

RESUMO

Este trabalho tem como objetivo a avaliação temática da aplicabilidade dos dados ópticos do satélite alemão *Rapideye* nos estudos de empreendimentos energéticos, comparando a técnica de Classificação da Máxima Verossimilhança (*pixel a pixel*) com a classificação por meio da Análise Orientada a Objetos, que surge como alternativa ao processo convencional *pixel a pixel*. Na metodologia baseada na análise orientada a objetos, a primeira abordagem foi a segmentação da imagem, na qual foram realizados diferentes níveis de segmentação até ser definida a melhor escala de delineamento para representação dos objetos. Para a classificação foi realizada uma rede hierárquica por meio da semântica de estrutura das classes e utilizou-se como algoritmo a limiarização para a separação das classes. Comparando os resultados das duas metodologias, pode-se concluir que ambas técnicas de classificação apresentaram respostas muito semelhantes, sendo que a orientada a objetos tem como principal vantagem a possibilidade de utilizar informações intrínsecas extraídas dos objetos, como a resposta espectral média, variância, dimensões, forma e textura. A acurácia da qualidade temática da classificação foi calculada a partir dos coeficientes de concordância (*kappa*) gerados a partir das classificações.

Palavras-chave: Segmentação, Limiarização, Classificação, Orientação a Objetos.

ABSTRACT

The objective of this study was to analyze the potential use of Rapideye images to characterize and map the land use and land cover in region of energy development projects. In this study, the technique of Maximum Likelihood Classification (pixel by pixel) was compared with the classification by object-based techniques for image analysis, which appears as an alternative to the conventional pixel by pixel image classification. In the methodological procedure by object-based analysis, the first approach was image segmentation, which were performed at different levels. The classification was based in an hierarchical network structure and thresholding algorithm was used for discriminating classes objects. The results showed very similar responses for both classifications, but object-based has the advantage of the possibility of using information extracted from the intrinsic objects, such as the spectral response mean, variance, size, shape and texture. The coefficients of agreement (Kappa) was used to evaluate the thematic quality.

Key Words: Segmentation, thresholding, classification.

LISTA DE FIGURAS

FIGURA 1: Localização Geográfica da área	14
FIGURA 2: Feições Identificadas	15
FIGURA 3: Feições Identificadas	15
FIGURA 4: Imagem de Satélite <i>Rapideye</i> utilizada no estudo	16
FIGURA 5: Caracterização de Caatingas.....	16
FIGURA 6: Caracterização de Pastagens.....	17
FIGURA 7: Caracterização de Agricultura	17
FIGURA 8: Caracterização de área urbanizada	17
FIGURA 9: Caracterização de área de solo exposto e área preparada para o cultivo.....	18
FIGURA 10: Caracterização de Afloramento Rochoso	18
FIGURA 11: Caracterização de área de exploração mineral – Lavra	18
FIGURA 12: Hierarquia de Objetos demonstrando a relação hierárquica dos super-objetos e sub-objetos (Fonte: Definiens Developer 7.0).....	22
FIGURA 13: Fusão-Segmentação Multi-Resolução (Fonte: Antunes, 2003).....	24
FIGURA 14: Histograma de intensidade particionado por um único Limiar (fonte GONZALEZ & WOODS 2008, adaptado)	25
FIGURA 15: Histograma de intensidade particionado por dois limiares (fonte: GONZALEZ & WOODS 2008, Adaptado)	26
FIGURA 16: Ilustração do Fluxo de Trabalho Fonte:Manual Definiens adaptado	28
FIGURA 17: Curvas de Reflectância dos materiais característicos dos ambientes urbanos.Fonte: Jensen 2009.....	29
FIGURA 18: Fluxograma demonstrativo das Etapas de Trabalho.....	31
FIGURA 19: Comportamento espectral das amostras	33
FIGURA 20: Comportamento espectral das amostras	33
FIGURA 21: Hierarquia da imagem segmentada em várias escalas.....	35
FIGURA 22: Limiarização das Classes.....	36
FIGURA 23: Divisão do Espectro com a Limiarização dos objetos.....	37
FIGURA 24: Resultado da Imagem inicial classificada hierarquicamente.....	38
FIGURA 25: Espectro da Limiarização da Vegetação.....	38
FIGURA 26: Classe de Limiarização da Vegetação	39
FIGURA 27: Espectro da Limiarização da Não Vegetação.....	39

FIGURA 28: Classe de Limiarização da Não Vegetação	40
FIGURA 29: Amostras aleatórias geradas na imagem original	42
FIGURA 30: Recorte da Imagem original <i>Rapideye</i>	47
FIGURA 31: Classificação Maxver	47
FIGURA 32: Classificação Orientada Objeto	48
FIGURA 33: Recorte da Imagem original <i>Rapideye</i>	49
FIGURA 34: Classificação Maxver	48
FIGURA 35: Classificação Orientada Objeto	50
FIGURA 36: Recorte da Imagem original <i>Rapideye</i>	49
FIGURA 37: Classificação Maxver	51
FIGURA 38: Classificação Orientada Objeto	51

LISTA DE TABELAS

TABELA 01: Parâmetros do Satélite Rapideye.....	19
TABELA 02: Classes Utilizadas.....	32
TABELA 03: Parâmetros utilizados no Processo de Segmentação dos Objetos da Imagem	34
TABELA 04: Classes de Objetos.....	40
TABELA 05: Matriz de Erros de Classificação Maxver (Pixel a Pixel).....	43
TABELA 06: Matriz de Erros de Classificação Orientada a Objetos.....	44
TABELA 07: Qualidade da Classificação segundo intervalos do coeficiente de concordância Kappa.....	46
TABELA 08: Tabela Condicional Kappa para cada classificação / categoria	46
TABELA 09: Tabela de Acurácia com Pontos Aleatórios para Classificação Pixel a Pixel.....	57
TABELA 10: Tabela de Acurácia com Pontos Aleatórios para Classificação Orientada Objetos	60

SUMÁRIO

1. INTRODUÇÃO	12
1.2. OBJETIVO	13
2. CARACTERÍSTICAS DA ÁREA DE ESTUDO	14
2.1 LOCALIZAÇÃO DA ÁREA	14
2.2 DEFINIÇÃO E CARACTERIZAÇÃO DAS CLASSES DE INTERESSE	16
2.3. MATERIAIS E DADOS UTILIZADOS	19
2.3.1 Dados de Imagem	19
2.3.2 Material de Apoio de Campo.....	19
2.3.3 Programas Utilizados	19
3. REVISÃO BIBLIOGRÁFICA	20
3.1 SEGMENTAÇÃO DE IMAGENS	20
3.1.1 Técnica de Crescimento de Regiões	20
3.1.2 Técnica de Segmentação Multi-resolução e Hierarquia dos Segmentos	21
3.1.2.1 Parâmetro da Escala de Segmentação	23
3.1.2.2 Composição do Critério de Semelhança.....	23
3.1.3 Técnicas de Classificação dos Segmentos	24
3.1.3.1 Classificador Vizinheiro mais Próximo.....	24
3.1.3.2 Classificador de Limiarização dos Segmentos	25
3.1.3.3 Classificador de Inferência Fuzzy	26
3.2 CLASSIFICAÇÃO DE IMAGENS	27
3.2.1 Método da Máxima Verossimilhança (Maxver) – <i>Pixel a Pixel</i>	27
3.2.2 Análise Orientada a Objeto	27
3.2.3 Rede semântica de Classificação Hierárquica das Classes	28
3.2.4 Comportamento Espectral dos Alvos	29
4. METODOLOGIA.....	30
4.1 FLUXOGRAMA DE TRABALHO	31
4.2 CLASSIFICAÇÃO MÁXIMA VEROSSIMILHANÇA – <i>PIXEL A PIXEL</i>	32
4.3 SEGMENTAÇÃO DA IMAGEM EM OBJETO.....	34
4.4 ANÁLISE ORIENTADA A OBJETO	36

4.4.1 Classificação dos Segmentos	36
4.4.2 Classificação Hierárquica das classes	37
4.4.3 Classificador de Limiarização dos Segmentos	37
5. ANÁLISE E COMPARAÇÃO DOS RESULTADOS OBTIDOS	41
5.1 AVALIAÇÃO DA ACURÁCIA.....	41
5.2 AVALIAÇÃO DO COEFICIENTE <i>KAPPA</i> (K).....	43
5.3 ANÁLISE COMPARATIVA ENTRE OS MÉTODOS DE CLASSIFICAÇÃO.....	47
6. CONCLUSÃO.....	51
REFERÊNCIAS BIBLIOGRÁFICAS	55
ANEXO 1.....	57

1. INTRODUÇÃO

O mapeamento do uso e cobertura do solo nas áreas de abrangência direta e indireta de empreendimentos energéticos como as linhas de transmissão, parques eólicos, subestações de energia, reservatórios e usinas de geração, tem se tornado uma importante tarefa para as empresas do setor elétrico. Tal tarefa de mapeamento constitui-se um desafio permanente no planejamento, construção e manutenção desses empreendimentos para as instituições e pessoas que procuram seu desenvolvimento econômico sem exceder os limites da capacidade de sustentabilidade. Os cenários dessas áreas de abrangência são formados pela transição de diversos ambientes terrestres, compostos desde áreas marcadas pelas ações antrópicas, áreas de preservação e áreas urbanizadas possuindo grande relevância no contexto ambiental, conseqüentemente o balanço entre relações de uso, desenvolvimento econômico e proteção ambiental de tais locais, demandam esforços coordenados nos diversos níveis de administração.

O avanço da tecnologia para aquisição de imagens de satélite e a comercialização de imagens com resoluções geométricas melhores que 10 metros, tem se tornado uma valiosa ferramenta podendo desempenhar importante papel no processo de planejamento e no mapeamento do uso e cobertura do solo, entretanto, os produtos advindos do sensoriamento remoto necessitam de novas técnicas de tratamento dos dados, porque permitem uma discriminação mais detalhada e obtenção de maior número de elementos que compõem a cena.

Na abordagem e discussão deste assunto podem ser utilizados diversos caminhos, escolheu-se apresentar este tema, depois de conceitualizar a problemática ambiental e da real necessidade de atualização constante de informações das áreas de cobertura vegetal e urbanização que estão na abrangência direta e indireta dos empreendimentos energéticos.

Podem-se ressaltar as razões e características especiais que justificam o estudo dos diversos ecossistemas próximos a esses tipos de empreendimentos, que são: fatores como especulação imobiliária, desmatamento e crescente nível de expansão urbana desordenada nas áreas próximas, entre outros.

Para atender essas necessidades, dentre as diversas técnicas disponíveis, o sensoriamento remoto que permite a visão global de áreas extensas, em conjunto com um sistema de informações geográficas, apresenta-se com alto valor estratégico para tomada de decisões, propiciando a identificação, a demarcação e o entendimento das relações entre aspectos socioambientais e econômico-constructivo.

Existe atualmente o mapeamento dos remanescentes da cobertura vegetal e do uso do solo do Bioma Caatinga com caracterização básica das diversas tipologias vegetais na meso-escala de 1:250.000, projeto conhecido como PROBIO - Projeto de Conservação e Utilização Sustentável da Diversidade Biológica Brasileira <<http://mapas.mma.gov.br/mapas/aplic/probio/datadownload.htm>> do Ministério do Meio Ambiente, entretanto, pelas limitações que esta escala apresenta, não é possível realizar um planejamento adequado no entorno destes tipos de empreendimentos e neste caso, seria necessário a realização de mapas de identificação de uso e ocupação do solo nas escalas de 1:25.000 ou melhor.

A questão a ser discutida em relação a este quadro, converge em torno dos métodos mais adequados de processamento digital de imagens para obter informações a respeito do espaço usando imagens do satélite *Rapideye*.

1.2. OBJETIVO

O objetivo geral deste trabalho é a avaliação temática da aplicabilidade dos dados ópticos do satélite *Rapideye* por meio do processamento digital de imagem, utilizando a técnica de Classificação Orientada a Objetos, comparando os resultados com uma classificação supervisionada pelo método estatístico da Máxima Verossimilhança (*Pixel a Pixel*), para a obtenção de informações de uso e ocupação do solo que sejam adequadas aos estudos de empreendimentos energéticos.

Dentre os objetivos específicos deste trabalho tem-se:

- Classificar as imagens pelo método da Máxima Verossimilhança (*Pixel a Pixel*);
- Definir parâmetros de Segmentação da imagem em objetos, de forma a caracterizar e delinear alvos;
- Classificar a imagem pelo método orientado a objetos utilizando algoritmo de limiarização;
- Avaliar o desempenho dos classificadores envolvidos a partir da análise de desempenho (matriz de confusão e índice *Kappa*);

2. CARACTERÍSTICAS DA ÁREA DE ESTUDO

2.1 LOCALIZAÇÃO DA ÁREA

A área de abrangência compreende uma região localizada no Estado da Bahia entre os municípios de Irecê e Morro do Chapéu, situado a 478 km da cidade de Salvador, abrangendo a parte Setentrional da Chapada Diamantina, localizada na área do Polígono das Secas, inserido no bioma caatinga. A figura 01 representa a localização geográfica da área.

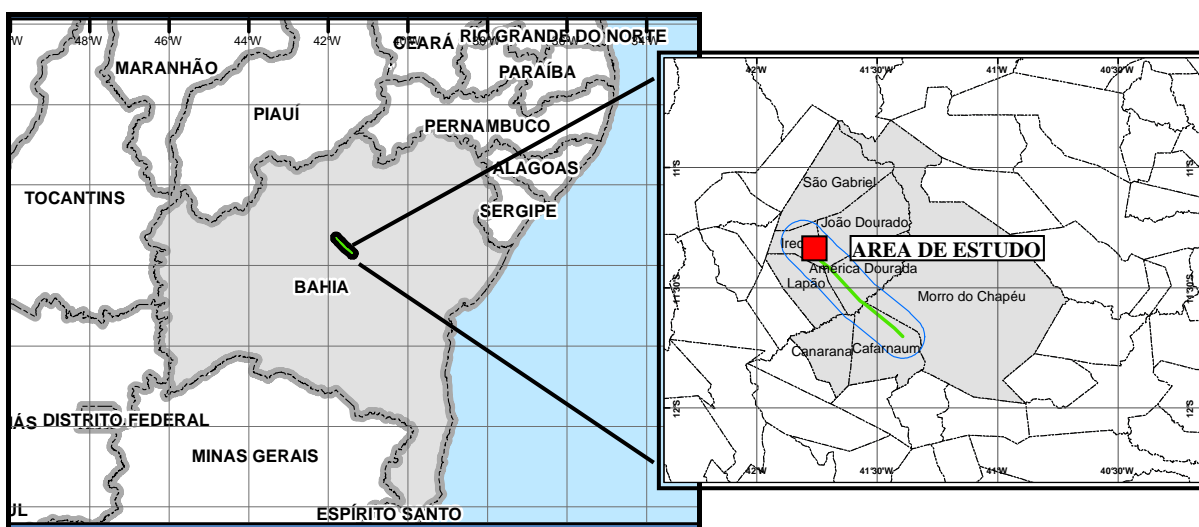


FIGURA 1: Localização Geográfica da área

A área de estudo está inserida no município de Irecê e abrange aproximadamente 2000 Ha de área e 20 km de perímetro e caracteriza-se por ser bastante antropizada, devido a exploração agrícola em larga escala. A área em estudo apresenta uma grande variedade de feições como:

- Trechos de vegetação de Caatingas Arbórea e Arbustiva;
- Atividades agrícolas de policultura intensivas, extensivas ou de subsistências com os cultivos principalmente de milho, feijão, cenoura, cebola, batata-doce, mamona, palma e sisal;
- Processos de ocupação e expansão urbana;
- Possibilidade de exploração mineral de lavras e minérios.

As figuras 2 e 3 a seguir mostram as principais feições identificadas na região de estudo.



FIGURA 2: Feições Identificadas




FIGURA 3: Feições Identificadas

A região destaca-se por ser alvo de empreendimentos de geração e transmissão de energia elétrica. Dentre os empreendimentos que serão construídos estão: um parque Eólico, uma nova Subestação de energia de 230 kV/69 kV e uma linha de transmissão de 230 kV. A linha de transmissão será de aproximadamente 60 km, e ligará a nova Subestação de Energia do Morro do Chapéu a Subestação existente de Irecê.



FIGURA 4: Imagem de Satélite *Rapideye* utilizada no estudo

2.2 DEFINIÇÃO E CARACTERIZAÇÃO DAS CLASSES DE INTERESSE

Para a definição das classes de uso e cobertura do solo deste trabalho foram realizados trabalhos de campo entre os dias 14/02/2011 a 17/02/2011 tanto *in loco* como um sobrevôo com helicóptero, obtendo as seguintes classes:

A) Vegetação composta de caatinga arbórea e arbustiva;



FIGURA 5: Caracterização de Caatingas

B) Área de pastagem;



FIGURA 6: Caracterização de Pastagens

C) Área de Agricultura, caracterizada por agricultura de subsistência e agricultura intensiva e mecanizada (pivôs);



FIGURA 7: Caracterização de Agricultura

D) Área urbanizada, como construções e sede de propriedades.



FIGURA 8: Caracterização de área urbanizada

E) Solo exposto, área preparada para o plantio e áreas de depósito de terras.



FIGURA 9: Caracterização de área de solo exposto e área preparada para o cultivo

F) Área com formação de Afloramento Rochoso;



FIGURA 10: Caracterização de Afloramento Rochoso

G) Área passível de exploração mineral (lavras)



FIGURA 11: Caracterização de área de exploração mineral – Lavra.

2.3. MATERIAIS E DADOS UTILIZADOS

2.3.1 Dados de Imagem

Utilizou-se neste estudo os dados do satélite alemão *Rapideye*, com lançamento realizado em 29 de agosto de 2008, possuindo um sensor multiespectral capaz de capturar imagens em cinco bandas espectrais, com alcance de comprimento de onda entre 440 μm a 850 μm , conforme descrito na Tabela 01. A imagem utilizada é um produto ortorretificado com correção radiométrica e geométrica compatível com escala 1:50.000, com sistema de referencia WGS84 e projeção UTM. A cena utilizada foi a 2433802 obtida na data 11/08/2010.

TABELA 01: Parâmetros do Satélite Rapideye (<http://www.rapideye.de/>)

MODO	Multiespectral 5 bandas
RESOLUÇÃO GEOMÉTRICA (NÍVEL SENSOR)	6,5 metros
RESOLUÇÃO GEOMÉTRICA ORTORRETICADA	5,0 metros
RESOLUÇÃO RADIOMÉTRICA	12 Bits (4096 níveis de cinza)
RESOLUÇÃO ESPECTRAL (μm)	440 – 510 (azul)
	520-590 (verde)
	630-685 (vermelho)
	690-730 (rededge)
	760-850 (IV. Próximo)
FAIXA IMAGEADA	78 km
ALTITUDE DA ÓRBITA	620 km

2.3.2 Material de Apoio de Campo

Foram utilizados neste trabalho para coleta de amostras de campo um receptor GPS Garmin modelo 60CSx, uma câmera digital RICOH modelo caplio 500 SE.

2.3.3 Programas Utilizados

Para o desenvolvimento deste trabalho foram utilizados os seguintes softwares:

- Erdas Imagine – Versão 9.3 Para Classificação das Imagens Máxima Verossimilhança <<http://www.erdas.com/products/ERDASIMAGINE/ERDASIMAGINE/>>;
- EcognitionDeveloper 7.0 - Para Segmentação e Classificação das Imagens Orientada a Objeto <<http://www.ecognition.com/>>;

3. REVISÃO BIBLIOGRÁFICA

3.1 SEGMENTAÇÃO DE IMAGENS

O processo de segmentação consiste na divisão da imagem em regiões que devem corresponder às áreas de interesse da aplicação. Entende-se por regiões um conjunto de *pixels* contíguos, que apresentam uniformidade.

Existem diferentes alternativas para a segmentação de imagens, como por exemplo, as técnicas de crescimento de regiões, limiarização, divisão-fusão (*Split and Merge*) (GONZALES, 2008) e segmentação multi-resolução (BAATZ & SCHÄPE, 1999).

Utilizando-se de algoritmos de segmentação é possível extrair objetos da imagem em diferentes resoluções (estruturas finas ou grosseiras), possibilitando adaptar a extração de objetos primitivos significativos da imagem às tarefas das classes (hierarquia das classes) e dos dados específicos da imagem (resoluções espacial e espectral). Sendo que os objetos segmentados apresentam muito mais informações que *pixels* individuais, como cor, forma, textura, brilho das regiões associadas.

3.1.1 Técnica de Crescimento de Regiões

De acordo com GONZALEZ & WOODS (2008), o crescimento de regiões é uma técnica de agrupamento espacial na qual somente *pixels* adjacentes, contíguos na imagem, podem ser agrupados. Esta técnica consiste em partir de um ou vários *pixels* considerados uniformes, analisar os *pixels* na vizinhança e adicionar os vizinhos que forem similares ao grupo inicial, de maneira que a região formada cresça num processo iterativo que termina quando as fronteiras naturais dos objetos presentes na cena forem atingidas. No final do processo, a imagem encontra-se dividida em várias sub-regiões.

Este processo pode ser formalmente descrito como:

Seja **I** o conjunto de todos os objetos da imagem, a segmentação por crescimento de região pode ser vista como o processo de subdivisão de **I** em **n** sub-regiões, **R₁**, **R₂**, ...**R_N**, tal que:

1. $\bigcup_{i=1}^n R_i = I$, onde todos os *pixels* devem pertencer a uma única região;
2. Cada região **R_i**, $i=1,2,3 \dots n$, deve ser conexa;

3. As regiões devem ser disjuntas, tal que, $\mathbf{R}_i \cap \mathbf{R}_j = \emptyset$ para todo i e j , $i \neq j$;
 4. Os pixels em \mathbf{R}_i de uma mesma região devem possuir a mesma intensidade ou característica;
 5. $\mathbf{P}(\mathbf{R}_i) = \text{verdadeiro}$ para $i = 1, 2, \dots, n$ e para diferentes regiões $\mathbf{P}(\mathbf{R}_i \cup \mathbf{R}_j) = \text{falso}$, para $i \neq j$.
- Onde $\mathbf{P}(\mathbf{R}_i)$ é um predicado lógico sobre os pontos do conjunto \mathbf{R}_i e \emptyset é o conjunto vazio;
- A condição (1) sugere que a segmentação deve ser completa. A segunda condição requer que *pixels* de uma mesma região devem ser conexos.

Um parâmetro fundamental para o sucesso do método é a escolha do critério de similaridade entre o *pixel* para definir se o pixel pertence à região. No caso de imagens de satélite, a uniformidade espectral é geralmente adotada, mas não é necessariamente a única opção.

O processo pode ser descrito assim:

- 1) Particionar a imagem em regiões (por exemplo: 1 região = 1 *pixel*);
- 2) Procurar um *pixel* que ainda não foi processado, ele será considerada a “semente” que dará origem a uma região maior;

0	0	5	6	6
0	0	5	7	7
1	1	6	7	7
0	0	7	6	6

0	0	5	6	6
0	0	5	7	7
1	1	6	7	7
0	0	7	6	6

- 3) Cada *pixel* da região “semente” é então comparado com seus vizinhos, se o vizinho atende ao critério de similaridade, então é incluído na região.
- 4) Repetir para cada *pixel* da região semente, até não ocorrer mais crescimento;
- 5) Repetir o processo, isto é, escolher nova “semente”.

3.1.2 Técnica de Segmentação Multi-resolução e Hierarquia dos Segmentos

A técnica de segmentação multi-resolução é considerada similar à utilizada pelo processo de segmentação por crescimento de região (ANTUNES, 2003), na qual cada *pixel* é rotulado seguindo um critério de similaridade para cada par de regiões adjacentes espacialmente (GONZALES; WOODS, 2008).

Nesta técnica de segmentação não existe um modelo formal, sendo o processo essencialmente empírico e, em geral, ajustável aos diferentes tipos de imagens, com limiares definidos conforme a complexidade dos alvos investigados (ANTUNES, 2003).

A segmentação multi-resolução, segundo (ANTUNES, 2003) pode ser descrita como uma técnica que junta pequenos *pixels* em grupos maiores de *pixels* até o nível de escala desejado, técnica conhecida como *bottom-up* de fusão de regiões

Na técnica *bottom-up* de fusão de regiões a segmentação a imagem é dividida como segmentos como parte do processo, representando uma região espacialmente definida. Os *pixels* de cada região estão ligados aos segmentos através de uma relação, sendo que o conjunto de segmentos resultante de um processo de segmentação forma um nível de segmento, e cada objeto inferior é ligado aos respectivos objetos de nível superior caracterizando o processo de hierarquia dos segmentos.

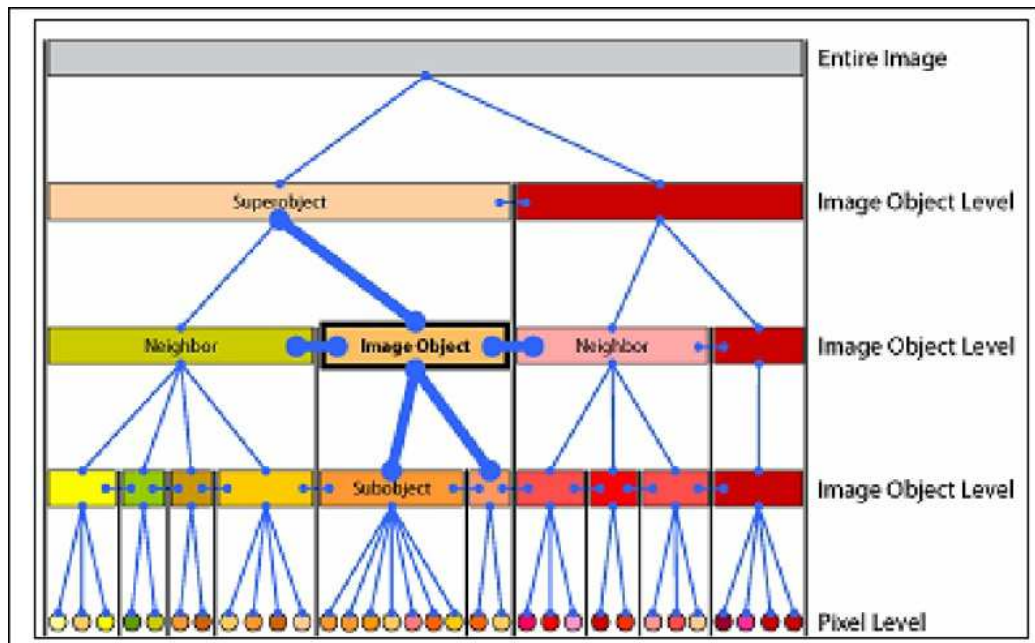


FIGURA 12: Hierarquia de Objetos demonstrando a relação hierárquica dos super-objetos e sub-objetos (Fonte: Definiens Developer 7.0)

O processo de segmentação inicia-se considerando cada *pixel* como um objeto. Iterativamente um par de objetos é agrupado em um objeto de dimensão maior. A regra para o agrupamento (fusão) é baseada em um critério de heterogeneidade, que descreve a dissimilaridade de objetos adjacentes. O critério de heterogeneidade é uma combinação de propriedades espectrais e espaciais. O algoritmo descreve estas propriedades como critérios de cor (espectrais) e de forma (espaciais). O critério de forma ainda é subdividido entre os parâmetros de compacidade e suavidade. Estes critérios podem ser traduzidos como uma

ponderação em que a segmentação buscará priorizar na formação dos objetos (ANTUNES, 2003).

Os números de elementos gerados variam conforme o peso que se atribui a cada banda da imagem em conjunto com o parâmetro de escala e com os pesos associados ao critério de semelhança (cor e forma).

3.1.2.1 Parâmetro da Escala de Segmentação

O parâmetro da escala de segmentação determina o tamanho médio do objeto da imagem, permitindo uma mudança heterogênea durante todo processo de segmentação, sendo sua determinação abstrata que depende do tamanho a imagem e do grau de detalhamento dos objetos da imagem.

3.1.2.2 Composição do Critério de Semelhança

A composição do critério de semelhança é usada para definir a uniformidade dos segmentos. Dois critérios são usados para descrever a separação do objeto da imagem: critério da cor e o critério da forma (critério de suavização e o critério de compactação).

O critério da cor é compreendido em parte pela semelhança espectral e o critério da forma diz respeito à distribuição espacial das bordas dos segmentos a serem fundidos. Os critérios de suavização e de compactação estão vinculados ao critério da forma, e descrevem o desvio da forma do segmento em relação a uma forma que pode ser geométrica.

Atribui-se pesos diferenciados para cada critério, peso maior para a cor quando se deseja salientar os detalhes espectrais da imagem colorida e peso maior para a forma quando se deseja salientar a textura da imagem.

Neste estudo utilizou-se a técnica de segmentação de multi-resolução de regiões, que segundo ANTUNES (2003), pode ser explicada com as seguintes etapas:

- I- O resultado de um processo de segmentação leva a objetos primitivos como uma primeira aproximação a objetos da imagem do mundo real. A segmentação multi-resolução é, em sua essência, a técnica que começa com os objetos de um *pixel*;
- II- Em etapas subseqüentes, numerosos objetos menores da imagem são fundidos em objetos maiores. Em cada etapa posterior, objetos adjacentes na imagem são fundidos conforme critérios de semelhança. O parâmetro escala influencia diretamente no

tamanho médio do objeto: um valor de escala maior conduz a objetos maiores (Figura 13).

III- Os objetos gerados na imagem segmentada (Figura 13) estão inter-relacionados, de modo que cada objeto da imagem possui um contexto (vizinhança). Assim, é possível definir dependências entre os objetos. A estrutura hierárquica é dotada de relações topológicas definidas, isto é, o limite de um super-objeto é coincidente com os limites dos objetos secundários, de acordo com a Figura 13. A área representada por um objeto específico da imagem é definida pelo somatório das áreas dos sub-objetos que o compõem. Cada nível é construído baseado em seus objetos secundários diretos, isto é, os objetos secundários são fundidos em objetos maiores da imagem em um nível subsequente, sendo que a fusão é limitada pelos limites do super-objeto.




FIGURA 13: Fusão-Segmentação Multi-Resolução (Fonte: Antunes, 2003)

3.1.3 Técnicas de Classificação dos Segmentos

Para a classificação dos segmentos, existem diversos métodos disponíveis, entre os quais podemos citar: vizinho mais próximo, limiarização e inferência fuzzy.

3.1.3.1 Classificador Vizinho mais Próximo

Este classificador tem como base segmentos que são utilizados como amostra de treinamento para cada classe, de forma que permita a combinação de características relacionadas às classes. Deste modo, em cada segmento é feita a análise da distância entre o segmento e cada classe, no espaço multidimensional dos parâmetros considerados, e opta pela classe mais próxima.

3.1.3.2 Classificador de Limiarização dos Segmentos

A limiarização é uma forma de agrupamento de regiões homogêneas (GONZALEZ & WOODS, 2008).

A limiarização por similaridade consiste basicamente no processo de separar os objetos a partir do valor de sua tonalidade (valor do pixel). Para isso, determina-se uma intensidade de cinza, chamada de limiar, que separa a imagem em duas partes: regiões com tonalidade maior que o limiar e regiões com tonalidade menor que o limiar. O principal complicador deste processo é determinar qual é o valor do limiar

De acordo com GONZALEZ & WOODS (2008), quando um limiar (**T**) é uma constante aplicável a uma imagem inteira, o processo é conhecido como limiarização global e quando o limiar (**T**) muda ao longo da imagem é o processo é conhecido como limiarização variável. Estabelecido o valor do limiar (**T**) para separar objetos de uma imagem simples do tipo binária, conforme figura 14, usa-se a seguinte função:

$$g(x,y) = 1, \text{ se } f(x,y) > T$$

$$g(x,y) = 0, \text{ se } f(x,y) \leq T$$

Onde $f(x,y)$ é o valor da intensidade de cinza dos objetos. Considera-se, então, os objetos com valor 1 como sendo objetos pertencente a uma classe e os de valor 0 como sendo de fundo.




FIGURA 14: Histograma de intensidade particionado por um único Limiar (fonte GONZALEZ & WOODS 2008, adaptado)

No caso de uma imagem contendo mais de dois objetos conforme figura 14, com níveis de cinza distintos utiliza-se a limiarização múltipla, representada pela seguinte função:

$g(x,y) = A$, se $f(x,y) \leq T1$

$g(x,y) = B$, se $T1 < f(x,y) \leq T2$

$g(x,y) = C$, se $f(x,y) > T2$




FIGURA 15: Histograma de intensidade particionado por dois limiares (fonte: GONZALEZ & WOODS 2008, Adaptado)

3.1.3.3 Classificador de Inferência Fuzzy

Os algoritmos de classificação baseado na inferência *fuzzy*, lidam com conceitos inexatos e com uma metodologia de caracterização de classes, que por várias razões não tem ou não pode definir limites rígidos (bordas) entre classes. A utilização de um conjunto *fuzzy* é indicada sempre que se tiver que lidar com ambigüidade, abstração e ambivalência em modelos matemáticos (BURROUGH, 1998).

De uma forma simples pode-se imaginar que a função é uma escolha em relação à capacidade de conhecimento do especialista, e da dificuldade de classificar a variável em análise.

Na representação *fuzzy*, o grau de pertinência nas classes pode ser definido como conjunto *fuzzy* e os pixels como elementos. Um *pixel* pode pertencer a uma determinada classe com um grau de pertinência e a outra classe com outro grau de pertinência.

3.2 CLASSIFICAÇÃO DE IMAGENS

Para a classificação de imagens existem diversos métodos disponíveis dentre os quais utilizam o *pixel* como referência, utilizando a informação espectral isoladamente do *pixel* e outros métodos que levam em conta as características de um conjunto de *pixels* vizinhos baseados em critérios de similaridade, construindo deste modo uma região de *pixels* ou segmentos.

3.2.1 Método da Máxima Verossimilhança (Maxver) – *Pixel a Pixel*

A classificação pelo método da Máxima Verossimilhança é baseada no princípio de que a classificação errada do *pixel* particular não tem mais significado do que a classificação errada de qualquer outro *pixel* na imagem (RICHARDS, 1999). O usuário determina a significância nos erros de atributos especificados para uma classe em relação à outra.

Os classificadores *pixel a pixel* utilizam apenas a informação espectral, isoladamente, de cada *pixel* para achar a classe mais provável para o *pixel*. Estes classificadores podem ser ainda separados em métodos estatísticos (que utilizam regras da teoria de probabilidade) e determinísticos (que não o fazem) (CHUVIECO,1990).

A eficácia do método Maxver depende, principalmente, de uma precisão razoável da estimativa do vetor médio e da matriz covariância de toda a classe espectral. Isso depende da quantidade de *pixels* incluída na amostra de treinamento. Com isso pode-se calcular a probabilidade de um dado *pixel* pertencer a uma classe específica (JENSEN, 2009), de acordo com a regra:

O *pixel* “x” pertence a classe w_i se

$P(w_i|x) > P(w_j|x)$ com $i \neq j$

Onde $p(w_i|x) = [p(w) * p(x|w_i)] / p(x)$

3.2.2 Análise Orientada a Objeto

A classificação digital de imagens baseada na metodologia de orientação a objeto permite que se leve em consideração propriedades oriundas do agrupamento de pixels, como forma, textura e brilho. Desta forma não se analisa o pixel individualmente, mas um conjunto

de pixels, determinados aqui como segmentos da imagem. Objetos que possuem propriedades similares podem ser associados a determinada categoria de segmentos (ANTUNES, 2003).

Ao contrário dos métodos tradicionais para a classificação digital de imagens, na classificação baseada em objeto a análise é realizada sobre objetos ou segmentos na imagem e não apenas sobre *pixels*. Cada objeto ou segmento representa uma feição do mundo real, possuindo propriedades temáticas e geométricas (ANTUNES, 2003).

3.2.3 Rede semântica de Classificação Hierárquica das Classes

A rede semântica de classificação hierárquica de classes pode ser considerada uma das etapas mais importantes do processo de classificação orientada a objetos. A separabilidade progressiva dos objetos facilita a discriminação entre as classes, permitindo que sejam aplicadas algoritmos de separação entre as classes distintamente uma das outras.

A classificação hierárquica é realizada por uma relação de dependência subordinada ao conhecimento adquirido. Essa relação pode ser formada por regras é oriunda das propriedades que compõem os objetos.

A Figura 16 apresenta um esquema hierárquico onde há duas grandes superclasses distintas que vão formando subdivisões em outras classes. As classes do nível inferior só podem existir condicionadas a superclasse do nível superior e assim sucessivamente.

O processo pode incluir um número arbitrário de processos filhos da imagem classificada, a hierarquia resultante define a estrutura e controle do fluxo da imagem.

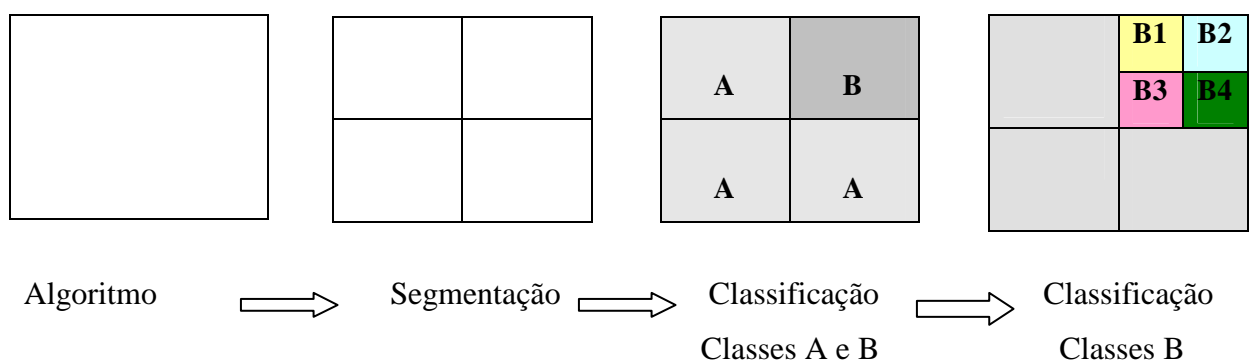


FIGURA 16: Ilustração do Fluxo de Trabalho Fonte: Manual Definiens adaptado

3.2.4 Comportamento Espectral dos Alvos

Em sensoriamento remoto, a assinatura espectral de um alvo compreende um conjunto de valores de reflectância para o mesmo, medido num intervalo específico de comprimento de onda. A reflectância é o processo pela qual a radiação “resvala” num objeto como o topo de uma nuvem, um corpo d’água, ou um solo exposto (JENSEN, 2009).

A reflectância espectral pode ser medida a grandes distâncias usando sistemas multiespectrais de sensoriamento remoto. Existem vários fatores que podem influenciar nas medidas de reflectância, como a relação entre a energia incidente e o ângulo de visada do sensor, os efeitos atmosféricos e as propriedades físicas dos alvos (JENSEN, 2009).

A figura 17, mostra as curvas de reflectância espectral para fenômenos urbano-periurbanos utilizando um espectroradiômetro para fazer as medidas, e construiu curvas de reflectância para os principais alvos urbanos.

Como pode ser visto, a curva de reflectância em ambientes urbano-periurbano apresentam uma grande diversidade de alvos, constituídos de vegetação, asfalto, concreto, solo, água e telhados de diversos materiais, formando uma paisagem heterogênea.




FIGURA 17: Curvas de Reflectância dos materiais característicos dos ambientes urbanos.
Fonte: Jensen 2009.

4. METODOLOGIA

Este trabalho foi desenvolvido com base no Processamento Digital de Imagem, aplicando os algoritmos de segmentação da imagem em objetos, com posterior classificação orientada a objeto, comparando os resultados com a classificação Maxver (*pixel a pixel*) a partir da imagem do satélite *Rapideye*. A análise e interpretação desta imagem foram feitas considerando as amostras de treinamento coletadas em campo por meio de fotografias registradas por GPS.

Para atingir os objetivos propostos será realizada a seguinte sequência metodológica:

- Classificação supervisionada da imagem pelo método da Máxima Verossimilhança (*pixel a pixel*);
- Segmentação da imagem em Objetos;
- Classificações dos Objetos utilizando algoritmo baseado em critérios limiares;
- Avaliação e comparação dos resultados obtidos das Classificações, utilizando a estatística *Kappa*;

4.1 FLUXOGRAMA DE TRABALHO

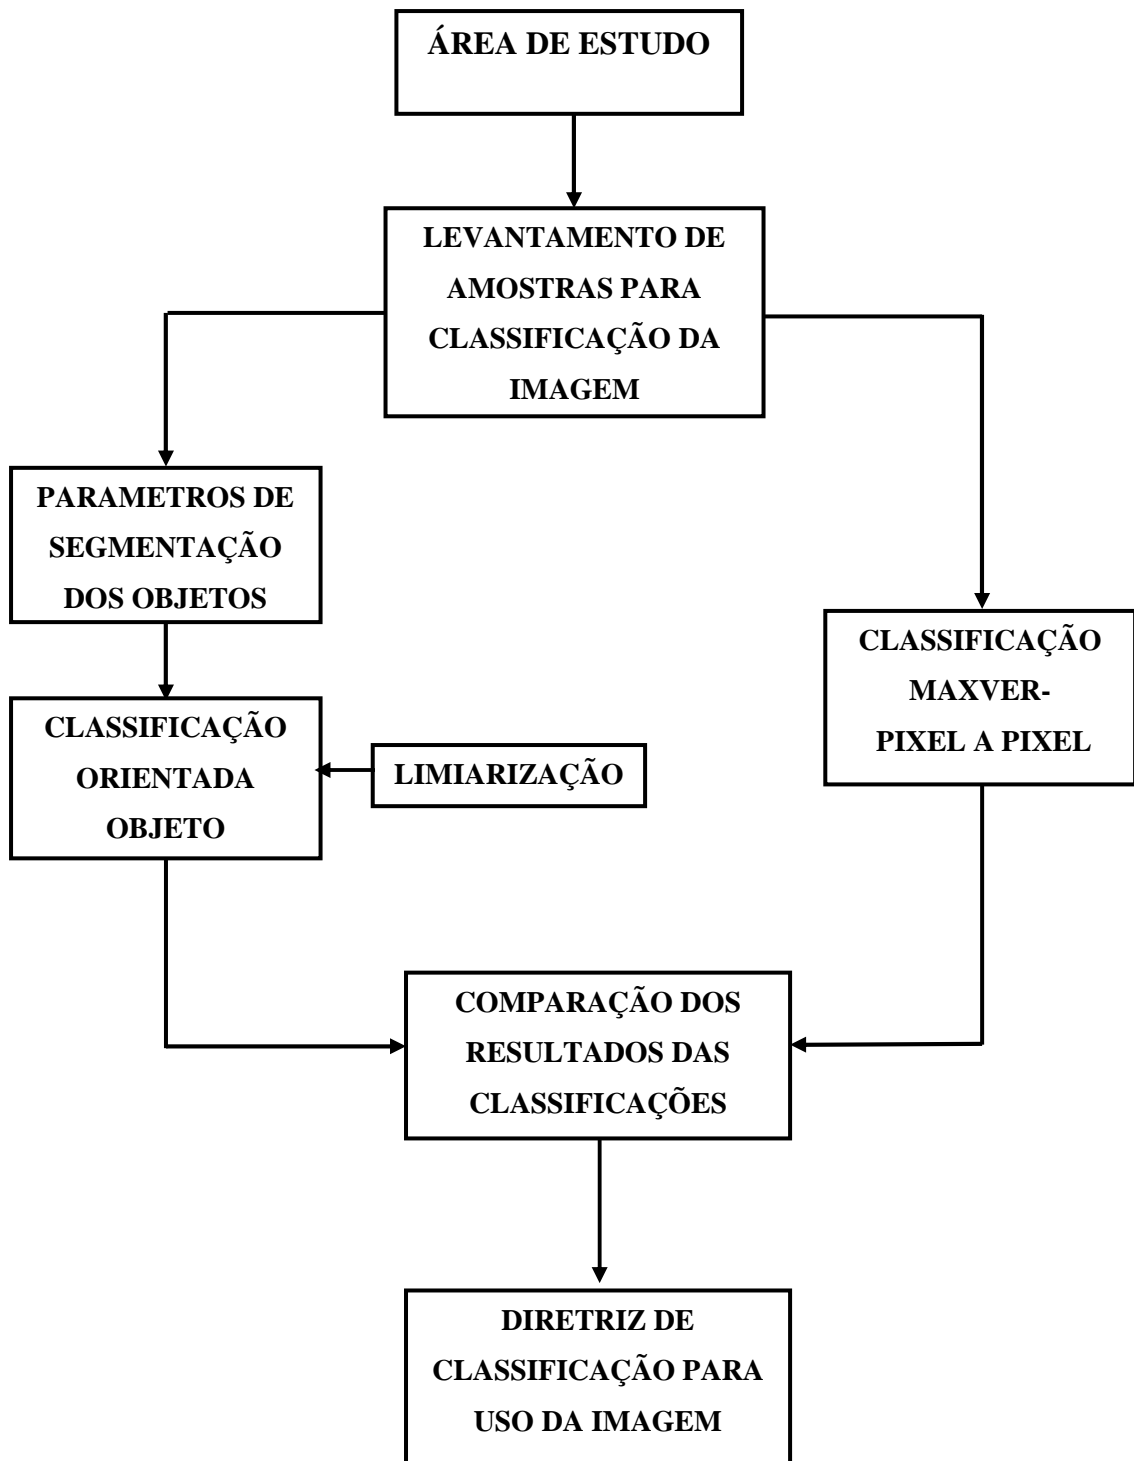


FIGURA 18: Fluxograma demonstrativo das Etapas de Trabalho

4.2 CLASSIFICAÇÃO MÁXIMA VEROSSIMILHANÇA – *PIXEL A PIXEL*

A metodologia utilizada nesta etapa foi a classificação supervisionada, sendo que o processo tradicional inicia-se com a seleção de amostras de treinamento que representam locais no terreno relativo a cada classe, para em seguida ocorrer a extração das estatísticas das amostras, as classes utilizadas estão descritas conforme Tabela 02.

TABELA 02: Classes Utilizadas

Classes	Número de Pixels das Amostras
Telhado (Cerâmica)	86
Solo Exposto	253
Subestação	79
Afloramento rochoso	145
Urbano (Concreto)	144
Pastagem	256
Área Lavras	581
Lago	39
Vegetação Arbustiva	256
Cultura	402
Vegetação Arbórea	398
Asfalto	119

As classes utilizadas foram as existentes no uso e ocupação do solo da região e que eram possíveis de identificação no trabalho de campo de forma que se pudesse testar a potencialidade do classificador Maxver para discriminação do maior número de classes possíveis utilizando o detalhamento da imagem *Rapideye*.

Algumas classes devido ao fato de não ser possível discriminação maior pela limitação da imagem foram representadas em conjunto como outras classes, como:

- Urbana: residencial, comercial, industrial que possuam materiais feitos de concreto.
- Cultura: lavouras e agricultura mecanizada, como cultura perenes e culturas cíclicas.
- Pastagem: pasto de gramíneas, pasto misto e gramíneas;
- Vegetação Arbustiva: pasto de arbustos (capoeira), Pasto misto e vegetação arbustiva.

Depois de selecionadas as amostras, foram analisados os gráficos das características das assinaturas espectrais conforme as figuras 19 e 20.




FIGURA 19: Comportamento da assinatura espectral das amostras

Observa-se no gráfico da figura 19 que as classes de telhado de cerâmica e solo exposto apresentaram características espectrais muito semelhantes, desta forma sendo agrupadas na mesma classe de categoria, o mesmo ocorrendo com afloramento rochoso e área urbana (concreto).

No gráfico da figura 20, mostra a classe de cultura com altos valores de radiância nas bandas as bandas RedEdge e Infravermelho-Próximo, que são os canais 4 e 5 no gráfico.

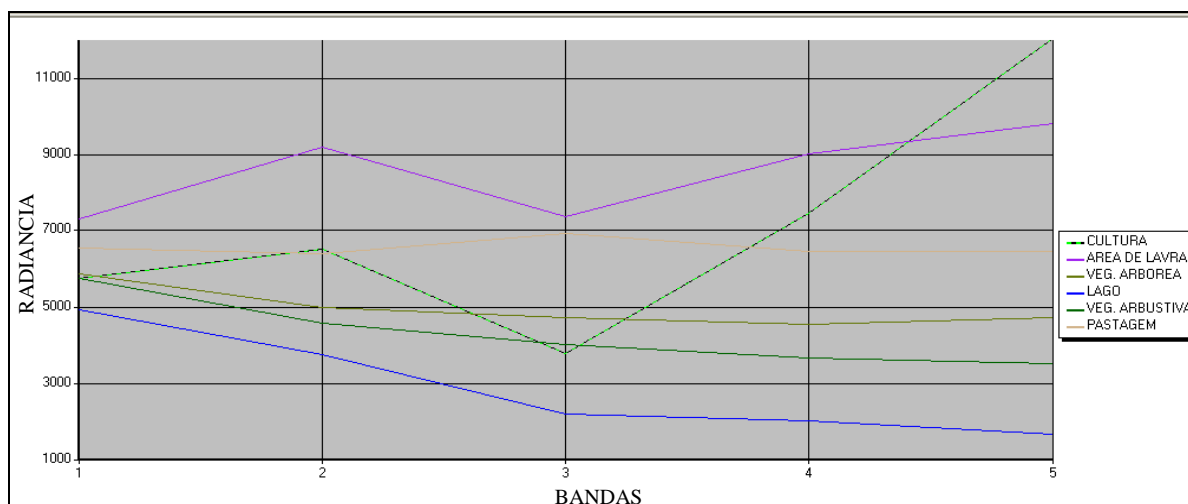


FIGURA 20: Comportamento da assinatura espectral das amostras

4.3 SEGMENTAÇÃO DA IMAGEM EM OBJETO

Conforme descrito no item 3.1.2 e utilizando-se da técnica de segmentação de multi-resolução e da hierarquia de segmentos, foram realizados vários testes de segmentação dos objetos, até adotar-se o que melhor representava e delineava os objetos de interesse.

Deste modo, foram testados valores para os parâmetros de escala variando entre 20 e 200, que geraram 6 níveis diferentes. No nível 1 com o parâmetro de escala 20 apresentou-se uma segmentação mais detalhada entre os objetos, nos níveis 2 e 3 com parâmetros de escala entre 40 a 80 apresentou-se objetos intermediários e a partir do nível 5 com parâmetro de superior a 100, os objetos apresentaram-se com uma estrutura mais grosseira (generalização dos objetos) que podem ser visualizados na figura 21.

Nos critérios de pesos para a semelhança (cor e forma) adotou-se o mesmo peso, pois o objetivo não era salientar alvos específicos, mas segmentar a imagem para um delineamento geral dos objetos. Os demais parâmetros (critérios de semelhança) adotou-se o padrão *default* do programa. O resumo dos pesos utilizados está apresentado na Tabela 03.

TABELA 03: Parâmetros utilizados no Processo de Segmentação dos Objetos da Imagem

NÍVEL	PARÂMETRO DE ESCALA	CRITÉRIO DE SEMELHANÇA	
		CRITÉRIO DA COR	CRITÉRIO DA FORMA
1	20	0,1	0,5
2	40	0,1	0,5
3	60	0,1	0,5
4	80	0,1	0,5
5	120	0,1	0,5
6	200	0,1	0,5

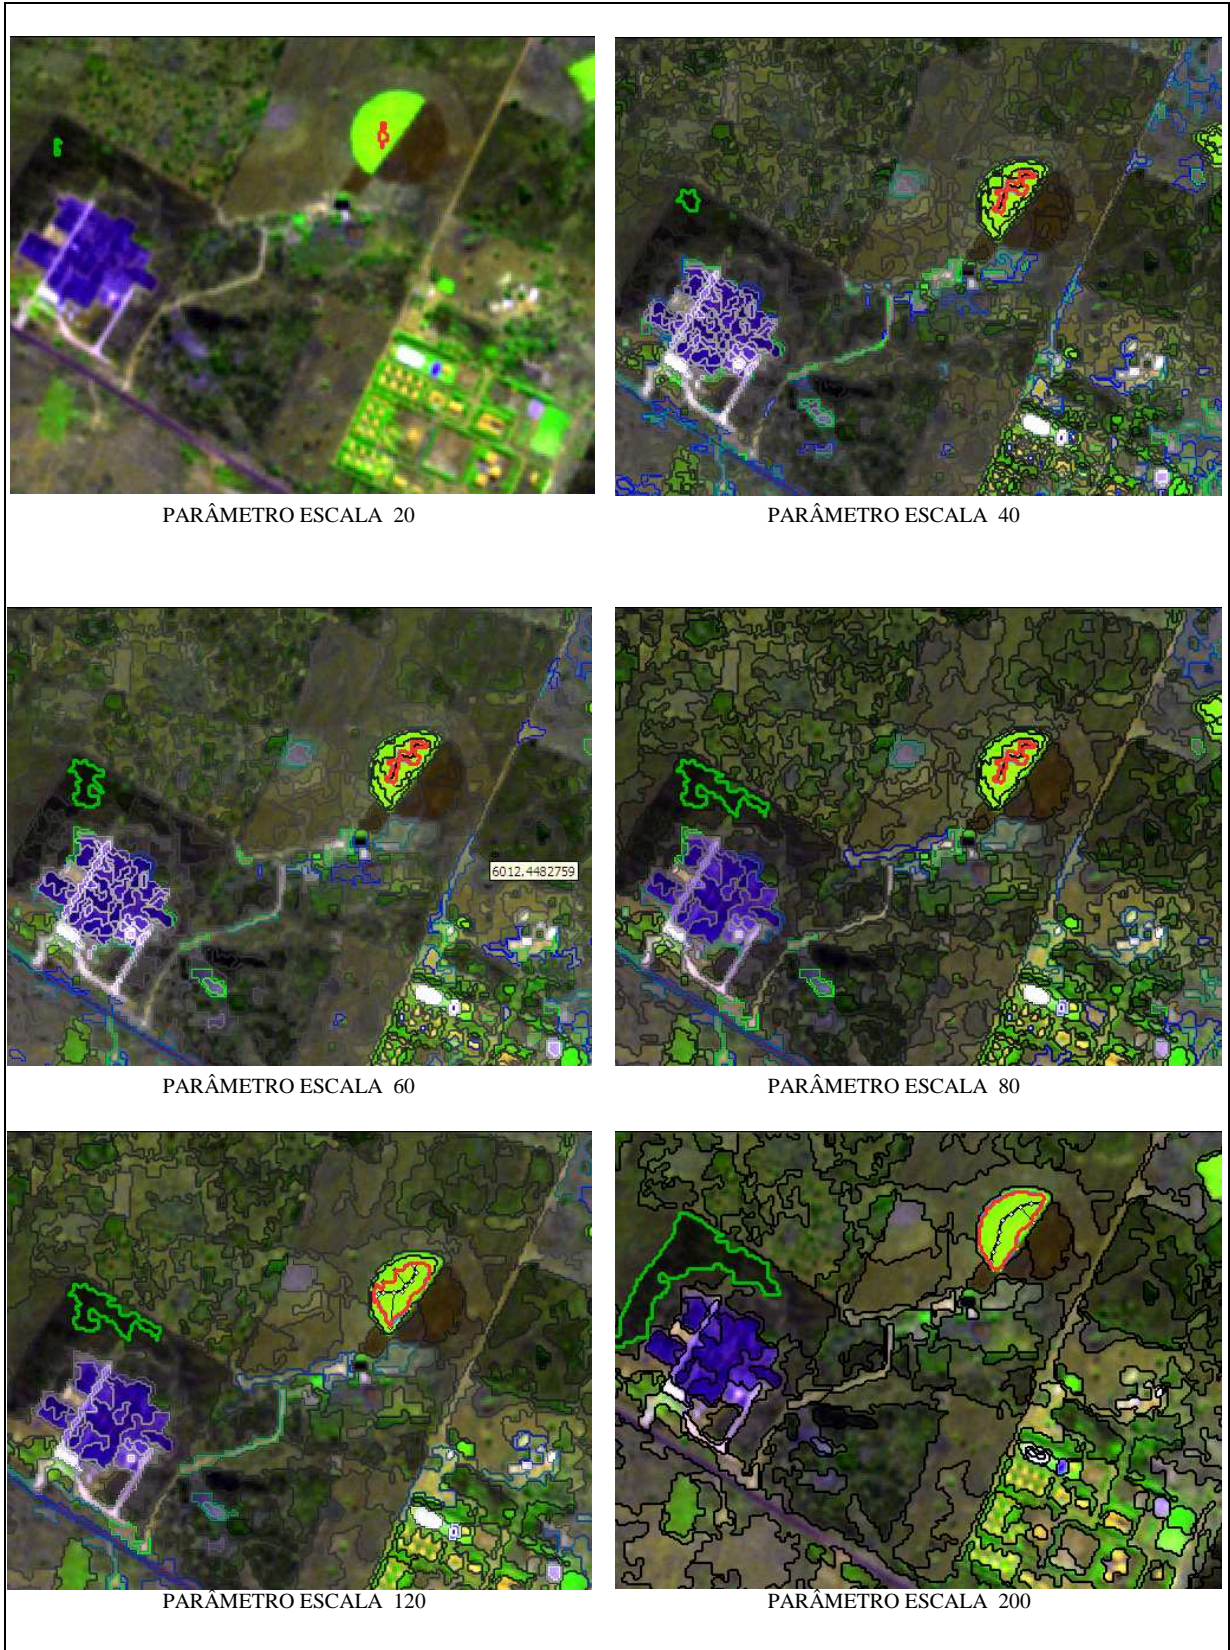


FIGURA 21: Hierarquia da imagem segmentada em várias escalas

4.4 ANÁLISE ORIENTADA A OBJETO

Na análise orientada a objetos o primeiro passo é a escolha da imagem segmentada que melhor represente os objetos de interesse, para posteriormente iniciar a classificação da imagem.

Neste caso, com segmentação de fator de escala 40 foi possível uma melhor discriminação entre as classes, que permitiu um bom delineamento visual das classes de interesse para o uso e cobertura do solo característico da região.

4.4.1 Classificação dos Segmentos

Para realizar a separação inicial das classes foi determinado um limiar de separação entre ambigüidades existentes. O limiar de separação utilizou como descritor à característica baseada no parâmetro das médias, que é calculado pela intensidade média dos objetos da vizinhança, e esta característica pode ser atribuída para uma ou mais bandas da imagem, podendo aplicar esse recurso a somente uma classe ou a todas as classes, definindo desse modo a classificação que melhor apresente discriminação entre as classes de interesse, conforme representado na figura 22.

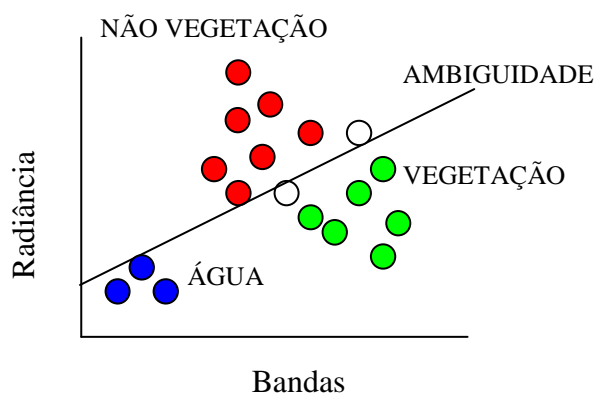


FIGURA 22: Limiarização das Classes

4.4.2 Classificação Hierárquica das classes

De acordo com o item 3.2.3 descrito neste trabalho, foi realizada a classificação hierárquica de forma que foi dividida em três grandes superclasses distintas, denominadas de classes mãe. As classes foram as seguintes:

- Vegetação (Pastagem, Cultura, Vegetação Arbórea, Vegetação Arbustiva);
- Não vegetação (Afloramento Rochoso, Solo Exposto, Urbano, Asfalto, Lavras);
- Corpos d'água (Lago).

Posteriormente foram se formando as subdivisões em outras classes.

4.4.3 Classificador de Limiarização dos Segmentos

Utilizando-se o algoritmo de limiarização, descrito no item 3.1.3.2, foi realizado os limiares de separação através da modificação do descritor do parâmetro das médias com as ferramentas do programa *ecognition*. Para obter as classes foram observados visualmente os melhores parâmetros de separação e utilizou-se como base as características das assinaturas espectrais. Os parâmetros de divisão do espectro foram:

- Vegetação - Banda 1 com limiarização de objetos entre os valores 5000 a 7200;
- Água - Banda 1 com objetos de valores inferiores a 5000.
- Não Vegetação - Banda 1: Demais objetos superiores a 7200.




FIGURA 23: Divisão do Espectro com a Limiarização dos objetos

A figura 24 representa a classificação das classes vegetação, água e não vegetação utilizando as limiarizações descritas anteriormente.




FIGURA 24: Resultado da Imagem inicial classificada hierarquicamente

O procedimento seguinte foi classificar as demais classes dentro da classe mãe vegetação, utilizando a limiarização das Banda 4 (RedEdge) e Banda 5 (I.V Proximo). As classes separadas foram as seguintes:

- Cultura – Banda 5 entre 8200 e 16500;
- Vegetação Arbórea – Banda 5 entre 2170 e 4700;
- Vegetação Arbustiva – Banda 4 entre 3800 a 5200;
- Pastagem – Todos os objetos que não foram enquadradas na classificação anterior.

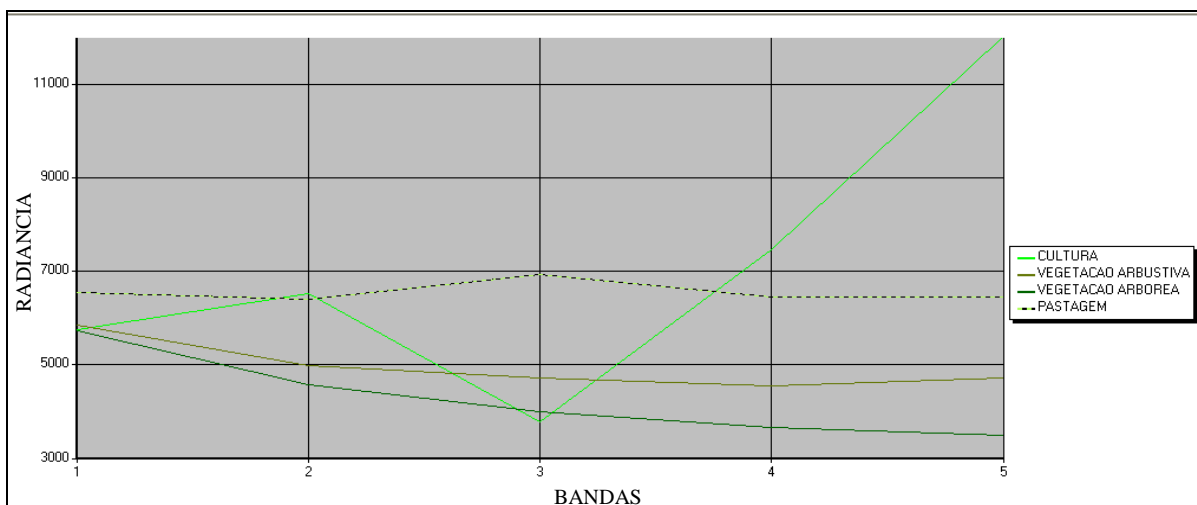


FIGURA 25: Espectro da Limiarização da Vegetação

A figura 26 representa a classificação das classes vegetação utilizando as limiarizações descritas anteriormente.




FIGURA 26: Classe de Limiarização da Vegetação

O procedimento seguinte foi classificar as classe dentro da classe mãe não vegetação, para isso utilizou-se as seguintes limiarizações:

- Afloramento Rochosos / Urbano - Banda 1 > 7000;
- Asfalto / Subestação - Banda 5 < 5600;
- Telhado Cerâmica/Solo Exposto - Banda 3 de 9700 a 12000;
- Área de Lavras -Banda 4 de 9200 a 8800.

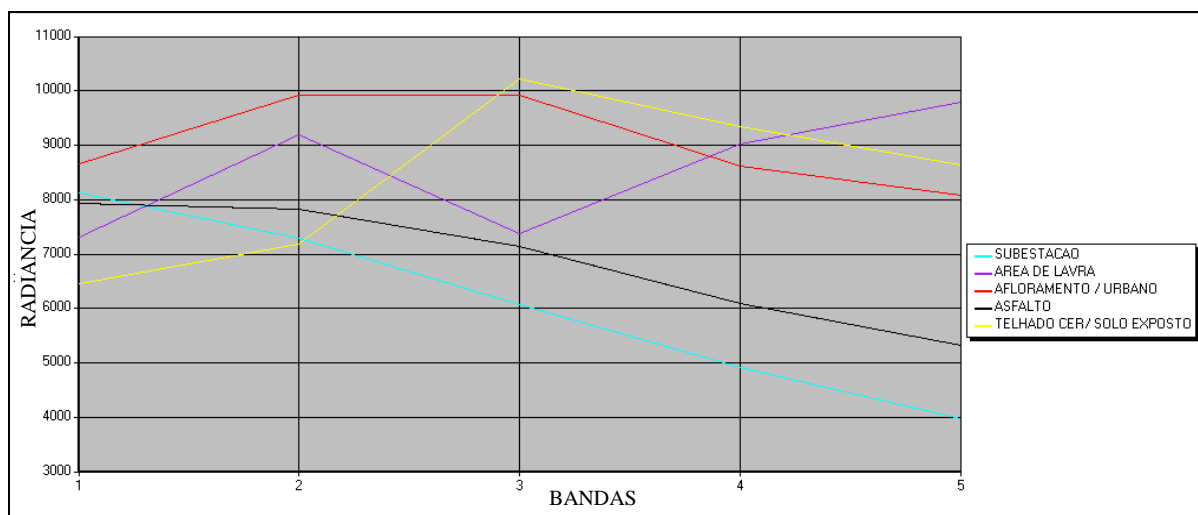


FIGURA 27: Espectro da Limiarização da não Vegetação

Observa-se que a classe lavras estava bem confusa com as demais classes sendo realizada uma nova classificação dentro da classe urbano/afloramento. A classe subestação foi também agrupada com asfalto, devido a apresentar características muito próximas.