disponível em: <<http://www.coffeescience.ufla.br/index.php/Coffeescience/article/download/334/pdf>>. Acesso em: 13 MAIO. 2012.

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

MELO, A. Á. et al. **O uso de dados do sensoriamento remoto como recurso didático para o ensino da cartografia na geografia**. Disponível em:<<http://www.caminhosdegeografia.ig.ufu.br/include/getdoc.php?id=369&>>. Acesso em: 30 ABRIL. 2012.

MERELLO, A. B., IMAI, N. N., BENEDITTI, C. A. **Abordagem orientada a objetos aplicada em classificação da cobertura da terra em imagens aéreas**. 2010. Disponível em: <[http://prope.unesp.br/xxii\\_cic/ver\\_resumo.php?area=100046&subarea=12980&congresso=30&CPF=35334637885](http://prope.unesp.br/xxii_cic/ver_resumo.php?area=100046&subarea=12980&congresso=30&CPF=35334637885)>. Acesso em: 01 Maio. 2012.

MORAES, R. M. **Sensoriamento Remoto e classificação de imagens**. João Pessoa. Universidade Federal da Paraíba, UFPB. Departamento de Estatística

1999. Disponível em: <  
<http://www.de.ufpb.br/~ronei/procimagem/procimagem.htm>>. Acesso em: 13  
 MAIO. 2012.

MOREIRA, M. A. Tecnologia da informação: imagens de satélite para o mapeamento de áreas de café de Minas Gerais. 2007.

MOREIRA, M. A. Fundamentos do sensoriamento remoto e metodologias de aplicação. 4ª edição. 2011.

MOREIRA, M. A. 2008 **Geotecnologias no mapeamento da cultura do café em escala municipal**. 2008. 10p. Disponível em: <  
[http://www.scielo.br/scielo.php?pid=S1982-45132008000100007&script=sci\\_arttext](http://www.scielo.br/scielo.php?pid=S1982-45132008000100007&script=sci_arttext)>. Acesso em: 12 Maio. 2012.

NOVO, E.M.L.M. Sensoriamento Remoto: Princípios e Aplicações. São Paulo: Ed. Edgard Blucher, 1989. 308p.

NOVO, E.M.L.M. Sensoriamento Remoto: Princípios e Aplicações. São Paulo: Ed. Edgard Blucher, 2ª edição, 1992. 308p

OLIVEIRA, J. A., DUTRA, L. V., RENNÓ, C. D., SANTOS, P. S. Extração de Atributos de Forma para Classificação de Imagens de Alta Resolução do Satélite HRC/CBERS-2B. In: XIV Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 25-30., Abril., 2009, Natal, **Anais**. São José dos Campos : INPE, 2009. Artigos, p. 7015-7022. Disponível em: <  
<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.17.22.33/doc/7015-7022.pdf>>. Acesso em: 10 Maio. 2012.

RAMOS, M. F. **Discriminação da qualidade dos cafés da Serra da Mantiqueira de Minas Gerais utilizando data mining**. Trabalho de Dissertação (Mestrado em Estatística e experimentação agropecuária) – Universidade Federal de Lavras. [2013] não publicado.

RENNÓ, C. D. **Avaliação das incertezas nas classificações de máxima verossimilhança e contextual de modas condicionais iterativas em imagens jers na região de tapajós, Estado do Pará**. 1998. Disponível em: <  
[http://www.dpi.inpe.br/cursos/ser301/trabalhos/camilo\\_incertezas.pdf](http://www.dpi.inpe.br/cursos/ser301/trabalhos/camilo_incertezas.pdf)>. Acesso em: 12 Março. 2013.

RIBEIRO, S. R. A., CENTENO, J. A. S. Integração de imagens digitais, dados gamaespectrométricos e complementares a fim de separar unidades geológicas

utilizando redes neurais artificiais e uma abordagem baseada na análise de regiões. In: XII Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 16-21., Abril., 2005, Goiânia, **Anais**. São José dos Campos : INPE, 2005. Artigos, p. 3571-3578. Disponível em: <<http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2004/11.18.16.59/doc/3571.pdf>>. Acesso em: 10 Março. 2013.

SILVA, P. R. **Comparação de métodos na classificação digital de imagens**. 2009. 33f. Trabalho de Graduação (Graduação em Engenharia Agrícola) – Universidade Federal de Lavras, UFLA, Lavras, 2009.

SMITH, J. R. & CHANG, S. F. **Quad-tree segmentation for texture-based image query**. 1994. In: ACM 2nd International Conference on multimídia, San Francisco, CA. Disponível em: <<http://www.ee.columbia.edu/ln/dvmm/publications/94/smith94a.pdf>>. Acesso em: 28 Janeiro. 2013.

SOUZA, V. C. O., VIEIRA, T. G. C., ALVES, H. M. R., VOLPATO, M. M. L. Análise e classificação textural de áreas de mata e café na região de Machado – MG. In: XIV Simpósio Brasileiro de Sensoriamento Remoto (SBSR), 25-30., Abril., 2009, Natal, **Anais**. São José dos Campos : INPE, 2009. Artigos, p. 7925-7932. Disponível em: <<http://www.alice.cnptia.embrapa.br/bitstream/doc/880111/1/Analiseeclasificacao.pdf>>. Acesso em: 14 Abril. 2012.

UNIVERSIDADE FEDERAL DE LAVRAS. Biblioteca da Ufla. **Manual de normalização e estrutura de trabalhos acadêmicos**: TCC, monografias, dissertações e teses. Lavras 2010. Disponível em: <<http://www.biblioteca.ufla.br/site/index.php>>. Acesso em: 15 Janeiro. 2013.

VASCONCELOS, C. H., NOVO, E. M. L. M. **Mapeamento do uso e cobertura da terra a partir da segmentação e classificação de imagens – fração solo, sombra e vegetação derivadas do modelo linear de mistura aplicado a dados do sensor TM/Landsat5, na região do reservatório de Tucuruí - PA**. 2004. Disponível em: <<http://www.scielo.br/pdf/aa/v34n3/v34n3a14.pdf>>. Acesso em: 30 Abril. 2012.

VENTURIERI, A. **Segmentação de imagens e lógica nebulosa para treinamento de uma rede neural artificial na caracterização do uso da terra na região de Tucuruí (PA)**. 1996. Disponível em: <<http://urlib.net/sid.inpe.br/iris@1912/2005/07.20.10.59>> Acesso em: 30 Abril. 2012.

VIEIRA, T. G. C., ALVES, H. M. R., VOLPATO, M. M. L., BERNARDES, T., SANTOS, E. R. 2009. **Avaliação de classificadores automáticos no mapeamento de áreas cafeeiras da região de Guaxupé, Minas Gerais.** 2009. In: VI Simpósio de Pesquisa dos Cafés do Brasil. 6p.

VIEIRA JUNIOR, J. A. V. 2011. **Análise comparativa dos métodos de classificação de imagem de alta resolução para mapeamento da cobertura do solo.** Monografia (Especialista em Geoprocessamento) – Universidade Federal de Minas Gerais, UFMG, Belo Horizonte, 2011.

Witten, I. H., Frank, E., Hall, M. A. Data Mining Practical Machine learning Tools and Techniques. 3rd Edition. 2011. 665p.