

# UERJ

Dissertação de Mestrado em Geomática

**EXTRAÇÃO AUTOMÁTICA DE FEIÇÕES RELATIVAS A  
COBERTURA VEGETAL E USO DA TERRA A PARTIR DE  
FOTOGRAFIAS AÉREAS**

Autor: João Paulo Carvalho Raivel

Orientador: Prof. Jorge Luís Nunes e Silva Brito, Ph.D.

Co-orientador: Prof. Raul Queiroz Feitosa, Dr.Ing.

Programa de Pós – Graduação em Engenharia da Computação

Área de concentração: Geomática

Abril / 2005

Faculdade de Engenharia



**EXTRAÇÃO AUTOMÁTICA DE FEIÇÕES RELATIVAS A  
COBERTURA VEGETAL E USO DA TERRA A PARTIR DE  
FOTOGRAFIAS AÉREAS**

**João Paulo Carvalho Raivel**

Dissertação submetida ao corpo docente da Faculdade de Engenharia da Universidade do Estado do Rio de Janeiro – UERJ, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia da Computação.

Orientador: Prof. Jorge Luís Nunes e Silva Brito, Ph.D.

Co-orientador: Prof. Raul Queiroz Feitosa, Dr.Ing.

Programa de Pós – Graduação em Engenharia da Computação  
Área de concentração Geomática

Rio de Janeiro, 2005

RAIVEL, JOÃO PAULO CARVALHO

Extração Automática de Feições Relativas  
a Cobertura Vegetal e Uso da Terra a Partir  
de Fotografias Aéreas [Rio de Janeiro] 2005.

xi 83p. 29,7 cm (FEN/UERJ, M.Sc.  
Programa de Pós-Graduação em Engenharia  
da Computação – Área de Concentração  
Geomática, 2005)

Dissertação – Universidade do Estado do  
Rio de Janeiro – UERJ

1. Extração Automática de Feições, 2 –  
Segmentação, 3 – Uso do Solo, 4 –  
Cobertura Vegetal.

I. FEN/UERJ II. Título (série)

## **FOLHA DE JULGAMENTO**

**Título: EXTRAÇÃO AUTOMÁTICA DE FEIÇÕES RELATIVAS A  
COBERTURA VEGETAL E USO DA TERRA A PARTIR DE  
FOTOGRAFIAS AÉREAS**

Candidato: João Paulo Carvalho Raivel

Programa de Pós-Graduação em Engenharia da Computação

Área de Concentração: Geomática

Data da Defesa: 27 de Abril de 2005

Aprovada por:

---

Orientador: Prof. Jorge Luís Nunes e Silva Brito – Ph.D./UERJ

---

Co-orientador: Prof. Raul Queiroz Feitosa – Dr.Ing./UERJ e PUC

---

Prof. João Araujo Ribeiro – Dr./UERJ

---

Prof. Oscar Ricardo Vergara – D.C./IME

## Prefácio

*“A regionalização do espaço geográfico, a partir de um quadro de referências que evidencie os padrões espaciais decorrentes da apropriação da natureza aos processos de construção social, tornou-se o principal objetivo de um conjunto significativo de políticas públicas, disciplinadoras das ações empreendidas, ou a serem empreendidas, por agentes públicos e privados que, de uma forma, ou de outra, transformem o ambiente natural. O zoneamento ambiental, enquanto um processo de regionalização, exigirá a realização de mapeamentos capazes de sumariar os arranjos naturais e sociais que respondem pelas intervenções da sociedade no meio físico, expondo resistências e fragilidades que deverão ser adequadamente tratadas nos processos de gestão do território”.*

*Nessa senda, o zoneamento do ambiente natural refletirá as funções associadas aos padrões espaciais e, em decorrência, permitirá a consolidação das análises identificadoras de vocações e fragilidades do ambiente. Uma alternativa metodológica para a condução dos estudos demandados na realização do zoneamento, sugere a consideração dos padrões espaciais da **cobertura vegetal e do uso da terra**, reconhecidos a partir da cartografia dos arranjos espaciais que delineiam. A proposta se concretizará na definição de uma estrutura conceitual articulada para os dois temas, a ser sumariada em opções de legendas para a cobertura vegetal e o uso da terra, explicitadas por faixas de escalas geométricas a que se associe a escala de análise: local, regional imediata e regional mediata.*

*A busca de alternativas metodológicas e a construção de um patamar conceitual em que se possa assentar a reflexão sobre o conteúdo mínimo para os estudos ambientais, associados aos empreendimentos de médio e grande porte, justificam a elaboração da presente avaliação, marcada pela utilização da linguagem cartográfica no sumariar o inventário de dados e na apresentação dos resultados das análises sócio-ambientais...”*

Texto extraído do trabalho “PREMISSAS METODOLÓGICAS PARA A ELABORAÇÃO DE LEGENDAS NO MAPEAMENTO DA COBERTURA VEGETAL E DO USO DA TERRA” confeccionado pelo Sr. Mauro Pereira de Mello, Engenheiro Cartógrafo, MSc Ciências Geodésicas, Prof. da Universidade do Estado do Rio de Janeiro (UERJ), da Escola Nacional de Ciências Estatísticas (ENCE) e Consultor da Companhia Vale do Rio Doce (CVRD) para o texto em questão

Dedico esse trabalho ao meu pai (João Baptista de Souza Raivel) que apesar de não ter podido acompanhar minha formação acadêmica, sempre me forneceu toda luz, energia e apoio, de um lugar muito melhor....

## Agradecimentos

Ao iniciar essa jornada de pesquisas e estudos, certas pessoas foram fundamentais para a conclusão deste trabalho. Todos, sem nenhuma exceção, foram importantes para mim.

Agradeço a DEUS, por sua presença em todos os momentos da minha vida e nos momentos difíceis por seu conforto.

Aos meus pais, pela minha formação e pela eterna confiança depositada em mim.

A minha companheira, Flávia, pela compreensão por minhas ausências.

Aos Professores Mauro Pereira de Mello e Ivan de Araújo Medina por sua amizade e apoio nos momentos mais difíceis desta jornada.

A Antonio Machado e Silva que me apoiou em primeiro lugar no início desta jornada.

Aos orientadores, Prof. Jorge Luís Nunes e Silva Brito e Prof. Raul Queiroz Feitosa, pelo compartilhamento de seus conhecimentos e experiências.

Aos demais professores do programa de pós-graduação em Geomática, pela complementação de nossa formação acadêmica.

Aos demais funcionários do programa de pós-graduação em Geomática, em especial a minha amiga Elizabeth, por todos os “galhos” quebrados.

A GISPLAN por ter me dado total suporte para a conclusão dos créditos deste programa em paralelo a minhas responsabilidades junto à mesma.

A CVRD por ter incentivado minha continuação neste programa e pela cessão de todo o material utilizado ao longo deste projeto.

Obrigado a todos.

Resumo da Dissertação apresentada à FEN/UERJ como parte dos requisitos necessários para  
obtenção do grau de Mestre (M.E.) em Engenharia de Computação  
Área de Concentração Geomática

**EXTRAÇÃO AUTOMÁTICA DE FEIÇÕES RELATIVAS A  
COBERTURA VEGETAL E USO DA TERRA A PARTIR DE  
FOTOGRAFIAS AÉREAS**

**Autor: João Paulo Carvalho Raivel**

Abril/2005

Orientador: Prof. Jorge Luís Nunes e Silva Brito, Ph.D.

Co-orientador: Prof. Raul Queiroz Feitosa, Dr.Ing.

Programa de Pós – Graduação em Engenharia da Computação  
Área de Concentração Geomática

Este trabalho tem como objetivo avaliar, do ponto de vista do processo produtivo cartográfico, a viabilidade na utilização de técnicas e métodos de extração automática de feições, com enfoque nos temas relativos à cobertura vegetal e ao uso e ocupação do solo, no apoio à construção de bases de dados cartográficas em suporte as atividades de licenciamento ambiental.

Abstract of Dissertation presented to FEN/UERJ as a partial fulfillment of the requirements  
for the degree of Master of Engineering (M.E.)  
Field of Geomatics

**AUTOMATIC FEATURE EXTRACTION OF VEGETAL COVERAGE  
AND LAND USE FROM AERIAL PHOTOS**

**Author: João Paulo Carvalho Raivel**

April/2005

Advisors: Prof. Jorge Luís Nunes e Silva Brito, Ph.D.  
Prof. Raul Queiroz Feitosa, Dr.Ing.

Program of Pos-Graduation in Computer Engineering  
Field of Geomatics

This work intends to evaluate, based upon a cartographic production process environment, the feasibility of using automatic feature extraction techniques and methods. These techniques focus land use and vegetation coverage themes. These themes are critical for the construction of cartographic geodatabases that can support environmental licensing activities.

## SUMÁRIO

CAPÍTULO 1 – INTRODUÇÃO .....	01
1.1. Considerações Iniciais .....	01
1.2. Caracterização do Problema .....	03
1.3. Objetivo .....	06
1.4. Estrutura da Dissertação .....	07
CAPÍTULO 2 – A EXTRAÇÃO AUTOMÁTICA DE FEIÇÕES .....	09
2.1. Considerações Iniciais .....	09
2.2. Fases da EAFC .....	11
2.2.1. Pré-Processamento de Imagens .....	13
2.2.2. Segmentação de Imagens .....	16
2.2.3. Interpretação e Rotulagem dos Dados .....	24
CAPÍTULO 3 – A EAFC E OS PLANOS DE INFORMAÇÃO CARTOGRÁFICOS.....	26
3.1. Dos Planos de Informação Cartográfica .....	27
3.2. Dos Softwares, Programas e Algoritmos de EACF .....	32
CAPÍTULO 4 – METODOLOGIA E TESTES OPERACIONAIS .....	37
4.1. Área Selecionada .....	37
4.2. Materiais Disponíveis.....	38
4.3. Classes e Legendas Utilizadas.....	41
4.4. Metodologia .....	41
4.4.1. Metodologia – E-Cognition .....	42
4.4.2. Metodologia – Erdas Imagine .....	43
4.4.3. Diferenças e Similaridades – E-Cognition Vs. Erdas Imagine .....	45
4.4.3.1.Segmentação .....	45
4.4.3.2.Classificação .....	48
CAPÍTULO 5 – ANÁLISE DOS RESULTADOS .....	51
5.1. Resultados Alcançados – E-Cognition .....	51
5.2. Resultados Alcançados – Erdas Imagine .....	60
5.3. Análise Relativa - E-Cognition Vs. Erdas Imagine .....	63
5.4. Resultados Finais – EAFC Vs. Processo Convencional .....	65

CAPÍTULO 6– CONCLUSÕES E SUGESTÕES .....	68
6.1. A Resolução das Imagens Digitais .....	68
6.2. A Segmentação de Imagens Digitais .....	68
6.3. A Classificação das Imagens Digitais .....	69
6.4. A EAFC e o Processo de Produção Cartográfica .....	70
6.5. Sugestões para Trabalhos Futuros .....	71
REFERÊNCIAS BIBLIOGRÁFICAS .....	74

## ÍNDICE DAS FIGURAS

Figura 1 – Esquema Conceitual de um Sistema de EAFC .....	11
Figura 2 – Extração Automática de Pontos .....	19
Figura 3 – Exemplo de Gabaritos Deformáveis .....	21
Figura 4 – Exemplo de Sementes .....	22
Figura 5 – Exemplo de Crescimento de Regiões .....	23
Figura 6 – Participação das pesquisas em EAFC segundo a dimensionalidade .....	28
Figura 7 – Participação das Pesquisas em EAFC Segundo o Objeto de Extração .....	29
Figura 8 – Participação das Pesquisas em EAFC - Cobertura Vegetal e Uso do Solo .....	30
Figura 9 – Participação das pesquisas em EAFC segundo o patrocínio .....	34
Figura 10 – Croqui de Localização do Projeto FERROVIAS .....	37
Figura 11 – Croqui Detalhado de Localização - Trecho 04 .....	38
Figura 12 – Trecho 04 (em azul) – Faixas de Vôo (em Preto) .....	39
Figura 13 – Ortofotomosaico do Trecho 04 .....	40
Figura 14 – Detalhe em Resolução Máxima do Ortofotomosaico .....	40
Figura 15 – Interpretação Temática sobre o Ortofotomosaico do Trecho 04 .....	40
Figura 16 – Detalhe da Interpretação Temática, em Resolução Máxima, sobre o Ortofotomosaico .....	40
Figura 17 – Extrato da Legenda completa – Projeto FERROVIAS .....	41
Figura 18 – Fluxograma de simulação de segmentação no Erdas Imagine .....	44
Figura 19 – Tabela de Atributos do nível de objeto – Multisegmentação .....	52
Figura 20 – Primeira Segmentação .....	53
Figura 21 – Segunda Segmentação .....	53

Figura 22 - Imagem segmentada a partir do parâmetro de escala 35 – Duas Visões	54
Figura 23 - Objetos da segmentação - Escala 35	55
Figura 24 - Imagem segmentada a partir do parâmetro de escala 100 – Duas Visões	55
Figura 25 - Objetos da segmentação - Escala 100	56
Figura 26 – Classificação inicial e final respectivamente – E-Cognition	57
Figura 27 – Tabela de relacionamento dos objetos – E-Cognition	60
Figura 28 – Tabela de relacionamento dos objetos – Erdas Imagine	60
Figura 29 – Classificação final no e-cognition e no Erdas Imagine respectivamente	61

## ÍNDICE DAS TABELAS

Tabela 1 – Principais Fontes de Distorções Geométricas em Imagens Digitais	14
Tabela 2 – Divisão dos Processos de Correção Geométrica	15
Tabela 3 – Operadores Básicos da Morfologia Matemática	24
Tabela 4 – A EAFC e os programas internacionais sistemáticos de mapeamento da Cobertura Vegetal e do Uso da Terra	31
Tabela 5 – Sumário dos Principais Sistemas de EAFC	32
Tabela 6 – Tabela de Classes Selecionadas	57
Tabela 7 – Resultado da Classificação no E-Cognition	58
Tabela 8 – Matriz de Confusão - E-Cognition	58
Tabela 9 – Resultado da Classificação no Erdas Imagine	62
Tabela 10 – Matriz de Confusão - Erdas Imagine	62
Tabela 11 – Comparação entre os resultados da Classificação – E-Cognition Vs. Erdas Imagine	63
Tabela 12 – Comparação das Matrizes de Confusão – E-Cognition Vs. Erdas Imagine	64
Tabela 13 – Novos Resultados da Classificação no E-Cognition – Área Total	64
Tabela 14 – Matriz de Confusão para a Área Total de Testes – E-Cognition	65
Tabela 15 – Comparação entre os resultados das Matrizes de Confusão	65
Tabela 16 – Quantitativo de esforços do Projeto FERROVIAS – Processo Convencional	66

## ÍNDICE DAS EQUAÇÕES

Equação 4.1. – Influência do Parâmetro de Escala na Segmentação .....	47
Equação 4.2. – Influência Conjunta dos Parâmetros de Cor e Forma na Segmentação	48
Equação 4.3. – Influência do Parâmetro de Cor na Segmentação .....	48
Equação 4.4. – Influência do Parâmetro de Forma na Segmentação .....	48
Equação 4.5. – Influência Indireta do Parâmetro de Suavidade na Segmentação .....	48
Equação 4.6. – Influência Indireta do Parâmetro de Compactação na Segmentação	48

# CAPÍTULO 1 – INTRODUÇÃO

## 1.1. Considerações Iniciais

Desde o início dos tempos o homem se preocupa em entender o espaço que o cerca. Aproximadamente em 240 Antes de Cristo (a.C.), Eratóstenes, então curador da biblioteca de Alexandria, fez a primeira estimativa da circunferência da Terra. Deste ponto, e através dos séculos, o homem tentou, de formas cada vez mais elaboradas, criar uma representação mais fidedigna da Terra e do Universo.

À medida que os séculos passavam o Homem aumentava seu conhecimento e entendimento dos fenômenos e do meio físico que o cercavam. Aumentava também a necessidade de representação dos mesmos a partir de forma simples e direta que pudesse ser entendida e compartilhada por todos; daí surgia a necessidade da representação dos dados e informações a partir de mapas. Com a consolidação do Mapa como forma de representação, a preocupação do Homem passou para a busca de processos que pudessem agilizar ou facilitar a produção da representação de fenômenos a partir de mapas.

A primeira grande descoberta que alavancou o processo produtivo de cartografia no mundo foi a descoberta da fotografia, efetivamente provada por Joseph Nicephone Niépce em 1837. Esta descoberta iniciou o processo de pesquisa para as duas principais áreas do conhecimento hoje utilizadas pela cartografia – A fotogrametria e o sensoriamento Remoto.

A fotogrametria, atribuída sua paternidade a Aimé Laussedat, foi a primeira técnica desenvolvida para o mapeamento de grandes áreas de forma precisa e rápida. Durante sua fase de maturidade a fotogrametria pôde ser dividida em 4 ciclos distintos:

1850 – 1900 – Fotogrametria Pioneira

1900 – 1960 – Fotogrametria Analógica

1960 – 1990 – Fotogrametria Analítica

1990 – Dias de Hoje – Fotogrametria Digital

Ao mesmo tempo em que a fotogrametria se desenvolvia, graças aos avanços tecnológicos experimentados em cada um dos quatro ciclos citados, desenvolvia-se também a necessidade de utilização de outras plataformas e sensores, que não os aviões e câmeras fotogramétricas, para o registro dos fenômenos físicos de interesse. Desta forma, com o lançamento em 1972 do ERTS-1 (*Earth Resources Technology Satellite*) posteriormente nomeado “*Landsat 1*”, o

Sensoriamento Remoto aparece no cenário científico como uma alternativa para a geração de mapeamentos de grandes áreas em curtos espaços de tempo.

Devido a uma dicotomia informal entre a fotogrametria e o sensoriamento remoto, durante algum tempo estas duas áreas do conhecimento foram tratadas como áreas distintas. Isto talvez se explique pela baixa resolução geométrica alcançada pelos sensores orbitais no início de seu desenvolvimento e a conseqüente dificuldade de utilização de suas imagens em mapeamentos em grandes escalas. Entretanto, com o atual estágio dos chamados satélites imageadores sub-métricos, capazes de produzir imagens digitais com resoluções espaciais menores que 1 (um) metro, o processo para o tratamento e processamento de imagens digitais se assemelha aos processos desenvolvidos para a fotogrametria.

Atualmente a tendência para o entendimento desta questão é que a fotogrametria esteja, com o advento da fotogrametria digital e com a semelhança técnica das deformações métricas - provocadas pela constante diminuição da órbita destes satélites e os efeitos atmosféricos inerentes a esta diminuição - entre fotos aéreas e imagens orbitais, inserida no contexto global do sensoriamento remoto.

Com a consolidação do entendimento da Terra em seu contexto métrico e geométrico (Geodésia) e com o aprimoramento das técnicas para a representação dos fenômenos físicos de maneira ampla e rápida, com a introdução da fotogrametria e do sensoriamento remoto, o Homem pôde então se dedicar a um sonho antigo, desde os primeiros “mapas” escritos em pedra até os dias atuais, qual seja à implementação de uma “Máquina de Mapeamento Automático”.

O termo “Máquina de Mapeamento Automático”, apesar de não ser um termo consagrado, reflete os anseios da comunidade científica para o momento. Depois de todos os avanços experimentados, na fase inicial do processo cartográfico, ou seja, na aquisição do dado, como agora desenvolver processos que possam automatizar a produção da informação e sua representação a partir de mapas?

Visando responder a esta pergunta um recente campo de pesquisa surge no cenário mundial, o campo da extração automática de feições (EAFC). O campo da EAFC, apesar do seu fascínio e atração ocasionado pela heterogeneidade de suas áreas de pesquisa, tem se mostrado um campo árduo nos últimos 20 anos. As principais áreas de pesquisa envolvidas nesta heterogeneidade são a área de Sistemas de Computação, representada pelas áreas de processamento digital de imagem e inteligência computacional, onde se concentram os principais desenvolvimentos de algoritmos e metodologias voltadas à Representação Formal do Conhecimento e a área de Tecnologia da Geoinformação, representada especificamente na

área de sensoriamento remoto, pela utilização das técnicas fotogramétricas e de processamento digital de imagens.

Somando-se a isto a quantidade e complexidade de objetos a serem cartograficamente representados, a partir de variadas escalas de interesse e objetivos de representação, gera-se uma matriz de possibilidades difícil de para ser coberta em um ou mais trabalhos de pesquisa. Desta forma este trabalho visa apenas à caracterização e ao estudo de métodos e metodologias de EAFC aplicadas à extração de temas relativos à cobertura vegetal e uso do solo em suporte as atividades de gerenciamento e licenciamento ambiental, a partir do enfoque do processo produtivo cartográfico.

## 1.2. Caracterização do Problema

O inventário e o monitoramento das ações que traduzem as diferentes formas assumidas pelos processos que regem a apropriação dos elementos da natureza à construção social, passaram a ter maior significado com a evolução das tecnologias voltadas para a observação terrestre, o sensoriamento remoto, e daquelas destinadas ao tratamento computacional dos dados espaciais como os sistemas de informação geográfica e as soluções de computação gráfica aplicadas à produção cartográfica.

Na consolidação dos conhecimentos sobre o mundo que as envolvem, as sociedades humanas desenvolveram variadas formas de linguagem, tendo por principal motivação externar a percepção dos fatos e fenômenos que caracterizam o permanente embate entre a natureza e a sociedade. Notadamente reconhecem-se, para a expressão dos fatos naturais e sociais que caracterizam o espaço geográfico, as linguagens: literária, representada pelos textos descritivos e analíticos que resumiam os inventários e as análises; a matemática, mormente a de expressão estatística, tabular, a que se recorre na consolidação dos recenseios e a cartográfica, linguagem gráfica que se materializa nos mapas, cartas, perfis e diagramas tridimensionais que expressam as propriedades dos diferentes objetos geográficos e suas relações espaciais.

A partir da popularização das tecnologias cartográficas e de sensoriamento remoto, se mostra inquestionável o fato de se observar sensível melhoria na conscientização e no despertar da responsabilidade para com a gestão do ambiente físico. Por outro lado, os estados nacionais passaram a regular e a fiscalizar todo e qualquer empreendimento que transforme ou tenha potencial transformador da natureza, embora nem sempre a regulação dos processos de permissão e licenciamento desses empreendimentos se mostre clara.

No Brasil, apesar da existência de um denso conjunto de dispositivos jurídicos, essa regulação se faz ausente enquanto norma técnica básica, universal, restringindo-se às orientações caso-a-caso, por parte da agência governamental detentora das prerrogativas reguladoras, o Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis – IBAMA. Embora possa ser justificada pela natureza particular de cada empreendimento, essa posição gera grande desperdício de conhecimentos e recursos, na medida em que impede a sistematização dos dados em escala regional e nacional.

Os esforços para se dotar o país de uma visão objetiva dos recursos naturais tem como marco significativo a aprovação e implantação do Projeto RADAM ao final da década de sessenta, início da década de setenta, do século passado. À medida que se avançava no inventário dos recursos naturais, em escala nacional ou de reconhecimento, a partir da região amazônica para as demais regiões do território nacional, consolidava-se no país uma nova cultura, motivada fortemente pelas preocupações e movimentos internacionais que tinham por foco o ambiente físico – natural.

Em seu processo de organização a sociedade estrutura o espaço geográfico criando, destruindo e recriando formas de organização territorial. Interagindo com o conteúdo natural do território, a sociedade estabelece novos padrões de articulação com a natureza e promove a instrumentalização do território, dando concretude ao que se convencionou denominar de espaço geográfico, que nada mais é do que o território socialmente construído .

Da sinergia entre espaço, tempo e sociedade articulam-se os sistemas sociais e naturais, compondo as diversas formas de organização espacial, as funções por elas desempenhadas, a estrutura que as suportam e os processos de construção das mesmas.

Caracterizar o espaço geográfico, segundo suas componentes ambientais e sociais, constitui o requisito básico para a construção dos cenários de apoio à tomada de decisão, no âmbito das políticas voltadas para o ordenamento do território. Compreender o espaço geográfico se faz essencial para a definição dos cenários e a identificação das ações que possibilitem manter ou estabelecer as funções transformadoras do espaço, caracterizando os agentes responsáveis pelos processos de reestruturação de um particular segmento, identificando a dimensão temporal e a extensão dos eventos naturais e sociais envolvidos na análise .

Os estudos necessários à identificação das referidas áreas exigem uma abordagem epistemológica interdisciplinar e integrada, tomando-se por referência a “Teoria Geral dos Sistemas”, cujos princípios norteiam a base conceitual a ser adotada, considerado o ambiente como um sistema dinâmico e articulado, em consequência, toda modificação introduzida em qualquer variável refletir-se-á nas demais.

O entendimento da questão ambiental, vista de forma integrada como a resultante de relações internas das estruturas espaciais da sociedade e da natureza, se torna, portanto, essencial para a compreensão desses espaços. Sob essa ótica, ressalta-se a importância do trabalho interdisciplinar no trato das questões ambientais, caracterizando-se processos e formas de organização social do espaço geográfico que, ao se apropriarem dos bens ou recursos naturais, interferem e modificam a ecodinâmica.

Duas questões são essenciais para o desenvolvimento dos trabalhos. A primeira confunde-se com a escolha da escala de análise, com o decorrente comprometimento da escala cartográfica, para as descrições e sínteses espaciais temáticas implicadas no suporte às atividades de levantamento e coleta de dados, ou na apresentação dos resultados dos inventários e das análises. A outra, pertinente à delimitação da área de estudo.

A adoção de procedimentos cartográficos na apresentação dos elementos inventariados, ou no resumo dos resultados das análises, permite a essencial visão de conjunto para a compreensão dos arranjos espaciais que exprimem a organização e a hierarquia das unidades elementares em processos estruturadores dos sistemas ambientais. As formas de interação das componentes caracterizadoras da dinâmica ambiental estarão, em decorrência, refletidas pela representação cartográfica dos fixos e fluxos que conformam o espaço geográfico. As interações são reveladoras das adequações e confrontos dos dois subsistemas, o natural e o social.

Um dos aspectos de maior relevância para se conduzir as etapas anteriores encontra-se vinculado ao mapeamento por grupo disciplinar, considerando-se que do entrecruzamento e integração desses temas emergirão os padrões espaciais para o diagnóstico ambiental. As sínteses morfoestrutural e morfopedológica somente serão possíveis a partir da adequada integração disciplinar. **O mapeamento da cobertura vegetal e o mapeamento do uso da terra** desempenham o papel viabilizador das sínteses, na medida em que sumarizam as iterações entre as características naturais e sociais, modeladoras do espaço geográfico.

O inventário dos recursos naturais tratado inicialmente pelo Projeto RADAM a partir da década de setenta do século passado, marca o esforço para a sistematização do conhecimento acumulado nessa área. Hoje, embora não adequadamente consolidado, esse acervo constitui um marco para os trabalhos ambientais. A obra completa insere-se em 38 volumes, correspondendo cada um ao corte da folha da Carta Internacional do Mundo, na escala de 1:1.000.000, ou agrupamento de folhas, quando não inteiramente vinculadas ao território nacional. A carta de serviço na escala de 1:250.000, origem das folhas editadas ao milionésimo, corresponde à escala dos mosaicos formados pelas imagens coligidas por sensor

RADAR aerotransportado. Esse acervo tem servido de base para a compilação de grande número de estudos temáticos.

Dos esforços desenvolvidos pelas diferentes equipes temáticas do Projeto RADAM restaram, acessoriamente, as especificações técnicas seguidas nos levantamentos e mapeamentos conduzidos nas áreas de: geologia, pedologia, geomorfologia, vegetação, clima e uso da terra. As especificações, hoje revistas e consolidadas pelo IBGE, podem ser apreciadas na série de Manuais Técnicos de Geociências, na origem decorrentes do apostilamento normalizador das equipes técnicas do RADAM, a partir de 1987 integradas aos quadros de pessoal da Fundação.

### 1.3. Objetivo

Da interpretação do exposto no item anterior fica clara a necessidade de desenvolvimento de pesquisas que subsidiem de maneira consistente a geração de bases de dados relativas à cobertura vegetal e ao uso e ocupação da terra de maneira rápida, consistente e precisa. Da mesma forma, o mapeamento dos grupos disciplinares relativos à cobertura vegetal e ao mapeamento do uso da terra desempenham o papel viabilizador para o sucesso destes estudos.

Os estudos ambientais, primeiro passo para a etapa de licenciamento ambiental, tem sido baseados primeiramente na análise visual e na vetorização manual de imagens digitais para a geração destas bases. Estes processos tornam os resultados pontuais e muitas vezes repetitivos causando duplicidades nas bases de dados existentes.

Basicamente, as escalas para o mapeamento destes temas encontram-se padronizadas consoantes ao maior ou menor grau de minudenciamento exigido pelos procedimentos da análise, sendo recomendável, por essa linha, a utilização da faixa de escalas de 1:1.000.000 a 1:2.500.000 nos mapeamentos de síntese macrorregional ou nacional, os autores clássicos denominam aos mapeamentos nessa faixa de exploratórios. A faixa de 1:250.000 a 1:1.000.000 acaba reservada aos mapeamentos regionais também ditos de reconhecimento. A faixa seguinte compreende as escalas entre 1:100.000 e 1:25.000, as escalas médias da Cartografia Sistemática, reservadas aos mapeamentos mesorregionais e microrregionais, classicamente denominados por mapeamentos de semidetalhe. As escalas maiores de 1:25.000 ficam reservadas aos mapeamentos locais também ditos cadastrais, correspondendo ao maior grau de aproximação dos fatos de interesse para a investigação de uma questão específica, associada a uma área de pequenas dimensões territoriais.

Estas escalas indiretamente dividem e caracterizam o uso da tecnologia espacial para estes fins, partindo-se de imagens digitais de baixa resolução para as sínteses macrorregionais, imagens de média resolução e técnicas aerofotogramétricas para as sínteses mesorregionais e microrregionais e os satélites de alta resolução e técnicas fotogramétricas para as sínteses cadastrais. Notadamente é nas escalas grandes onde se concentram as maiores carências em termos tecnológicos para a correta manipulação e trabalho destes dois grupos disciplinares, dada a quantidade enorme de objetos possíveis de serem interpretados a partir do uso de dados de imagem com características métricas e sub-métricas.

A pesquisa por materiais e métodos que comprovadamente possam extrair, de maneira confiável em termos quantitativos e qualitativos, informações referentes a estes dois grupos disciplinares de forma automatizada torna-se indispensável para dotar o poder público de instrumentos que capacitem o mesmo a normatizar as atividades de estudo e licenciamento ambiental, bem como fiscalizá-las de forma eficaz e correta. Para os órgãos transformadores do espaço geográfico, sejam eles públicos ou privados, a tecnologia de EAFC proporciona um instrumento para a geração de bases de dados ambientais de forma rápida e aderente aos requisitos explicitados pelo órgão normatizador.

Este trabalho tem como objetivo avaliar, do ponto de vista do processo produtivo cartográfico, a viabilidade na utilização de técnicas e métodos de extração automática de feições, com enfoque nos temas relativos à cobertura vegetal e ao uso e ocupação do solo, no apoio à construção de bases de dados cartográficas em suporte às atividades de licenciamento ambiental.

#### 1.4. Estrutura da Dissertação

Esta dissertação está organizada em 6 (seis) capítulos, sendo este **primeiro capítulo**, a motivação, o objetivo e a justificativa do estudo ora proposto.

No **segundo capítulo** será explorada a conceituação do processo de EAFC, sua finalidade, suas implementações e principais áreas de suporte, bem como apresenta uma revisão bibliográfica buscando a síntese das opiniões acerca do tema proposto, bem como os comentários decorrentes dessa leitura;

O **terceiro capítulo** visa apresentar o relacionamento dos grupos disciplinares ou temas cartográficos com o processo de extração automática de feições (EAFC) da mesma forma que introduz uma coletânea reduzida das principais iniciativas, relativas ao processo de EAFC no mundo, para cada um destes temas, de maneira isolado ou em conjunto;

O **quarto capítulo** visa apresentar a metodologia a ser adotada para o alcance dos objetivos firmados no capítulo 1 deste trabalho apresentando de forma sucinta as ferramentas principais a serem empregadas nesta investigação;

O **quinto capítulo** coroa a apresentação os testes operacionais realizados a partir da metodologia proposta e organiza de forma sistemática os resultados destes testes para o processo de análise dos resultados alcançados buscando de forma prática situar as respostas obtidas a partir da fase de testes;

**A EAFC vale realmente a pena do ponto de vista do processo produtivo?** Esta será a resposta apresentada no capítulo final, **sexto capítulo**, desta dissertação. Mesmo sendo possível a confecção da chamada “Máquina de Mapeamento Automático” ela é viável em termos operacionais, produtivos e financeiros ou simplesmente é ainda um primeiro passo rumo a automatização total do processo produtivo cartográfico?

# CAPÍTULO 2 – A EXTRAÇÃO AUTOMÁTICA DE FEIÇÕES

## 2.1. Considerações Iniciais

Segundo Vosselman <sup>[94]</sup>, de todas as tarefas dentro da fotogrametria, a extração de feições cartográficas é a que mais consome tempo e recursos em termos computacionais e humanos. Desde a introdução da fotogrametria digital uma atenção especial foi dada ao desenvolvimento de ferramentas eficientes para a aquisição de feições cartográficas. McKeown Jr. complementa, em sua introdução ao capítulo 9 do “*Digital Photogrammetry - An Addendum to the Manual of Photogrammetry*”, colocando que a extração automática de feições cartográficas (EAFC) é um problema complexo cujo grau de dificuldade se torna maior na medida em que são ignoradas as informações métricas e geométricas disponíveis pelo uso da fotogrametria.

Cético também é Tommaselli <sup>[90,91,92]</sup> que coloca em sua publicação “Extração de Feições Cartográficas” que “...como os métodos totalmente automatizados ainda não geram resultados satisfatórios, quando aplicados a imagens reais, os métodos semi-automáticos para a extração de feições cartográficas, a partir de imagens aéreas, são soluções a serem investigadas...”.

Ainda Aggarwal <sup>[10]</sup>, consoante as opiniões acima, coloca um ponto interessante sobre o problema do reconhecimento de objetos citando que a dificuldade na obtenção de uma solução genérica para o problema do reconhecimento de objetos pode ser atribuída à complexidade no reconhecimento de objetos por si só, tendo em vista que o mesmo envolve processamentos em todos os níveis da visão computacional (*machine vision*) como também por outros fatores como a possibilidade de oclusão de objetos, a falta de uma estimativa da quantidade de objetos presentes na imagem, possibilidade de objetos desconhecidos aparecerem na imagem, objetos em movimento, entre outros.

Juntamente a Aggarwal, podem-se somar os conceitos apresentados por Mayer <sup>[61]</sup> e traçar um modelo mínimo para o entendimento do problema da EAFC a partir dos conceitos apresentados a seguir:

- Modelagem

A modelagem é um assunto chave para o desempenho de qualquer abordagem para a extração automática ou semi-automática de objetos. Basicamente a modelagem consiste no conhecimento sobre os objetos que se tem interesse em serem extraídos. Adicionalmente é

necessária a análise de suas relações espaciais e topológicas bem como o seu relacionamento com objetos adicionais que não necessariamente são objeto do processo de extração porém faz o papel de “pistas” no reconhecimento de um dado objeto.

- Representação do Conhecimento

Representar significa apresentar algo por meio de algo materialmente distinto de acordo com regras exatas, nas quais certas características ou estruturas daquilo representado devem ser expressas, acentuadas e tornadas compreensíveis pelo tipo de apresentação, enquanto outras devem ser conscientemente suprimidas.

**Epistemologia** (Também denominada de Teoria do Conhecimento – Gnoseologia) - Pode ser definida como a teoria dos princípios materiais do conhecimento humano, ou seja, os pressupostos materiais mais gerais do conhecimento científico. Pode ser definida, também, como a teoria do pensamento verdadeiro sobre os objetos do mundo fenomenal. Surge na Idade Moderna com John Locke;

**Nível Epistemológico** - especifica os objetos e suas relações. É o nível da estruturação. Ex: OO;

**Ontologia** - Especificação de uma conceptualização, ou seja, é uma abstração, uma visão simplificada do mundo que se representa para atingir um dado propósito, como por exemplo de ajudar pessoas a atingir um consenso no seu entendimento sobre uma área de conhecimento. O termo “ontologia” surgiu na transição da Idade Média para Moderna na escolástica e significa ciência do ser, quer dizer, do ente enquanto tal em geral. Analogamente as ontologias, na Ciência da Computação, são usadas com o intuito de desvendar o significado das coisas no mundo, procurando descrever a natureza das coisas;

**Nível Ontológico** – Possui o objetivo de restringir o número de possibilidades de interpretação do conceito dentro de um dado contexto, a partir de um formalismo que pretende representar o conteúdo do conceito através de definições axiomáticas;

- Nível de Sistema

Segundo Schenk <sup>[9]</sup> o nível de sistema é caracterizado pelas atividades de manipulação de dados de imagens digitais como: Armazenamento, Acesso e Visualização de Imagens.

- Nível Inicial (Lower-Level Vision)

O nível inicial ou nível baixo de visão computacional é o nível responsável pelo pré-processamento das imagens digitais. Contempla as atividades de correção radiométrica, atmosférica e geométrica de dados de imagens de sensoriamento remoto.

- Nível Intemediário (Mid-Level Vision)

O nível intermediário ou nível médio de visão computacional é o nível responsável pelas atividades de agrupamento e segmentação de imagens bem como a representação e descrição dos padrões de forma e a extração de feições.

- Nível Avançado (High-Level Vision)

O nível avançado ou nível alto de visão computacional é o nível responsável pelas atividades de designação de padrões de categoria, normalmente fundamentados no chamado “*Image Understanding*” ou processos baseados em conhecimento.

Estes primeiros conceitos permitem a confecção de um esquema conceitual simplificado, apresentado a seguir pela figura 1, ilustrando as principais fases do processo de extração automática de feições cartográficas (EAFC). Este modelo será utilizado ao longo deste trabalho na montagem da conceituação teórica a ser empregado na fase metodológica do texto e será detalhado ao longo deste capítulo.

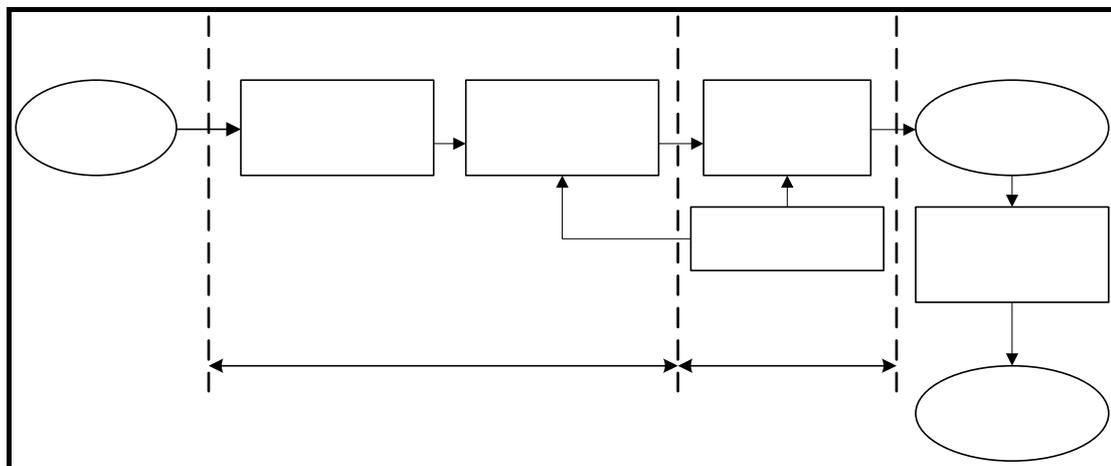


Figura 1 – Esquema Conceitual de um Sistema de EAFC - Adaptado de Aggarwal <sup>[10]</sup>

## 2.2. Fases da EAFC

O processamento digital de imagens consiste no conjunto de técnicas voltadas para a análise de dados de várias dimensões adquiridos por diversos tipos de sensores, ou seja, é a manipulação de uma imagem por computador onde a entrada e a saída do processo são imagens. O processamento é usado para melhorar o aspecto visual da imagem original, fornecer alguns subsídios para a sua interpretação e gerar produtos que possam ser

posteriormente submetidos a outros processamentos. Dentre as áreas em que ele é utilizado estão: análise de recursos naturais e meteorologia por meio de imagens de satélites, transmissão digital de sinais de televisão, análise de imagens biomédicas, obtenção de imagens médicas por ultra-som, radiação nuclear ou técnicas de tomografia computadorizada, aplicações em automação industrial envolvendo o uso de sensores visuais em robôs. O sistema de processamento de imagens é constituído de diversos processos, tais como: digitalização, pré-processamento, segmentação, pós-processamento, extração de atributos, classificação e reconhecimento.

- A digitalização é a conversão de um sinal da forma analógica para a forma digital.
- O pré-processamento refere-se ao processamento inicial de dados brutos para calibração radiométrica da imagem, correção de distorções geométricas e remoção de ruído.
- A segmentação consiste na etapa de processamento em que se analisa a imagem do ponto de vista da informação nela presente, ou seja, consiste em dividir a imagem em diferentes regiões, que serão posteriormente analisadas por algoritmos especializados em busca de informações de alto-nível.
- O pós-processamento é a etapa em que se corrigem os defeitos da segmentação, já que muitas vezes, o resultado da segmentação não é adequado. Para corrigir os defeitos residuais nesta etapa, utilizam-se as técnicas diversas, como por exemplo, a morfologia matemática.
- A extração de atributos é a fase em que se realizam medidas sobre a imagem. Estas medidas podem ser muito sofisticadas, permitindo uma nova separação dos objetos em classes de similaridade, em função dos parâmetros medidos, fase esta chamada de classificação.
- Já o reconhecimento de padrões é a área do processamento em que se utilizam técnicas computacionais para aproximar a performance das máquinas à do ser humano de modo a reconhecer padrões dentro de uma imagem.

Processar uma imagem consiste em transformá-la sucessivamente com o objetivo de extrair a informação nela presente. O objetivo do processamento de imagens consiste em processar uma imagem de modo que o resultado final seja mais adequado que a imagem original para uma aplicação específica. A seguir, serão apresentadas de maneira sucinta as principais fases ou etapas do processamento digital de imagens, de maneira a caracterizá-lo.

### 2.2.1. Pré-Processamento de Imagens

Toda a imagem digital adquirida a partir de sensores aerotransportados e orbitais, antes de sofrer qualquer tratamento referente às diversas distorções inerentes ao processo de coleta de dados, é chamada de imagem bruta. Estas imagens (brutas), antes de serem utilizadas como dados de entrada para processos de produção cartográfica, automatizados ou não, devem passar por etapas ou estágios do processo de PDI para que as distorções citadas anteriormente possam ser modeladas e corrigidas.

O pré-processamento de imagens digitais visa à correção de distorções radiométricas e geométrica em imagens brutas, ou seja, o pré-processamento visa que imperfeições intrínsecas às imagens digitais, normalmente chamadas de ruídos, possam ser removidas ou atenuadas para que na fase de Realce estas imperfeições não sejam enfatizadas ou aumentadas em níveis que comprometam a qualidade dos processos de interpretação e extração de feições. Ainda, a fase de pré-processamento visa garantir que as imagens produzidas sejam compatíveis, em escala e nível de informação, com imagens já geradas permitindo análises multi-temporais e o correto “casamento” entre informações geradas a partir de imagens de sensores distintos.

- Correção Radiométrica

Os sinais provenientes de sensores remotos podem ser considerados como sendo essencialmente a quantidade de energia refletida por um determinado alvo em uma determinada faixa espectral, recebida por um sensor. Porém, os sinais adquiridos diretamente do satélite são normalmente ruidosos. Este ruído pode normalmente ser dividido em duas componentes: Ruído interno e externo. O ruído interno é o proveniente do sensor imageador e o ruído externo o proveniente da atmosfera e das áreas adjacentes a um determinado alvo.

Para a correção destas distorções, existem alguns níveis de correção radiométrica. O primeiro converte o valor do DN do sensor em um valor de radiância e requer as informações de calibração do sensor. O segundo é a transformação das radiâncias do sensor em radiâncias na superfície da Terra. Este nível é muito mais difícil de ser alcançado que o primeiro, tendo em vista que o mesmo requer informações sobre as condições atmosféricas no instante e local do imageamento. O último nível de calibração ou correção refere-se à reflectância da superfície ou da topografia e é alcançada pela correção da declividade e aspecto da topografia do terreno, função da variação do comprimento espectral devido ao relevo, particularmente em locais movimentados, irradiação solar, transmitância atmosférica solar e a radiância.

- Correção Geométrica

O processo de correção geométrica de imagens visa modelar os efeitos provocados pelas fontes de distorções geométricas de modo a eliminar, ou reduzir, a degradação geométrica que tais efeitos provocam. Deve-se ter em mente, que neste processo, a radiometria da imagem deve ser preservada, para não degradar os dados que estão representados na imagem. Dentre as principais fontes de distorções geométricas presentes em imagens digitais, oriundas de plataformas aéreas ou orbitais, pode-se destacar, conforme apresentado na Tabela 1 a seguir:

**Tabela 1 – Principais Fontes de Distorções Geométricas em Imagens Digitais**

<b>Tipo de Distorção</b>	<b>Tipo de Sensor</b>	<b>Efeitos</b>
Distorções quanto a Plataforma		<ul style="list-style-type: none"> <li>• Velocidade</li> <li>• Altitude</li> <li>• Atitude</li> <li>• Rolamento</li> <li>• Arfagem</li> <li>• Guinada</li> </ul>
Distorções quanto ao Sensor Remoto	<ul style="list-style-type: none"> <li>• Sensores de Varredura Mecânica</li> </ul>	<ul style="list-style-type: none"> <li>• Cisalhamento</li> <li>• Variação do tempo útil da varredura</li> <li>• Distorção panorâmica</li> <li>• Deslocamento entre bandas</li> <li>• Deslocamento entre detectores</li> </ul>
	<ul style="list-style-type: none"> <li>• Sensores de Varredura Eletrônica</li> </ul>	<ul style="list-style-type: none"> <li>• Deslocamento entre bandas</li> <li>• Deslocamento entre barras de detectores</li> <li>• Desalinhamento das barras de detectores</li> </ul>
Distorções quanto ao Objeto Imageado (Terra)		<ul style="list-style-type: none"> <li>• Rotação da Terra</li> <li>• Esfericidade da Terra</li> <li>• Relevo da Terra</li> </ul>

A correção geométrica apresenta-se como uma ferramenta importante nas aplicações de sensoriamento remoto. Por este motivo, ela deve incluir o rol de tarefas que compõem o pré-processamento de imagens. A literatura apresenta modelos matemáticos para este fim, bem como modelos para refinar a correção geométrica.

Após o processo de correção geométrica é possível realizar medições sobre a imagem, medições estas que podem ser de distâncias, ângulos e, conseqüentemente, áreas; bem como registros temporais entre imagens de épocas diferentes. A precisão destas medições está

intrinsecamente relacionada com a precisão da correção geométrica, que pode ser determinada a partir de um criterioso procedimento de avaliação. É importante, então, que a correção geométrica seja sempre seguida de um processo de avaliação que informe a qualidade ou a exatidão da geometria da imagem.

Os processos de correção geométrica podem ser divididos de acordo com seu objetivo, às fases de correção e aos modelos matemáticos envolvidos, conforme a Tabela 02 apresentada abaixo:

**Tabela 2 – Divisão dos Processos de Correção Geométrica**

<b>Foco da Correção</b>	<b>Tipo de Correção</b>
Quanto ao Objetivo	<ul style="list-style-type: none"> <li>• Mapeamento Direto (Correção Absoluta)</li> <li>• Mapeamento Inverso (Correção Relativa)</li> <li>• Reamostragem (Interpolação)</li> </ul>
Quanto as Fases de Correção	<ul style="list-style-type: none"> <li>• Correção Absoluta</li> <li>• Correção Relativa</li> </ul>
Quanto aos Modelos Matemáticos	<ul style="list-style-type: none"> <li>• Correção por modelos polinomiais</li> <li>• Correção por modelos independentes</li> <li>• Correção pelo modelo fotogramétrico</li> </ul>

- – Realce de Imagens

O objetivo da atividade de realce de imagens digitais é o de aumentar a capacidade interpretativa visual de uma imagem. Isto pode ser alcançado pelo aumento da diferença aparente entre as diversas feições existentes em uma imagem. Como o cérebro humano é capaz de distinguir com maior facilidade que um computador as relações espaciais entre feições numa imagem, bem como feições escondidas, o realce de imagens visa aumentar a capacidade humana de percepção destas relações espaciais. Da mesma forma o olho humano é capaz de perceber bem menos variações espectrais ou radiométricas em uma imagem do que um computador. O realce de imagem também auxilia no aumento da percepção destas variações pelo computador.

Sendo assim, o realce de imagem visa aumentar a capacidade de percepção do homem e da máquina em seus melhores campos de atuação e conjugar estas habilidades de maneira unificada.

Basicamente existem duas grandes classes de realce – Os realces pontuais e os realces locais. Os realces pontuais são aqueles que alteram a intensidade do valor do brilho em cada pixel de uma imagem de forma independente. Os realces locais são aqueles que alteram esta mesma

intensidade do valor do brilho dos pixels de uma imagem baseado em princípios de vizinhança do valor de intensidade de brilho de um pixel em relação a seus vizinhos.

### 2.2.2. Segmentação de Imagens

O objetivo básico do processo de segmentação de imagens é o particionamento da mesma em um número de regiões não sobrepostas que formam uma rede completa sobre o plano da imagem. Uma quantidade de trabalhos tem sido desenvolvida para alcançar este objetivo já que a segmentação encontra diversas aplicações variando desde aplicações médicas a aplicações militares.

A segmentação é um passo fundamental para a análise e identificação das características relevantes em uma imagem. Segmentar uma imagem significa separá-la em regiões com propriedades (cor, textura, etc) as quais correspondem a objetos ou partes de objetos na imagem. De maneira geral, os métodos para segmentação fazem uso de limiares e hipóteses iniciais para a imagem tais como tipos de texturas, distribuição do histograma, etc.

As técnicas de segmentação de imagens podem ser classificadas de diferentes formas segundo o grau de particionamento ou detalhamento a ser alcançado. Fu e Mui <sup>[102]</sup> utilizam 3 classes relativas – (1) Agrupamento ou “clustering” (2) Detecção de Bordas e (3) Extração de Regiões. Já Haralick e Shapiro <sup>[103]</sup> utilizam uma classificação mais detalhada que divide a segmentação em – (1) Agrupamento; (2) Crescimento de regiões (incluindo os métodos individual e híbrido); (3) Combinação de técnicas híbridas de vinculação ou “linkagem”; (4) Esquemas de agregação espacial e (5) esquemas de união e desagregação. Ainda, Pal e Pal <sup>[107]</sup> sugere uma outra classificação também detalhada, porém mais baseada na visão do pixel – (1) Limiarização do nível de cinza; (2) Classificação interativa de pixels; (3) Segmentação baseada em superfícies; (4) Segmentação de imagens coloridas; (5) Detecção de bordas e (6) Métodos Baseados em Lógica Fuzzy.

As duas últimas apresentadas são classificações complexas e tecnicamente orientadas. De forma mais simples, a divisão do processo de segmentação em (1) Baseado em Pixel; (2) Baseado em Contornos e (3) Baseado em Regiões é uma classificação suficiente para o entendimento desta técnica.

Interessante ressaltar ainda uma classificação bastante simples, porém elegante, apresentada por Sobral <sup>[86]</sup> que divide o processo de segmentação em duas estratégias genéricas:

- Descontinuidade – A partição da imagem é efetuada com base nas alterações bruscas de intensidade (ex., detecção de contornos)

- Similaridade – A partição é efetuada com base na similaridade entre pixels, seguindo um determinado critério (ex., binarização, crescimento de regiões, divisão e junção de regiões)

Abaixo segue um pequeno resumo das principais técnicas de segmentação existentes:

- Análise de Histograma

O procedimento mais básico de segmentação que pode ser efetuado é o de limiarização do nível de cinza de uma imagem. O Limiar pode ser aplicado globalmente em toda a imagem, e é chamado de Limiar Estatístico, ou pode ser aplicado localmente e o limiar irá variar dinamicamente ao longo da imagem. Caso uma imagem possua uniformidade em seus elementos e possua iluminação proporcional, a imagem resultante deste tipo de segmentação irá conter regiões homogêneas com limites ou contornos bem definidos.

- Segmentação e Análise do Espaço Cor

Algoritmos de desagregação recursiva de regiões utilizando discriminantes baseados em cores foram descritos por Ohlander <sup>[105]</sup> e Ohta <sup>[106]</sup>. Iniciando com a imagem como uma única região, estes algoritmos aplicam um conjunto de limiares derivados de histogramas analisados de feições de cores individuais. Uma vez que a região tenha sido segmentada, o algoritmo é aplicado recursivamente para cada nova região.

- Segmentação por Textura

Os três métodos principais para segmentar uma imagem pela textura são: estatísticos, estruturais e espectrais. As técnicas estatísticas permitem caracterizar uma textura do tipo suave, irregular, granulada, etc. As técnicas estruturais tratam da disposição das primitivas numa imagem, por exemplo, textura baseada sobre linhas paralelas dispostas regularmente. As técnicas espectrais levam às propriedades do espectro de Fourier e permitem detectar a periodicidade global a partir da identificação de altas energias na imagem.

- Transformada de Hough

Um problema freqüentemente encontrado na extração de primitivas é a detecção de curvas analíticas do tipo segmento de reta, círculos, elipses, etc.

O método da transformada de Hough para detecção de bordas é aplicável quando se possui informação precisa acerca da forma da curva. Os dados de base da transformada de Hough são geralmente pontos de uma imagem obtidos através das transformações de gradiente e da

limiarização. A idéia é aplicar na imagem uma transformação tal que todos os pontos pertencentes a uma mesma curva sejam mapeados num único ponto do espaço, a partir dos parâmetros da curva procurada. A transformada de Hough é um método de acumulação de requisitos muito geral que permite detectar qualquer curva, mesmo pouco visível ou fortemente ruidosa.

Uma desvantagem do método é a precisão da discretização dos parâmetros. O risco no caso de um passo de discretização muito fraco, é não detectar as curvas. Ao contrário, um passo de discretização muito alto cria erros de interpretação no lugar das curvas bem como no número das retas. Uma outra desvantagem da transformada de Hough é que ela não permite obter a posição nem o comprimento das curvas.

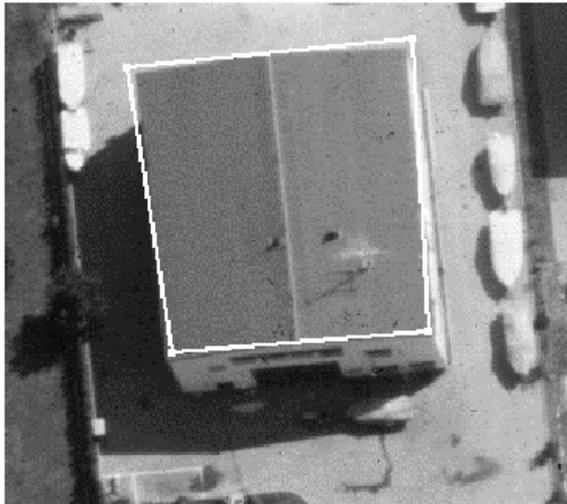
- Detecção de Pontos

A forma mais resumida de segmentar uma imagem sob a forma de contornos é segmentá-la na forma de pontos particulares relevantes. Isto supõe, muitas vezes, eliminar de forma eficiente o ruído para evitar detecções falsas. Esses pontos particulares pesquisados são pontos isolados que devem conter muita informação e não devem ser deteriorados por um ruído. Essa categoria de pontos é muito usada no processo de reconhecimento de objetos e na análise do movimento.

A Detecção de Pontos, por exemplo, é utilizada para a medição de pontos cotados e para a medição de cantos de objetos. A medição de pontos cotados é prática comum dentro do campo da fotogrametria, principalmente para a confecção de bases cartográficas planialtimétricas em escala grande onde normalmente são inseridos pontos cotados no cruzamento de ruas em áreas urbanas. Estas rotinas estão implementadas na maioria das soluções fotogramétricas de mercado e automatiza a atividade do operador que simplesmente posiciona o cursor no local desejado e o sistema marca automaticamente o valor de Z no ponto.

Os algoritmos para a medição de cantos em objetos, também implementados em soluções fotogramétricas de mercado, utilizam funções de gradientes apresentadas por Forstner and Gulch <sup>[101]</sup> para que o operador marque um ponto próximo ao canto desejado e o algoritmo, a partir do valor do nível de cinza, corrija a posição do ponto assinalado. Esta automatização no procedimento auxilia imensamente a produção dos produtos chamados de “Building Heights”.

A Figura 2 abaixo ilustra o processo de detecção de pontos.



Cantos marcados pelo operador



Cantos ajustados pelo algoritmo

Figura 2 – Extração Automática de Pontos <sup>[94]</sup>

- Segmentação por contorno

Um contorno é uma mudança brusca do nível de cinza entre duas regiões relativamente homogêneas. Ele pode aparecer como uma seqüência de pontos, uma linha, um segmento, uma curva ou uma forte variação do nível de cinza médio.

- Detecção de Bordas

Uma das técnicas de detecção de bordas mais usada consiste no processamento de uma imagem a partir de um operador de derivada local. O Gradiente  $G(x,y)$  e o Laplaciano  $L(x,y)$ , operadores de derivada de primeira e segunda ordem respectivamente, podem ser usados para realçar o contraste. Esses operadores são, também, muito usados na pesquisa de contornos.

A avaliação do gradiente a partir de máscaras não é única e depende dos coeficientes e do tamanho das máscaras. A escolha das máscaras adequadas depende de vários critérios (quantidade de ruído, tipo de ruído, contraste, etc.) cujo principal e mais significativo é o tamanho da máscara. Este define a importância da suavização nos cálculos das diferenças (princípio da derivada local). Quanto maior a máscara, maior será a suavização.

A imagem gradiente não fornece diretamente os contornos. Na prática, ela fornece traços grossos e irregulares. Para obter traços mais precisos e mais nítidos, usa-se o processo de limiarização do módulo do gradiente da imagem. A precisão dos traços depende do valor da limiarização e da exatidão dos cálculos das derivadas: um valor alto usado na limiarização fornece traços finos mas muitas vezes interrompidos, enquanto um valor fraco proporciona traços mais completos porém mais grossos e podem produzir linhas que não existem na imagem de origem.

- Enlace de bordas e detecção de contornos

As técnicas precedentes permitem detectar discontinuidades nos níveis de cinza e fornecer contornos entre as diferentes regiões. Mas raramente o conjunto de pixels traduz contornos completos. Por causa do ruído, dos cortes no contorno devido à iluminação não uniforme e de outras perturbações, o contorno aparece como sendo um conjunto descontínuo.

A partir desses fatos, alguns procedimentos de enlace de bordas são usados junto aos algoritmos de detecção de contornos para reunir pixels de bordas em um conjunto significativo de contorno de regiões.

- Perseguição de Contornos

Uma técnica apropriada para enlaçar pixels de um contorno é dispor de uma ferramenta que permita analisar as características dos pixels que têm a possibilidade de pertencer ao contorno e escolher os mais relevantes. A vantagem dessa codificação é permitir representar simplesmente uma seqüência de pontos a partir de oito direções, numeradas de 0 até 7, que são os eixos verticais, horizontais e as duas diagonais.

O princípio do algoritmo de perseguição reside na busca iterativa de pontos similares do contorno, cada um desses pontos respeitando um critério de pertinência ao contorno e escolhido da vizinhança do ponto anterior já retido. O grande interesse desse algoritmo vem do fato que a busca é otimizada por pesquisa orientada segundo direções preferenciais.

O critério de pertinência depende exclusivamente do tipo de imagem processada e, de forma geral, está ligada à noção de nível de cinza. Ele pode ser, por exemplo, o valor do gradiente, caso a imagem tenha sido derivada por um operador de diferenciação do tipo gradiente, ou ainda simplesmente um dos níveis de cinza (preto ou branco) caso a imagem seja binária.

- Modelos de Contorno Ativo (“Snakes”)

Os Modelos de Contornos Ativos, por sua vez, na sua formulação original proposta por Kass <sup>[104]</sup>, fazem uso de informações locais sobre um contorno, podendo incorporar também informações a priori sobre a imagem como um todo ou sobre os segmentos procurados. São métodos usados para extração das bordas dos objetos da cena, sendo em geral aplicados conjuntamente com técnicas de filtragem usadas na detecção de pontos de bordas. Uma dificuldade com estes métodos é a necessidade de uma boa estimativa inicial do contorno procurado para garantir o bom funcionamento do método. Apesar disto, esses modelos têm a vantagem de facilitar a incorporação de informações conhecidas a priori sobre os contornos

(topologia, suavidade, etc) bem como facilitar a interação com o usuário quando esta se torna necessária.

Basicamente existem duas grandes abordagens para a extração de feições lineares, uma baseada na técnica de gabaritos deformáveis (*deformable templates*) também chamada de “*snakes*” e outra baseada na técnica de sementes.

Gabaritos Deformáveis – Na técnica de gabaritos deformáveis o operador representa, a partir de um polígono, a diretriz da feição linear. A partir deste polígono com alguns nós o algoritmo tentará expandi-lo de forma a criar novos nós coincidentes com os limites da feição linear a ser representada. Caso não existam limites para a deformação o polígono continua crescendo e se deformando indefinidamente. Para tanto, regras de restrição ou limites são impostas ao algoritmo para que ele pare exatamente (ou o mais próximo possível) ao limite da feição a ser representada.

Sementes – Na técnica de sementes, ao contrário dos gabaritos deformáveis, o operador não traça um gabarito inicial envolvendo toda a feição a ser representada, mas sim um pequeno pedaço desta feição ou uma semente. A partir desta semente o valor do nível de cinza da mesma é computado pelo algoritmo e perseguido em toda a imagem digital baseado em regras de direção e curvatura estimadas. Esta estimativa é utilizada para prever a posição da feição no passo seguinte ao da marcação da semente. O valor de cinza do próximo passo é computado e comparado com o padrão computado para a semente. Caso os valores de cinza sejam similares, as posições da semente e do passo são comparadas e dão lugar a um novo passo com nova direção e curvatura e o processo segue até que os valores de cinza posterior e anterior não sejam similares. As Figuras 3 e 4 a seguir ilustram as técnicas de contornos ativos por gabaritos deformáveis e por sementes.



Figura 3 – exemplo de Gabaritos Deformáveis<sup>[94]</sup>



**Figura 4 – Exemplo de Sementes (Segmentos em Preto - Sementes)<sup>[94]</sup>**

- Crescimento de Regiões e Algoritmos de União e Desagregação

O método de segmentação por crescimento de regiões realiza uma busca por grupos de pixels com alguma propriedade de similaridade, tentando agrupar os pixels de uma área com brilho similar, isto é, que caracterizam uma mesma região.

Inicialmente, o método começa com um pixel e, a partir daí, examina seus vizinhos, numa seqüência, para decidir se eles possuem brilho similar, segundo o critério de similaridade escolhido. Se os pixels vizinhos analisados forem aceitos como similares, então eles são agrupados ao pixel inicial (semente) para formar uma região. Desta forma, as regiões vão sendo desenvolvidas a partir de pixels sementes (únicos).

Uma maneira mais precisa de iniciar o processo de crescimento de regiões é não começar com pixels, mas com um conjunto de pequenas regiões. A partir disto, um teste de uniformidade é aplicado a cada região. Caso o teste falhe, a região é subdividida em elementos menores até que todas regiões fiquem uniformes. A vantagem em usar pequenas regiões ao invés de pixels é a redução da sensibilidade ao ruído.

O método de Divisão e Fusão permite agrupar pixels para criar regiões sobre as quais um predicado de homogeneidade  $H$  é verificado. A imagem é manipulada através de divisões e fusões até se obter regiões que satisfaçam o critério  $H$  (mesmo nível de cinza, mesma média etc).

Esse método é muitas vezes associado a uma estrutura QUADTREE que permite, de uma forma elegante, decompor e agrupar partes de uma imagem. Construir um quadtree consiste em dividir uma imagem  $I(x,y)$  em quatro regiões iguais e continuar a dividir cada região da mesma maneira até encontrar regiões satisfazendo a um critério  $H$ . O quadtree é uma estrutura

em árvore constituída de uma raiz, que corresponde à imagem original, e de nós onde cada nó representa um quadrante da imagem. A Figura 5 ilustra com clareza o processo de crescimento de regiões.



**Figura 5 – Exemplo de Crescimento de Regiões<sup>[94]</sup>**

- Segmentação de Bacias (“Watershed”)

O algoritmo de Bacias pode ser aplicado a uma imagem de magnitude de gradiente para os propósitos de segmentação de imagens. Considerando-se a magnitude do gradiente em cada pixel como uma altura de uma superfície 3-D, regiões podem ser formadas pela simulação de uma inundação da imagem que começa na mínima local da função gradiente de imagem. Os limites de cada região param de avançar quando regiões vizinhas inundadas são encontradas e os limites ainda correspondem a caminhos do gradiente de magnitude.

- Operadores Morfológicos

A Morfologia Matemática surgiu na década de sessenta, mais precisamente entre 1964 e 1968, onde se estabeleceram as primeiras noções teóricas derivadas de pesquisas feitas por G. Matheron e J. Serra. No mesmo período foi fundado o Centre de Morphologie Mathématique na École de Mines de Paris (França), permanecendo em atividade desde então.

A morfologia matemática, além de aplicável como técnica de segmentação, pode ainda ser aplicada na otimização da forma das regiões ou objetos obtidos no processo de segmentação. Os principais operadores da Morfologia Matemática são:

**Tabela 3 – Operadores Básicos da Morfologia Matemática**

<b>Operador Morfológico</b>	<b>Implementação</b>
Erosão	Os pixels mais exteriores da região são removidos
Dilatação	É acrescentada mais uma camada de pixels à região
Anti-Erosão	Erosão seguida de uma dilatação
Anti-Dilatação	Dilatação seguida de uma erosão

### 2.2.3. Interpretação e Rotulagem dos Dados

Esta etapa, também conhecida como refinamento, é a etapa do processamento que vai classificar os objetos a partir de informações encontradas na imagem, geralmente tendo como apoio uma base de conhecimento previamente estabelecida. Esta fase é normalmente aplicada após uma fase de segmentação e parametrização da imagem. A fase de parametrização identifica e calcula parâmetros nos objetos segmentados. Um exemplo de parâmetros pertinentes a um objeto é o seu perímetro ou sua área.

Na fase de Interpretação e rotulagem de dados, técnicas já sedimentadas se misturam a novas técnicas no sentido de refinar os dados oriundos do processo de segmentação. A partir de uma imagem segmentada a classificação e extração dos objetos de interesse pode ser efetuada de várias formas:

- Classificação Não-Supervisionada
- Classificação Supervisionada
- Classificação baseada em Conhecimento e baseada em lógica Fuzzy
- Métodos Híbridos
- Redes Neurais

As técnicas de classificação, introduzidas logo após o lançamento dos primeiros satélites de observação da Terra, foram desenvolvidas para que os grandes volumes de imagem que estavam sendo coletados à época pudessem ser analisados e integrados de forma rápida e confiável. Neste momento, as imagens de sensoriamento remoto, ainda de baixa resolução espacial, cobriam extensas porções terrestres - na faixa dos trinta (30) mil Km<sup>2</sup>. Este grande volume de dados ou de extensão do globo, imageada pelos primeiros sensores remotos, tornava impossível para equipes de especialistas estarem interpretando estes dados de forma rápida e precisa. Ainda com relação à baixa resolução espacial dos primeiros sensores remotos o processo de classificação automático de imagens digitais alcançou grande sucesso

por conseguir extrair excelentes resultados apenas por levar em consideração a análise única da informação espectral contida nos “pixels” da imagem digital. Quando a análise do processo de classificação é feita de forma isolada denomina-se o processo de “classificação supervisionada” e quando a análise é efetuada de forma relacional, a partir de métodos estatísticos, denomina-se o processo de “classificação não supervisionada”.

Com o aumento da resolução espacial dos sensores remotos o processo de classificação unicamente baseado na informação espectral da imagem não se mostrou suficiente para discretizar a enorme quantidade de novas classes ou temas possíveis de serem extraídos a partir das imagens digitais. Era necessário buscar outras informações dentro da própria imagem digital capazes de auxiliar na definição exata de cada objeto a ser classificado.

É bem verdade que durante o tempo de avanço tecnológico na resolução espacial dos sensores orbitais várias áreas do conhecimento como a visão computacional (*Machine Vision and Machine Learning*) e o “*image understanding*” evoluíram ainda mais, amenizando um possível choque com o avanço da resolução espacial. Juntamente a estes fatores a fotogrametria evoluiu e dá lugar à nova fotogrametria digital capaz de trabalhar com dados de sensores aéreos e orbitais de alta resolução de forma análoga.

Estes avanços promovem a união das áreas relacionadas às geociências com as áreas relacionadas à sistemas e computação e mostram que além das informações espectrais, contidas nas imagens digitais, esforços devem ser travados no entendimento das informações posicionais, métricas, geométricas e estatísticas contidas nas mesmas.

## **CAPÍTULO 3 - A EAFC E OS PLANOS DE INFORMAÇÃO CARTOGRÁFICOS**

A partir da análise dos principais métodos de segmentação presentes no capítulo anterior pode-se destacar como fundamental a caracterização inequívoca do plano de informação de interesse a ser abordado no processo de EAFC para a correta escolha do fluxo de trabalho a ser empregado no processo de extração automática de feições.

Analogamente aos planos de informação cartográficos, que sofrem a influência da variação da escala em suas representações, o processo de EAFC também sofre esta influência a partir dos dados de entrada (imagem digital) a serem adotados no processo.

Da mesma forma que a escala, que influencia na modelagem da feição a ser representada no plano de informação cartográfico, a resolução da imagem digital limita ou abre espaço para a utilização de um ou mais processos de segmentação e classificação de imagens.

Um fato interessante no processo de EAFC é o relacionamento entre a evolução da resolução espacial e a transição desta evolução entre as esferas militar e civil. Durante muitos anos a tecnologia de imagens de alta resolução espacial esteve disponível somente à comunidade militar, o que ocasionou, durante este mesmo período, uma pesquisa maior no campo da EAFC em de imagens de média e baixa resoluções e algoritmos baseados somente no domínio espectral da imagem, dentro da comunidade civil.

À medida que a resolução espacial das imagens foi incrementada, a heterogeneidade radiométrica das mesmas aumentou, aumentando também a demanda por métodos mais sofisticados para a quantificação e interpretação da informação espacial.

Guindon <sup>[45]</sup> cita que a comunidade civil de sensoriamento remoto, que ao longo do tempo manipulou uma enorme quantidade de dados de imagens multiespectrais de média e baixa resolução espacial (de 10 a 1000 metros), se concentrou na exploração dos atributos espectrais das imagens ao invés dos atributos espaciais das imagens nos mapeamentos temáticos em escalas pequenas. Enquanto estas conquistas tiveram um impressionante impacto no mapeamento em escalas pequenas, eles foram de menor valor para os mapeamentos em escalas detalhadas.

Por outro lado, pesquisas paralelas, em andamento nos últimos 20 anos, desenvolveram sistemas de processamento de imagens aéreas baseadas em computador. Pesquisas estas que foram amplamente patrocinadas pela comunidade militar e como resultado produziram aplicações diretamente focadas a esta comunidade. Entretanto, estas mesmas pesquisas

resultaram no desenvolvimento de um conjunto de tecnologias baseadas no contexto espacial altamente aderentes a imagens monocromáticas de alta resolução e, em teoria, passíveis de serem generalizadas para um outro grande número de aplicações.

### 3.1. Dos Planos de Informação Cartográfica

Sendo primeiramente o mapa uma representação dos aspectos naturais e artificiais da superfície da Terra, toda essa representação só pode ser convencional, isto é, através de pontos, círculos, traços, polígonos, cores, etc.

A carta ou mapa tem por objetivo a representação do espaço tridimensional do mundo real no espaço bidimensional do papel e modernamente dos monitores de computadores pessoais. Este espaço tridimensional pode ser dividido em duas componentes, que podem estar representadas conjuntamente ou isoladamente nas cartas e mapas, segundo o interesse, sendo a primeira referente ao plano (X, Y) e a segunda à altitude (Z), ou seja, componentes planimétricas e altimétricas.

A representação planimétrica pode ser dividida em duas partes, de acordo com os elementos que cobrem a superfície do solo, ou seja, físicos ou naturais e culturais ou artificiais. Os primeiros correspondem principalmente aos temas relacionados à **hidrografia** e **vegetação**, os segundos decorrem da **ocupação humana**, **sistema viário**, **construções**, limites políticos ou administrativos, etc.

A representação altimétrica corresponde à representação de temas físicos como **aspectos do relevo** (acidentes naturais e referências de nível), **curvas de nível** e **redes de drenagem** entre outros.

Com base na revisão bibliográfica efetuada no capítulo 2 deste trabalho, dentro de um pequeno universo de textos pesquisados que abordam o tema da extração automática de feições em fotografias aéreas ou em imagens de alta resolução, pode-se chegar a algumas conclusões acerca do andamento das pesquisas em EAFC no mundo, comentadas e traduzidas na forma de gráficos apresentados ao longo deste capítulo.

De acordo com a primeira divisão em componentes do espaço tridimensional, representada pela planimetria e pela altimetria, pode-se notar um expressivo interesse pelas feições planimétricas às feições altimétricas.

Uma das justificativas para esta concentração reside no fato de que a fotogrametria, mesmo antes de seu estágio digital, já fazia uso de dados de alta resolução, a partir de filmes em formato analógico, para a extração de feições altimétricas. Nesta fase (analógica) da fotogrametria, o delineamento ou desenho de curvas de nível era a atividade de maior

consumo de tempo e esforços por parte de operadores o que possivelmente, quando do advento da fotogrametria digital, iniciou os processos de pesquisa na automatização da extração de feições altimétricas, previamente às feições planimétricas.

Uma outra corrente defende a idéia de que as feições altimétricas, para serem extraídas de forma automática, necessitam que suas feições planimétricas de inter-relacionamento sejam extraídas previamente, como a hidrografia e o sistema viário. Com isto, a pesquisa sobre a extração de feições planimétricas deve ser dominada previamente a extração de feições altimétricas. A figura 6, construída a partir da análise estatística dos materiais pesquisados durante a fase de revisão bibliográfica deste trabalho, apresenta a participação da ocorrência de pesquisas em feições planimétricas e altimétricas de forma isolada e também de forma conjunta. Pode-se notar a maior ocorrência de pesquisas voltadas às feições planimétricas:

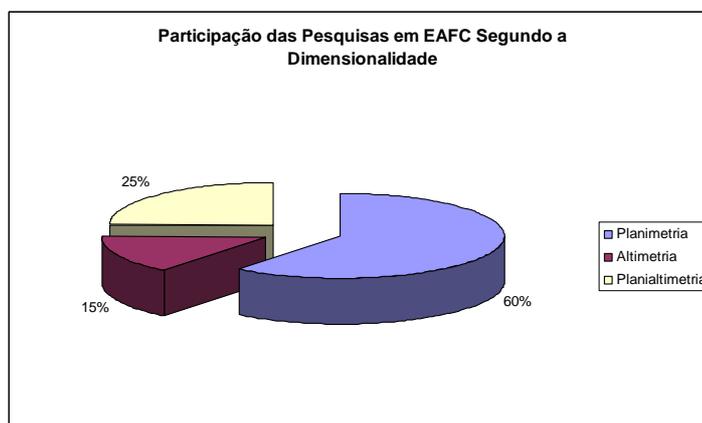
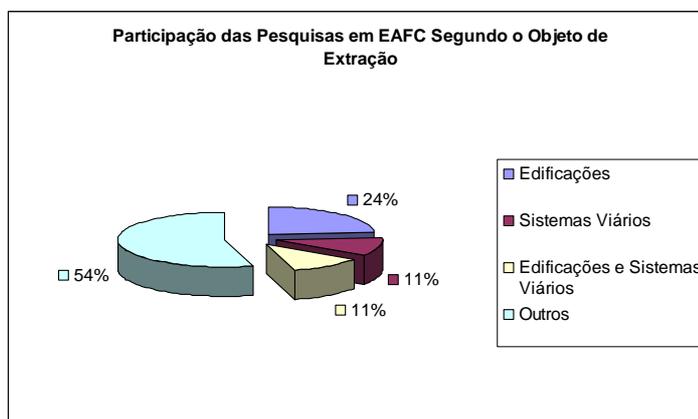


Figura 6 – Participação das pesquisas em EAFC segundo a dimensionalidade

Descendo para um nível mais detalhado na divisão de temas de representação cartográfica pode-se corroborar o fato de que as feições planimétricas têm sido alvo de maior interesse pela comunidade científica do que as feições altimétricas. Este aspecto tem como base a rápida transição citada anteriormente das resoluções espaciais médias e baixas para a alta resolução dos sensores atuais. No passado, as imagens de média e baixa resolução não permitiam a subdivisão de feições em grupos mais detalhados, limitando a pesquisa de EAFC a grupos mais homogêneos. Por exemplo, com o aumento da resolução espacial dos sensores orbitais e aerotransportados o tema relacionado a áreas urbanas, representado em escalas médias e pequenas como um polígono envolvendo a mancha urbana, pode ser subdividido em grupos de feições mais detalhados como edificações, logradouros, lotes, quadras e outros.

O gráfico da Figura 7, também confeccionado a partir da análise do banco de dados de materiais consultados durante a fase de revisão bibliográfica, mostra que as feições construídas pelo homem (“man-made features”), tais como edificações e sistemas viários, ocuparam quase que 50% do interesse das pesquisas efetuadas no momento.



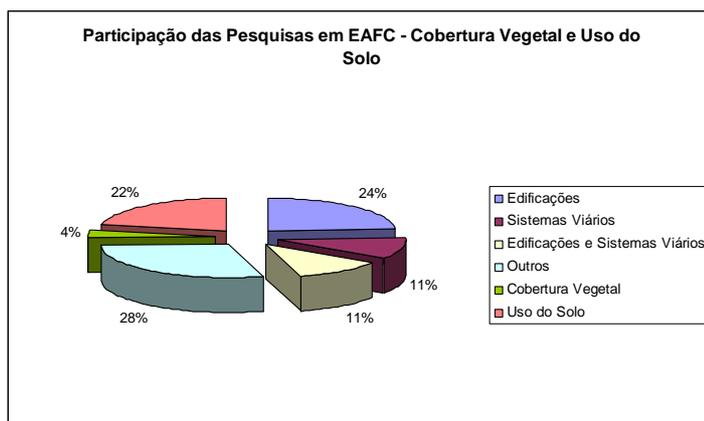
**Figura 7 – Participação das Pesquisas em EAFC Segundo o Objeto de Extração**

Especificamente para o tema de interesse desta dissertação, devido a uma maior fiscalização da responsabilidade social e ambiental de empresas na execução de seus empreendimentos, os mapas ditos de cobertura vegetal e uso e ocupação da terra tornam-se de extrema importância na análise pública ou privada destes empreendimentos. O objetivo básico destes tipos de monitoramento é o conhecimento da parcela de biomassa natural presente nas regiões envolvidas por estes empreendimentos, e um dimensionamento ou estimativa de quanto desta parcela será afetada de forma direta e indireta pela execução do empreendimento, bem como o mapeamento dos principais tipos de uso da terra, por exemplo na forma de culturas permanentes ou sazonais, visando a possíveis indenizações individuais ou de interesse coletivo.

As pesquisas em EAFC ainda não refletem, de forma mais acentuada, o grande interesse na representação do espaço geográfico a partir dos temas de cobertura vegetal e uso do solo.

As pesquisas relativas ao uso da terra, possivelmente pela grande expansão do agro-negócio no mundo, se apresentam como uma parcela representativa das pesquisas em EAFC investigadas neste trabalho.

Entretanto, as pesquisas sobre a cobertura vegetal, ainda apresentam números pequenos, conforme se pode verificar na figura 8.



**Figura 8 – Participação das Pesquisas em EAFC - Cobertura Vegetal e Uso do Solo**

Como estes tipos de estudos levam em consideração aspectos e influências denominados tecnicamente de Macro, Meso e Micro análises, de acordo com a distância do impacto causado por um empreendimento em um determinado espaço geográfico, imagens de diferentes resoluções e coberturas espaciais são utilizadas no processo.

Como as áreas envolvidas em estudos deste tipo podem chegar a círculos de 50 Km de raio ou aproximadamente 8.000 Km<sup>2</sup>, as imagens de média e baixa resolução ainda são as imagens mais empregadas neste tipo de estudo, sendo a imagem Landsat de ampla utilização, por exemplo, em suas resoluções pancromática e multiespectral de 15 metros e 30 metros. Além de seu baixo custo, as imagens Landsat possuem mais de 20 anos de pesquisa em seus padrões espectrais facilitando seu uso e permitindo a automatização de sua classificação.

A automatização dos processos de classificação e EAFC para o tema de Cobertura Vegetal e Uso e Ocupação do Solo se torna de extrema importância na medida em que as áreas envolvidas são sempre extensas e a classificação das mesmas de forma visual e manual eleva em muito o prazo para a conclusão de estudos ambientais e relatórios de impactos ambientais (EIA/RIMA) importantes para a condução das ações públicas, em especial ao Ministério do Meio Ambiente (MMA).

A tabela 4 a seguir, ilustra o predomínio do uso de imagens Landsat nos programas internacionais de estudo e acompanhamento dos processos de desenvolvimento de cobertura vegetal e uso do solo. A coluna **Programa** caracteriza o nome do programa e a área de abrangência do mesmo. As colunas **Num. de classes**, **Formato dos dados** e **Imagens de satélite** caracterizam, respectivamente, o número de temas trabalhados pelos programas no processo de extração, os formatos envolvidos e as imagens digitais utilizadas como entrada no processo. A coluna **Metodologia** descreve a forma como os dados são manipulados,

ênfatizando, em alguns programas, o uso de processos de segmentação para a discriminação das feições ou classes de interesse e o uso de processos de classificação automatizados.

Cabe notar que nos programas desenvolvidos pelos EUA a classificação é feita de forma automática (não assistida) sendo somente avaliada a partir de análise visual posterior.

**Tabela 4 – A EAFC e os programas internacionais sistemáticos de mapeamento da Cobertura Vegetal e do Uso da Terra – Adaptado de Caetano<sup>[20]</sup>**

<b>Programa</b>	<b>Num. de classes</b>	<b>Formato dos dados</b>	<b>Unidade mínima (ha)</b>	<b>Imagens de satélite</b>	<b>Metodologia</b>	<b>Localização</b>
North American Landscape Characterization (NALC)	16	<i>Imagem Digital</i>	0.36	Landsat MSS	Classificação não assistida e análise visual de imagens	América do Norte
National Land Cover Characterisation (NLCD)	21	<i>Imagem Digital</i>	0.09	Landsat TM	Classificação não assistida	48 estados contínuos dos EUA
Kansas State Land Use/Land Cover Map	10	Vetorial	Aprox. 1 ha	Landsat TM	Classificação não assistida e edição manual	Estado do Kansas, EUA
California Land Cover Mapping and Monitoring Program	44	Vetorial	Aprox. 1,2 ha	Landsat TM	Classificação digital, segmentação e reclassificação	Estado da Califórnia, EUA
North Carolina State Land Cover Map	22	<i>Imagem Digital</i>	0.97 ha	Landsat TM	Classificação de imagens com um método híbrido	Estado da Carolina do Norte, EUA
Ontario Cover Map	28	<i>Imagem Digital</i>	0.5 ha	Landsat TM	Classificação assistida	Estado do Ontário, Canadá
South African National Land Cover Database (NLC)	31	Vetorial	25 ha	Landsat TM	Análise visual de imagens	África do Sul, Suazilândia e Lesoto
CORINE Land Cover	44	Vetorial	25 ha	Landsat TM	Análise visual	Europa
Finnish land use and forest classification	50	<i>Imagem Digital</i>	0.06	Landsat TM	Classificação assistida	Finlândia
Swedish Terrain Type Classification	13	<i>Imagem Digital</i>	0.06	Landsat TM e SPOT XS	Classificação e análise visual	Suécia
Land cover map of Great Britain	25	Vetorial	0.06	Landsat TM	Classificação assistida	Reino Unido

### 3.2. Dos Softwares, Programas e Algoritmos de EAFC

Atualmente, a quantidade de pesquisas no campo da EAFC se apresenta em diversos estágios de desenvolvimento. Dentre esta quantidade, algumas pesquisas já estão num estágio de maturação avançado, resultando em sistemas para tratamento de fotografias aéreas e imagens de alta resolução. Esses sistemas podem ser categorizados, de acordo com o objetivo temático da extração automática de feições, a partir da divisão em classes que, num primeiro momento, remetem o leitor à própria divisão, apresentada na introdução deste trabalho, para a Visão Computacional.

- Sistemas Abrangentes, capazes de prover interpretação total da imagem digital
- Sistemas Direcionados, capazes de delinear e caracterizar um conjunto limitado de objetos
- Sistemas de Apoio, capazes de prover funcionalidades automatizadas em áreas como a retificação de imagens, integração de dados de imagens e outros

A tabela 5 a seguir apresenta um extrato, a partir dos materiais levantados durante a fase de revisão bibliográfica, ilustrando a participação de organismos militares nos principais sistemas de EAFC em estágio avançado ou final de desenvolvimento. A tabela concentra seus exemplos em entidades norte-americanas porém pode ser estendido para outros países como Itália, Suíça, Alemanha, Austrália, França e Israel entre outros. Esta tabela não leva em consideração sistemas assistidos ou semi-automáticos mas sim somente os sistemas plenamente automatizados voltados a EAFC.

**Tabela 5 – Sumário dos Principais Sistemas de EAFC**

<b>Sistema</b>	<b>Referência da Pesquisa</b>	<b>Desenvolvedor</b>	<b>Patrocinador</b>	<b>País</b>	<b>Feições de Interesse</b>
3DIUS	Fischler and Bolles (1994), Sinning-Meister et al., (1996)	SRI International	Forças Armadas	EUA	Mundos Virtuais
ACRONYM	Brooks (1981)		DARPA	EUA	Aeronaves
AIMS	Chu e Aggarwall (1996)		Forças Armadas	EUA	Várias
ARF ( A Road Tracker)	McKeown and Denlinger (1988)	Carnegie-Mellon University	Intituições Civis	EUA	Rodovias

<b>Sistema</b>	<b>Referência da Pesquisa</b>		<b>Patrocinador</b>	<b>País</b>	<b>Feições de Interesse</b>
ASCENDER	Prof. Allen R. Hanson		DARPA	EUA	Mundos Virtuais
BABE (Built-up Area Building Extractor)	Shufelt and McKeown (1993)		Intituições Civis	EUA	Edificações
BUILD	McKeown et al., (1994)		Intituições Civis	EUA	Edificações
CANC	Mohan and Nevatia (1989)		Intituições Civis	EUA	Edificações
COBIUS (Constraint-Based Image Understanding System)	Bjorklund et al (1989)	Lockheed Artificial Intelligence Center	DARPA	EUA	Aeronaves
CYCLOPS	Barnard (1990)		Intituições Civis	EUA	Várias
MULTIVIEW (Multi-Image Building Extraction)	Roux et al . (1995)	University of Michigan	IBM, Intel, entre outros	EUA	Edificações
OCAPI	(Clemet & Thonnat, 1993)		DARPA	EUA	Várias
PACE	Corby et al . (1988)		DARPA	EUA	Aeronaves
PIVOT	McGlone and Shufelt, 1994	Carnegie-Mellon University	DARPA/USATEC	EUA	Edificações
PSEIKI	(Andress & KAK, 1988)		DARPA	EUA	Várias
ROADF	Zlotnick and Carnine (1993)	Carnegie-Mellon University	Intituições Civis	EUA	Rodovias
ROADMAP	McKeown et al., 1996		DARPA	EUA	Rodovias
S3	McKeown et al., (1994)		Intituições Civis	EUA	Correlação de Imagens
SCORPIUS	Bogdanowicz and Newman (1989)		DARPA	EUA	Rodovias e Edificações
SIGMA	Matsuyama (1987)	Carnegie-Mellon University	Forças Armadas	EUA	Várias
SITECITY	Hsieh, (1996)		DARPA/USATEC	EUA	Mundos Virtuais
SPAM	Harvey et al . (1992) McKeown et al . (1989)		Intituições Civis	EUA	Aeroportos

Sistema	Referência da Pesquisa		Patrocinador	País	Feições de Interesse
TRIPLE (Target Recognition Incorporating Positive Learning Expertise)	Bhanu and Ming (1988)		Forças Armadas	EUA	Várias
VHBUILD	McGlone and Shufelt, 1994b	Carnegie-Mellon University	DARPA/USATEC	EUA	Edificações

Esta tabela, além de outros aspectos, apresenta a influência da comunidade militar nos projetos de pesquisa de sistemas de EAFC mais maduros. Frequentemente, estas pesquisas não são desenvolvidas pelos órgãos militares e sim por instituições de ensino e pesquisa em todo o mundo a destacar-se a “*School of Computer Science - Carnegie Mellon University – Pittsburgh*” que tem desenvolvido a maioria das pesquisas apresentadas a partir de contratos de parceria e patrocínio com o DARPA (*Defense Advanced Research Projects Agency*) e o acompanhamento e fiscalização das pesquisas pela USATEC (“*U.S. Army Topographic Engineering Center*”).

A presença de organismos militares suportando as pesquisas acima mencionadas provavelmente faz com que estes sistemas não estejam disponíveis para avaliação integral ou a partir de seus códigos-fonte. Apenas os resultados de suas pesquisas estão disponíveis, bem como o arcabouço teórico utilizado que poderá ser reutilizado para reconstruir os ensaios efetuados. A figura 9 ilustra o exposto neste parágrafo a partir da participação de organismos militares no patrocínio à pesquisas relacionadas com a EAFC.

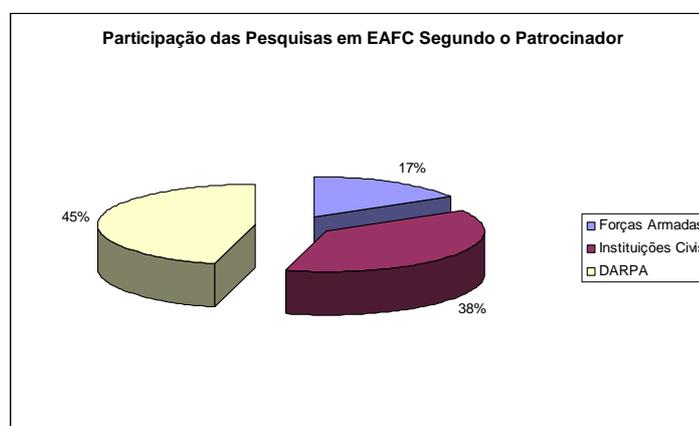


Figura 9 – Participação das Pesquisas em EAFC segundo o Patrocínio

Independentemente da influência do patrocínio de organismos militares nos principais projetos de EAFC, existe o fato concreto de que não estão disponíveis para a incorporação em ambientes e processos de produção cartográfica, soluções ou algoritmos genéricos de extração automática de feições baseados em softwares livres ou códigos abertos.

A falta de resultados mais conclusivos e abrangentes para a automatização da produção cartográfica, independente da região geográfica ou do conhecimento prévio dos arranjos geográficos das feições de interesse, abre espaço ainda, para a pesquisa por alternativas viáveis e passíveis de incorporação ao processo.

Como já abordado ao longo desta dissertação e, tendo em vista o processo produtivo cartográfico, a fase de vetorização ou restituição de feições cartográficas ainda apresenta-se como a etapa que mais consome tempo e recursos, em termos computacional e humano, para sua execução.

Desta forma, este trabalho procurou suporte na utilização de softwares e soluções atualmente disponíveis no mercado e capazes de serem inseridas de forma integral ou parcial ao processo de produção cartográfica. Apesar de alguns softwares disponibilizarem a seus usuários ferramentas e processos para a preparação ou para a extração de feições, esta dissertação procurou reduzir seu campo de possibilidades baseando sua escolha nos softwares e soluções que efetivamente possuíssem uma integração com os softwares e soluções hoje em uso no contexto dos processos produtivos cartográficos. Tal estratégia tem por finalidade a obtenção de uma sinergia entre o software a ser avaliado e os softwares de produção cartográfica tradicionais, bem como softwares ou soluções que notadamente propusessem uma quebra de paradigma dentre as ofertas de soluções para a extração automática de feições em softwares comerciais.

Com isto, este trabalho valeu-se da utilização dos softwares *E-Cognition* distribuído pela *Definiens Imaging GmbH* e do *Erdas Imagine* distribuído anteriormente pela *Erdas Inc.* e hoje distribuído pela *Leica Geosystems GIS & Mapping, LLC*.

O software *E-Cognition* segue uma abordagem nova, orientada a objeto, para a análise de imagens digitais. O conceito embutido neste software é de que a informação semântica necessária à correta interpretação de imagens, não está representada ou baseada em pixels, mas sim em objetos da imagem e seus relacionamentos mútuos. A diferença básica entre o *E-Cognition* e outras soluções baseadas em pixels é que o mesmo não classifica pixels individuais, mas sim objetos da imagem que são extraídos a partir de um processo de segmentação. O processo de classificação é baseado em lógica fuzzy, que permite a integração de características dos objetos, tais como os valores espectrais ou, por exemplo, a

textura. Utilizando não somente as características do objeto, mas também o relacionamento entre eles, os resultados incorporam “contexto” à classificação.

Outro diferencial deste software em relação aos seus pares de mercado é a execução do processo de segmentação a partir da técnica de multivariação. Esta técnica baseia-se na união de regiões, onde cada região é iniciada por um único pixel. O algoritmo de união de regiões, a partir de um processo iterativo, conecta as regiões adjacentes baseado nas propriedades espectrais e espaciais dos objetos. Os principais parâmetros de controle deste algoritmo são a escala, a cor e a forma. A cor refere-se ao espaço espectral e a forma ao espaço geométrico dos objetos. Há que se ressaltar que o parâmetro de forma é o resultado da combinação dos parâmetros de suavização e compactação que também podem ser ponderados pelo usuário.

O software *Erdas Imagine*, em sua versão 8.7, será utilizado de maneira a criar um contraponto de avaliação ao software *E-Cognition*. Diferentemente do *E-Cognition*, o *Erdas Imagine* possui seu processo de classificação baseado em pixels, sendo assim, o mesmo não inclui em seu fluxograma de trabalho a etapa de segmentação. Todavia, o *Erdas Imagine* seja o software comercial que possui o maior número de algoritmos e filtros **Espaciais**, **Radiométricos** e **Espectrais** para o tratamento e interpretação de imagens. Para a contraposição dos processos efetuados no *E-Cognition* este trabalho implementa, a partir do módulo “*Spatial Modeler*” do *Erdas Imagine*, uma seqüência de filtragens direcionadas à extração de regiões, de forma a representar um segmentador.

A implementação faz uso da seleção de pixels chamados de sementes e calcula a distância euclidiana dos pixels adjacentes a esses pixels. Caso a distância seja menor ou igual ao limiar espectral definido na implementação, os novos pixels são incorporados ao pixel semente formando regiões. Ao contrário, caso a distância seja maior que o limiar espectral definido, o pixel passará por um novo teste, associado a uma distância espacial definida para as regiões. Caso o pixel seja rejeitado, o processo recomeça com um novo pixel e caso o pixel seja aceito, ele é adicionado à nova região e o processo continua até que toda a imagem seja discretizada em regiões.

Este processo é baseado nas pesquisas do Departamento de Agricultura dos Estados Unidos (USDA), do Serviço de Engenharia Florestal e do Centro de Aplicações em Sensoriamento Remoto (RSAC) <sup>[34,35]</sup>.

# CAPÍTULO 4 - METODOLOGIA E TESTES OPERACIONAIS

Neste Capítulo são apresentados os materiais e métodos empregados no alcance dos objetivos propostos, bem como a descrição da área objeto selecionada para a aplicação da metodologia ora proposta.

## 4.1. Área Selecionada

Para a seleção de uma área de testes capaz de ensaiar de forma satisfatória a metodologia proposta neste capítulo, foram considerados os seguintes parâmetros:

- Disponibilidade de uma base cartográfica atualizada e confiável, em escala adequada aos trabalhos em questão, para as análises quantitativa e qualitativa da metodologia proposta;
- Existência de um número mínimo de planos de informação relativos à Cobertura Vegetal e ao Uso e Ocupação da Terra, objetos desta dissertação;
- Possibilidade de disponibilização desta base em meio digital;
- Possibilidade de deslocamento ao local para trabalhos de campo;



Figura 10 – Croqui de Localização do Projeto FERROVIAS

A área selecionada foi um dos trechos que compõem o **Projeto FERROVIAS** executado atualmente pela Companhia Vale do Rio Doce (CVRD). A figura 10, mostrada anteriormente, apresenta uma versão sintética do encaminhamento do projeto, onde cada um dos trechos (14 trechos) contemplados pelo projeto estão representados.

Especificamente, a área selecionada encontra-se ao longo de um dos trechos da Ferrovia Centro-Atlântica (FCA), compreendida entre as cidades de Sete Lagoas e Belo Horizonte, denominado Trecho 04. A figura 11 apresenta ao centro o encaminhamento do trecho 04 e sua ligação com os demais trechos.



**Figura 11 – Croqui Detalhado de Localização - Trecho 04 (BH - 7Lagoas)**

## 4.2. Materiais Disponíveis

O Projeto Ferrovias tem como objetivo geral a criação de uma base cartográfica de referência para o controle e monitoramento da infra-estrutura da malha ferroviária da CVRD hoje em operação. Como objetivo específico, o Projeto Ferrovias prevê a confecção de planos de informação temática compreendendo os temas relativos à cobertura vegetal, uso do solo e infra-estrutura, para subsídio às atividades de licenciamento e preservação dos diversos empreendimentos da CVRD junto ao IBAMA e ao Ministério do Meio Ambiente (MMA).

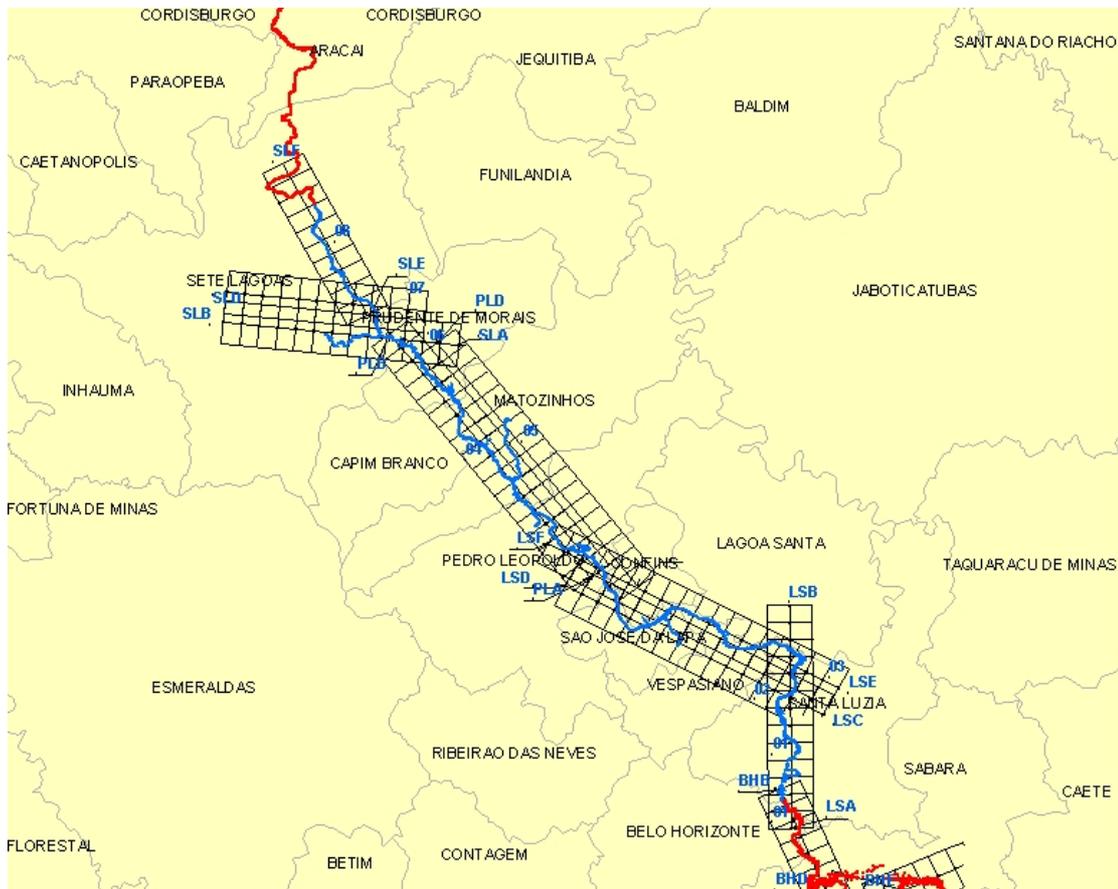
Do ponto de vista técnico, o Projeto Ferrovias contemplou a contratação de um recobrimento aerofotogramétrico, na escala de 1/15.000, cobrindo uma área de aproximadamente 8.000 Km lineares e 16.000 Km<sup>2</sup>, a partir de fotografias aéreas coloridas tomadas com superposição

longitudinal de aproximadamente 60% e lateral de aproximadamente 30%. Dada a resolução resultante do sistema câmera-filme, as fotografias tomadas apresentam uma resolução de 25 micra, quando digitalizadas matricialmente à resolução de 1016 DPI, o que corresponde no terreno a 37,50 centímetros (cm), considerando-se a escala da cobertura aerofotogramétrica.

Estas fotografias, ortorretificadas a partir de pontos de controle planialtimétricos e modelos digitais de elevação geraram ortofotos digitais com 50 cm de resolução. Estas ortofotos foram equalizadas e geraram o mosaico contínuo ao longo de toda a ferrovia.

Especificamente para o Trecho 04 foram tomadas 08 faixas com 139 fotografias no total. Estas fotografias foram ortorretificadas e mosaicadas gerando um ortofotomosaico de aproximadamente 500 Km<sup>2</sup>.

A figura 12 apresenta a articulação das fotos e faixas que recobrem a área de testes desta dissertação, ou seja, o trecho 04 do Projeto FERROVIAS.



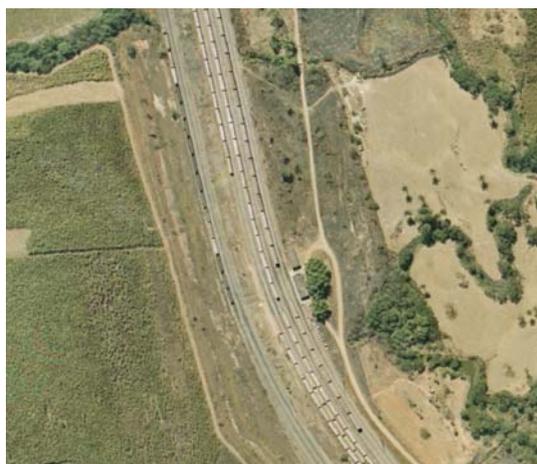
**Figura 12 – Trecho 04 (em azul) – Faixas de Vôo (em Preto)**

Os mosaicos resultantes foram interpretados, a partir de consultoria especializada e visitas em campo para conferência de dúvidas, visando à extração dos diversos planos de informação temáticos. Basicamente, devido ao caráter específico envolvido no licenciamento ambiental, um maior foco foi dispensado aos planos de informação relativos aos temas ligados à Vegetação e ao Uso do Solo.

A figura 13 apresenta a configuração do ortofotomosaico completo para a área de testes do projeto e a figura 16 apresenta uma ampliação deste ortofotomosaico em sua resolução máxima (50 cm). A figura 14 caracteriza a forma clara com que se apresenta a heterogeneidade numa imagem de alta resolução.



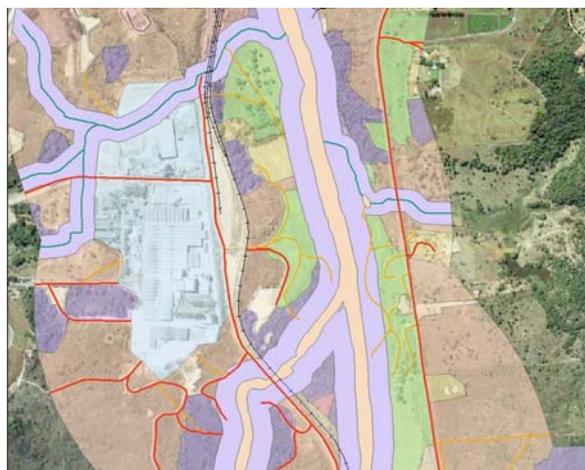
**Figura 13 – Ortofotomosaico do Trecho 04**



**Figura 14 – Detalhe em Resolução Máxima do Ortofotomosaico**



**Figura 15 – Interpretação Temática sobre o Ortofotomosaico do Trecho 04**



**Figura 16 – Detalhe da Interpretação Temática, em Resolução Máxima, sobre o Ortofotomosaico**

A figura 15 apresenta a interpretação temática executada ao longo de um corredor de 1 km ao longo do eixo de toda a ferrovia, enquanto a figura 16 traz uma ampliação desta interpretação sobreposta a uma porção do ortofotomosaico, em sua ampliação máxima.

### 4.3. Classes e Legendas Utilizadas

A legenda original aplicada dentro do Projeto Ferrovias é extensa, cobrindo mais de 300 níveis relativos a diversos grupos disciplinares como Hidrografia, Sistema Viário, Altimetria, Vegetação, Uso do Solo entre outros. Infelizmente, devido ao prazo para a conclusão deste trabalho, não é possível cobrir toda esta legenda. Mesmo as legendas relativas à cobertura vegetal e ao uso do solo são bastante detalhadas e não foram utilizadas, em sua totalidade, como norteadoras dos esforços deste documento.

Para este trabalho foram adotadas somente quatro classes, cobrindo os temas de interesse desta dissertação, a saber: **Floresta Estacional, Pasto Sujo, Pastagem e Culturas Perenes**.

A figura 17 apresenta um pequeno exemplo da legenda original do Projeto Ferrovias com 18 classes estratificadas dos temas relativos ao uso do solo e da cobertura vegetal.

Na figura, a legenda “FloEstSemi” representa a classe de **Floresta Estacional Semi-Decidual** utilizada neste trabalho. Respectivamente, as legendas “PastoSuj”, “Pastagem” e “CultPerenes” representam as classes **Pasto Sujo, Pastagem e Culturas Perenes**.

**Figura 17 – Extrato da Legenda completa – Projeto FERROVIAS**

004-AMB-USO-PL-F23S	
 <all other values>	 CultTemp
<b>SUBCAT</b>	 FloEstSemi
 AreaAntropica	 FloOmbAl
 AreaIndustrial	 FloOmbD
 AreaMineracao	 FloOmbDI
 AreaUrbana	 Pastagem
 AreasUmidas	 PastoSuj
 Campo	 Reflorestamento
 Cerrado	 Restinga
 CultPerene	 SoloExposto

### 4.4. Metodologia

Dado o curto espaço de tempo para a execução de todos os testes referentes às classes adotadas neste trabalho e tendo em vista o grande volume de dados a ser utilizado nos testes operacionais, a estrutura da metodologia adotada para esta dissertação contempla a divisão da mesma a partir de quatro etapas de trabalho. Nas etapas 1 e 2 os testes relativos aos processos

de segmentação, classificação e extração dos objetos de interesse são executados dentro dos softwares *E-Cognition* e *Erdas Imagine* respectivamente e seus resultados analisados comparativamente à base de dados existente, considerada a “verdade de campo” para o trabalho. Como o volume de dados da área de testes como um todo remonta um total de 500 Km<sup>2</sup> e 40 Gb de dados, as etapas 1 e 2 são aplicadas somente a uma porção desta área. Estas duas primeiras etapas visam caracterizar a aplicabilidade dos softwares adotados ao problema proposto.

A etapa 3 da metodologia cria uma base de comparação entre os resultados alcançados nas etapas 1 e 2, visando determinar qual das etapas apresentou o melhor resultado frente a verdade de campo.

A partir da escolha do melhor software ou da melhor solução apresentada, a etapa 4 executa novamente toda a metodologia adotada para as etapas 1 ou 2, dependendo do software que apresentar o melhor resultado, na área total de testes empregada nesta dissertação.

Estes resultados serão comparados em termos técnicos, tendo em vista as análises quantitativas e qualitativas a serem implementadas, bem como em termos do aspecto produtivo, aspecto este balizador de toda esta dissertação, comparando-se os esforços em termos de tempo de operadores e máquina para o alcance dos resultados gerados a partir do processo totalmente automatizado contra o processo clássico de restituição ou vetorização manual.

#### 4.4.1. Metodologia - E-Cognition

No *E-Cognition* serão utilizadas duas segmentações sucessivas. A primeira, lançando-se mão de um parâmetro de escala de valor alto, de forma a resultar uma segmentação que particione a imagem em grandes grupos de feições poligonais mais próximas às classes relativas ao uso do solo e cobertura vegetal existentes. Esta nova imagem-objeto será utilizada para representar as classes a serem geradas no *E-Cognition* e para o refinamento do processo de classificação.

A segunda segmentação será efetuada a partir de um parâmetro de escala de valor baixo (porém ambos os fatores de escala serão maiores que o fator de escala ou a resolução original do pixel da imagem) para que a imagem seja compartimentada em grupos menores de objetos que serão utilizados para as etapas de treinamento do classificador fuzzy e para as operações de união e desagregação das amostras a serem empregadas na classificação. A classificação será executada baseada nas ferramentas de lógica fuzzy disponíveis no software.

#### 4.4.2. Metodologia – Erdas Imagine

Analogamente ao processo de segmentação no ambiente do *E-Cognition* a imagem teste será segmentada dentro do ambiente do *Erdas Imagine 8.7* com base num processo de segmentação desenvolvido pelo Serviço Florestal do Departamento de Agricultura Norte Americano (USDA) e comentado sumariamente no capítulo 3 deste trabalho. Para o trabalho com o parâmetro de escala será utilizado um filtro estatístico de homogeneização de regiões, presente dentro do módulo “*Interpreter*” do *Erdas Imagine*. Para as análises de Cor e Forma, o algoritmo proposto utilizará um fluxograma de trabalho expresso pela figura 18 apresentada a seguir.

Esta metodologia, proposta pelo USDA, se dá de uma maneira similar ao início das pesquisas deste trabalho, por alguns aspectos de ordem técnica e financeira. No aspecto técnico, segundo a USDA, a maioria dos programas que abordam o problema da EAFC para fins de mapeamento temático está disponível somente para plataformas UNIX ou em códigos não abertos, impossibilitando o uso numa organização de produção cartográfica. Este aspecto é exaustivamente abordado na publicação de 1996 de David M. McKeown, Jr. <sup>[69]</sup>.

No aspecto financeiro, separando-se as soluções baseadas em UNIX que além do custo de aquisição de software envolvem ainda a aquisição de hardware de valor elevado, as soluções de mercado como o PCI GEOMATICS e o *E-COGNITION* são ditas pela USDA como caras. Sendo assim a USDA optou por implementar uma solução própria, no ambiente do *Erdas Imagine*, da mesma forma que neste trabalho.

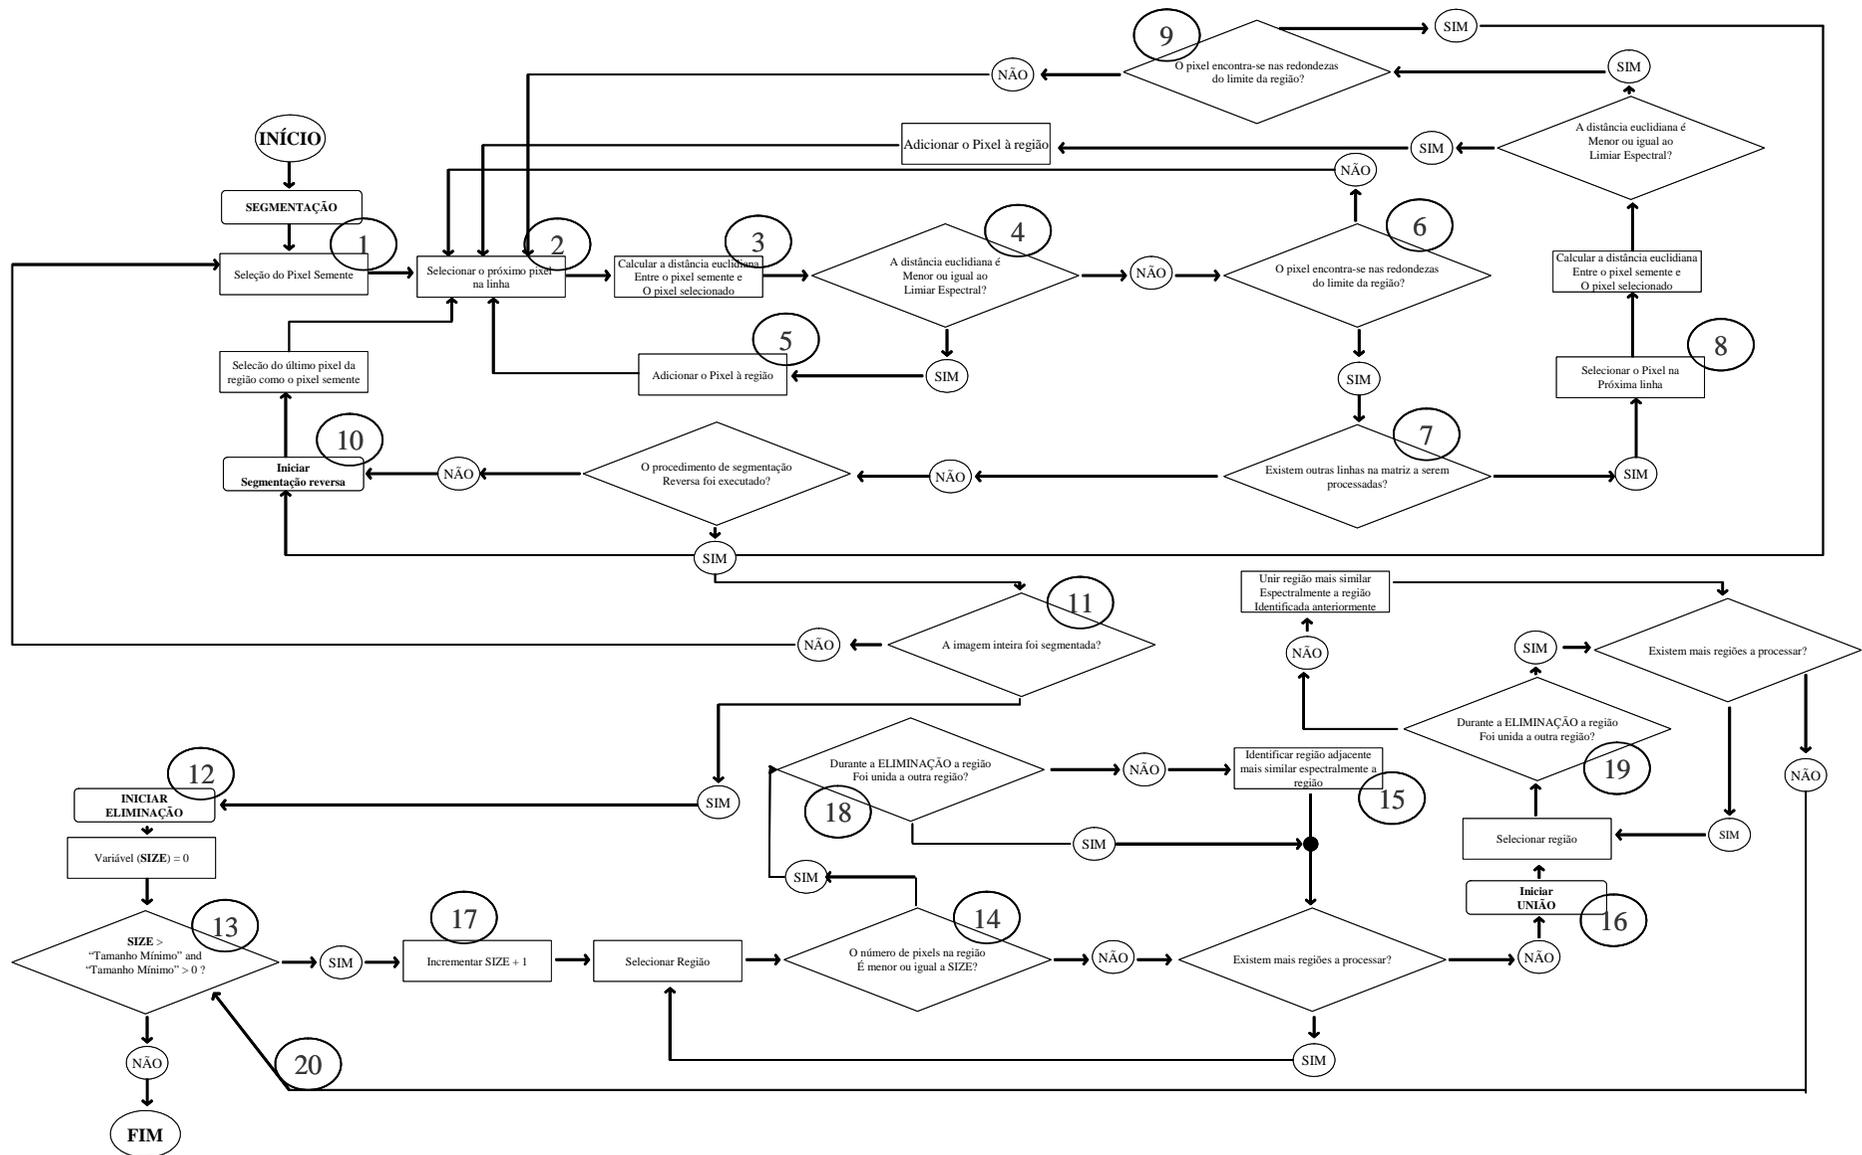


Figura 18 – Fluxo de simulação de segmentação no Erdas Imagine

#### 4.4.3. Diferenças e Similaridades – E-Cognition Vs. Erdas Imagine

##### 4.4.3.1. Segmentação

Dentro da filosofia do *E-Cognition* a escala é um parâmetro chave para o “*image understanding*”. Embora para o sensoriamento remoto a noção de escala esteja sempre conectada à resolução espacial do pixel de uma imagem, objetos de interesse dentro de uma imagem podem ter sua própria escala, segundo os interesses da aplicação destes objetos. A escala pode determinar a ocorrência ou não de uma determinada classe de objetos, por exemplo. Da mesma forma, um mesmo objeto pode possuir diferentes representações segundo as diferentes escalas de interesse.

Basicamente pode-se definir a diferença entre a escala e a resolução, dentro de um conceito de processamento de imagem, como a resolução espacial sendo a área média coberta por um pixel de imagem digital no terreno e a escala como sendo o nível de abstração ou generalização com que um certo fenômeno pode ser representado.

Com respeito à segmentação, como já dito anteriormente, a mesma pode ser definida como a subdivisão da imagem digital em regiões distintas. Várias abordagens diferentes, citadas no capítulo três desta dissertação, têm sido tema de pesquisa nos últimos anos. Todas estas abordagens enfrentam problemas que dificultam o aprimoramento dos processos de EAFC como o grande número de graus de liberdade envolvidos nas várias possíveis soluções, a heterogeneidade das regiões nas imagens, problemas de ambigüidade entre outros.

No processo de segmentação a expectativa em muitos casos é que seja possível, após o processo de segmentação, a extração automática dos objetos segmentados. Entretanto, devido aos obstáculos descritos no parágrafo anterior, os resultados têm se apresentado de forma mais satisfatória somente para áreas específicas, com um número reduzido de classes e de dados de imagem.

De forma simplificada o processo de segmentação pode ser dividido em dois grandes domínios: Os métodos baseados em conhecimento, chamados de métodos “*Top-Down*”, onde são considerados os algoritmos e os desenvolvimentos desenhados para imagens específicas ou para a ocorrência específica de um dado objeto em uma imagem e os métodos baseados no dado de imagem, chamados de métodos “*Bottom-Up*”, normalmente mais aplicados a problemas genéricos.

Os métodos baseados em conhecimento, como o próprio nome já enseja, são métodos aplicados quando é conhecido o objeto, ou objetos, que se deseja extrair. A partir do conhecimento dos objetos é formulado um modelo matemático dos mesmos, bem como o processo de filtragem mais adequado à aplicação deste modelo, além do processo de segmentação, que buscará este modelo em toda a área da imagem. Já os métodos baseados nos dados são normalmente mais aplicados à segmentação de objetos que podem se apresentar de diversas formas numa mesma imagem digital. Esses métodos utilizam parâmetros estatísticos para o processamento da imagem. As regiões de imagem segmentadas ou objetos segmentados não possuem conhecimento associado e normalmente são chamados de primitivas da imagem.

Tanto o *E-Cognition* como o *Erdas Imagine* baseiam sua segmentação em métodos baseados em dados, ou seja, métodos “*Bottom-Up*”. A diferença entre eles é como este método de segmentação é implementado.

Para o processo de segmentação o *E-Cognition* lança mão da técnica de multisegmentação. A multisegmentação como o nome indica é uma reunião de técnicas de segmentação que são aplicadas conjuntamente em toda a imagem objetivando a geração de primitivas em várias escalas diferentes. No *E-Cognition* as primitivas geradas formam o chamado nível de objeto e as segmentações podem ser armazenadas de forma hierárquica. A partir do armazenamento das primitivas o *E-Cognition* incorpora a cada objeto as relações de vizinhança (espacialidade) com seus objetos vizinhos, com objetos de camadas inferiores e superiores (no caso de mais de uma camada de segmentação). A partir desta rede de relacionamento entre a imagem original, a imagem segmentada e as camadas de classificação, o *E-Cognition* cria uma conexão baseada em diferentes escalas, entre estes objetos, representando a mesma informação em diversas escalas simultaneamente.

Esta capacidade do *E-Cognition* justifica a adoção da metodologia proposta onde a imagem será trabalhada não só com um nível de segmentação mas sim com dois níveis de segmentação distintos.

Apesar da adoção de mais de um nível de segmentação, conjugado à imagem original, tornar a manipulação da rede complexa, este caminho foi adotado, pois a classificação existente, gerada a partir do processo de vetorização tradicional, considerada neste trabalho como a verdade de campo, não será utilizada como informação inicial para o processo de segmentação.

Isto porque a idéia deste trabalho baseia-se na avaliação da capacidade de utilização da técnica de EAFC na produção cartográfica de qualquer área a ser mapeada ou atualizada. Caso a classificação existente fosse utilizada como parâmetro de entrada do processo de segmentação, o *E-Cognition* segmentaria a imagem a partir de tentativas sucessivas, até que os objetos gerados pelo resultado da segmentação fossem iguais aos polígonos utilizados como dados de entrada, mascarando o resultado final da aplicação.

Desta forma, a “verdade de campo” será utilizada para a escolha das amostras que serão utilizadas no processo de classificação fuzzy dentro do *E-Cognition*.

No *E-Cognition* cinco são os parâmetros possíveis de serem trabalhados dentro do processo de segmentação, sendo três diretos e dois indiretos, a saber: **Escala, Cor, Forma, Suavidade e Compactação**, respectivamente.

A escala é basicamente o parâmetro que controla a homogeneidade das primitivas a serem geradas no processo de segmentação. O objetivo do parâmetro de escala é minimizar a heterogeneidade da imagem a partir da união de pequenas áreas da imagem em áreas maiores. Para tanto a escala faz uso da equação 4.1.:

$$h = \sum_c W_c \times \sigma_c, \text{ Onde: } \dots\dots\dots \text{ (Eq. 4.1.)}$$

- $h$  = Valor do Parâmetro de Escala fixado a ser alcançado na segmentação;
- $\sum_c W_c$  = Somatório dos desvios padrão dos valores espectrais em cada canal da imagem;
- $\sigma_c$  = Peso para cada canal da imagem

Os parâmetros de cor e forma são aplicados conjuntamente na imagem, juntamente com o parâmetro de escala. Esses parâmetros obedecem a formulação da equação 4.2.:

$$f = w \cdot h_{color} + (1 - w) \cdot h_{shape} \quad \dots\dots\dots(\text{Eq. 4.2.})$$

Onde  $W$  é um número entre 0 e 1 e corresponde ao valor informado para o parâmetro de Cor no início do processo de segmentação.

Da mesma forma,  $h_{color}$  e  $h_{shape}$  pode ser definidos pelas equações 4.3. e 4.4. abaixo:

$$h_{color} = \sum_c w_c \left( n_{Merge} \cdot \sigma_c^{Merge} - \left( n_{Obj1} \cdot \sigma_c^{Obj1} + n_{Obj2} \cdot \sigma_c^{Obj2} \right) \right) \quad \dots\dots\dots(\text{Eq. 4.3.})$$

$$h_{shape} = w_{cmpct} \cdot h_{cmpct} + \left( 1 - w_{cmpct} \right) \cdot h_{smooth} \quad \dots\dots\dots(\text{Eq. 4.4.})$$

Como se pode notar,  $h_{shape}$  é um parâmetro direto composto por dois parâmetros indiretos, quais sejam, Suavidade e Compactação. Suavidade (*smooth*) e Compactação (*cmpct*) podem ser expressos pelas equações 4.5. e 4.6., a seguir:

$$h_{smooth} = n_{Merge} \cdot \frac{l_{Merge}}{b_{Merge}} - \left( n_{Obj1} \cdot \frac{l_{Obj1}}{b_{Obj1}} + n_{Obj2} \cdot \frac{l_{Obj2}}{b_{Obj2}} \right) \quad \dots\dots\dots(\text{Eq. 4.5.})$$

$$h_{cmpct} = n_{Merge} \cdot \frac{l_{Merge}}{\sqrt{n_{Merge}}} - \left( n_{Obj1} \cdot \frac{l_{Obj1}}{\sqrt{n_{Obj1}}} + n_{Obj2} \cdot \frac{l_{Obj2}}{\sqrt{n_{Obj2}}} \right) \quad \dots\dots\dots(\text{Eq. 4.6.})$$

#### 4.4.3.2. Classificação

O processo de classificação nos dois softwares se apresenta de forma similar, diferentemente do processo de segmentação, onde as diferenças entre as duas soluções (*E-Cognition* e *Erdas Imagine*) são bastante sensíveis, principalmente no aspecto das variáveis a serem levadas em consideração no processo (cor, forma, suavidade e compactação) bem como na criação de redes hierárquicas lógicas para a conexão dos objetos no ambiente *E-Cognition*.,. O *Erdas Imagine*, em sendo um software não só dedicado ao processamento de imagens, mas também à publicação de dados geográficos, possui diversos módulos, desde a preparação dos dados de entrada até sua publicação na forma de mapas impressos ou mesmo de modelos

virtuais em 3D. Sendo assim, o processo de classificação do *Erdas Imagine* se apresenta na forma de módulos, de maneira compartimentada, onde vários passos são necessários até o alcance do resultado final.

Já o *E-Cognition*, desenvolvido especificamente em suporte às atividades de processamento digital de imagens, possui um fluxograma de trabalho simples e de entendimento fácil. Várias funções que se apresentam compartimentadas no ambiente do *Erdas Imagine*, principalmente as de avaliação dos resultados, podem ser acessadas no *E-Cognition* a partir de um simples clique no mouse. Porém, todas as atividades de classificação a serem executadas no ambiente do *E-Cognition* podem ser traduzidas para o ambiente do *Erdas Imagine*.

Para fins deste trabalho, em ambas as soluções, o processo de classificação a ser adotado é o da classificação supervisionada, a partir da seleção de amostras presentes na base vetorial de interpretação, gerada a partir do processo clássico de vetorização. Os exemplos extraídos da base existente foram selecionados e introduzidos nas duas soluções como objetos de treinamento da rede fuzzy de classificação.

No *E-Cognition*, a partir da ferramenta “*sample editor*”, os atributos espectrais dos exemplos extraídos da base existente foram estendidos aos objetos ou primitivas criados a partir da segmentação da imagem original. A partir dos objetos segmentados, o nível das primitivas foi classificado a partir de um conceito de associação. O conceito de associação, ou “*membership*” como usualmente encontrado na literatura, é um conceito derivado da própria lógica fuzzy onde um objeto, diferentemente das abordagens dos sistemas unicamente baseado na análise de intensidade de cinza de pixels, pode ou não pertencer a uma determinada classe, a partir da determinação de graus ou critérios de pertinência para os mesmos. O conceito de associação é extremamente útil para imagens de alta resolução, pois as mesmas possuem um alto grau de heterogeneidade que tende a ser minimizado durante a fase de segmentação, porém não suprimido das imagens. A partir do conceito de associação, um objeto ainda heterogêneo que poderia ser classificado erradamente por sistemas de classificação não baseados em lógica fuzzy, pode ser classificado em uma ou mais classes, dependendo do grau de sua heterogeneidade, associando-se um critério de pertinência em relação as camadas de classificação utilizadas.

O critério de pertinência de um objeto também será o suporte para o refinamento dos resultados de classificações sucessivas até que o resultado final das matrizes de probabilidade esteja dentro de um limite de confiança aceitável para o mesmo. Usualmente é adotado um nível de confiança maior ou igual a 80% como aceitável para que um objeto esteja bem representado dentro de sua classe.

No ambiente do *Erdas Imagine*, o processo de classificação se dá de forma semelhante. A partir do módulo “*signature editor*” os objetos de treinamento são selecionados e a classificação é executada. O módulo “*knowledge engineer*” é o responsável pela etapa de “fuzzificação”, ou seja, pela alocação de pesos e influências para cada um dos objetos classificados.

Tendo em vista a motivação deste trabalho pela investigação da potencialidade da utilização da tecnologia de EAFC na produção cartográfica, especificamente nos temas de cobertura vegetal e uso e ocupação do solo, não serão aplicadas regras mais elaboradas para a modelagem dos objetos relativos as classes estipuladas, pois intenciona-se a simulação de uma extração a partir de uma área nova, ou seja, não conhecida pelo foto-intérprete. Como não se possui um conhecimento maior dos arranjos espaciais, configurados pelos objetos geográficos no terreno, não serão aplicadas regras de forma específicas, mas somente uma regra de filtragem de áreas menores para que pequenas regiões dentro dos objetos segmentados não sejam classificadas isoladamente, porém incorporadas aos objetos maiores, representativos do todo.

No capítulo seguinte serão apresentados os resultados obtidos pela utilização dos softwares expostos ao longo deste capítulo. Estes resultados serão analisados de forma quantitativa e qualitativa tentando caracterizar a viabilidade, em termos do processo produtivo de bases cartográficas, da metodologia adotada. Os resultados expressam a agregação de valor da adoção da segmentação dentro do processo de EAFC, especificamente a adoção de técnicas de segmentação baseadas na multivariação e da adoção da lógica fuzzy no processo de classificação das imagens digitais de alta resolução, principalmente as fotografias aéreas.

## CAPÍTULO 5 – ANÁLISE DOS RESULTADOS

A análise deste trabalho será apresentada a partir de quatro segmentos. No primeiro segmento serão apresentados os resultados, em termos quantitativos e qualitativos, referente ao processo de classificação a partir do *E-Cognition*, executado na porção da área total, conforme anteriormente explicado na introdução do capítulo 4 deste trabalho. No segundo segmento serão apresentados os resultados, também em termos quantitativos e qualitativos, referentes ao processo de classificação a partir do *Erdas Imagine*, também com base na porção da área total. No terceiro segmento será apresentada uma análise comparativa dos resultados obtidos no *E-Cognition* com os obtidos no *Erdas Imagine*, de forma a criar uma base de comparação entre as duas abordagens e apresentar a melhor alternativa. A partir desta análise, a metodologia aplicada a etapa que apresentar o melhor resultado será aplicada, para toda a base de dados do trecho 04, e os novos resultados finais serão apresentados.

No quarto e último segmento serão comparados os resultados finais conseguidos no segmento três deste capítulo com os esforços empregados pelo processo convencional de interpretação e vetorização manual da base de dados existente para que se faça uma comparação entre o processo automatizado e o processo convencional, em termos do tempo necessário para a execução dos testes baseados na metodologia vencedora. Os resultados estão apresentados de forma que venham a contribuir para que futuras pesquisas e implementações a serem executadas neste campo possam se basear na metodologia ora proposta. Espera-se também que a compartimentação dos resultados venha a contribuir como um insumo inicial para o aprimoramento deste tipo de aplicação não só no tema de interesse, como também em novos grupos disciplinares onde a pesquisa possa vir a ser inserida.

### 5.1. Resultados Alcançados – *E-Cognition*

Efetivamente o *E-Cognition* agrega, a partir de seu processo de segmentação baseado na multisegmentação, uma enorme contribuição ao processo de classificação e rotulação de dados. Quer seja a partir da modelagem prévia de uma base de conhecimento para um ou mais objetos, no caso de uma abordagem “*top-down*”, ou ainda a partir de uma abordagem “*bottom-up*” como no caso deste trabalho, o *E-Cognition* soma, a partir de sua multisegmentação e da criação da camada de objeto chamada de primitiva, uma enorme contribuição ao processo de classificação de imagens baseado em lógica fuzzy.

A primeira grande contribuição do *E-Cognition*, ainda no nível do objeto ou das primitivas é a criação das classes de associação entre os objetos segmentados. Antes da classificação, esta rede de relacionamento encontra-se somente estruturada, mas não ainda classificada e todos os objetos não apresentam pertinência em relação às classes.

A figura 19, mostrada a seguir, ilustra o exposto anteriormente apresentando a tabela de atributos de objetos criada a partir do processo de segmentação da imagem. Cada objeto gerado durante a segmentação corresponde a uma linha da tabela de atributos.

FID	Shape	ID	Red	Green	Blue	BestClass	BestClass	BestMember	SecondClass	SecondCl 1	SecondMem	ThirdClass	ThirdCla 1	ThirdMemb
0	Polygon	0	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
1	Polygon	1	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
2	Polygon	2	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
3	Polygon	3	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
4	Polygon	4	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
5	Polygon	5	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
6	Polygon	6	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
7	Polygon	7	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
8	Polygon	8	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
9	Polygon	9	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
10	Polygon	10	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
11	Polygon	11	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
12	Polygon	12	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
13	Polygon	13	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
14	Polygon	14	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
15	Polygon	15	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
16	Polygon	16	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
17	Polygon	17	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
18	Polygon	18	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
19	Polygon	19	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
20	Polygon	20	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
21	Polygon	21	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
22	Polygon	22	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
23	Polygon	23	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
24	Polygon	24	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
25	Polygon	25	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
26	Polygon	26	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
27	Polygon	27	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
28	Polygon	28	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
29	Polygon	29	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
30	Polygon	30	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
31	Polygon	31	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0

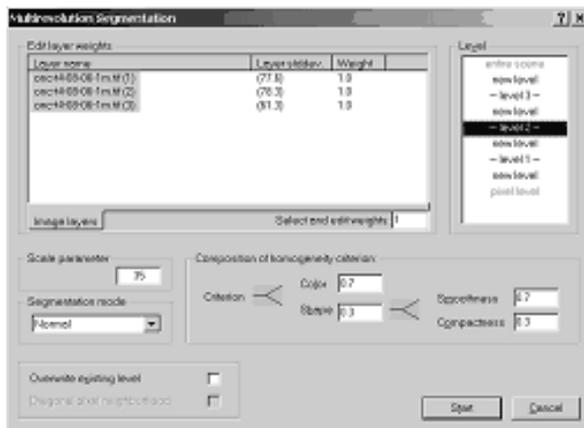
Figura 19 – Tabela de Atributos do nível de objeto - Multisegmentação

As associações entre os objetos ficam representadas a partir das colunas da tabela apresentada na figura 21. Basicamente a tabela de atributos de objetos contém as seguintes informações:

- Colunas 1 à 3: Indexação da Tabela;
- Colunas 4 à 6: Composição RGB que cada objeto receberá após o processo de classificação;
- Coluna 7 à 9: Primeiro nível de possibilidade de um objeto pertencer a uma determinada classe. Respectivamente, as colunas representam o nome da classe, a probabilidade do objeto pertencer a esta classe e a possibilidade do mesmo pertencer a esta classe;
- Colunas 10 à 12: Segundo nível de possibilidade de um objeto pertencer a uma determinada classe. Respectivamente, as colunas representam o nome da classe, a probabilidade do objeto pertencer a esta classe e a possibilidade do mesmo pertencer a esta classe;

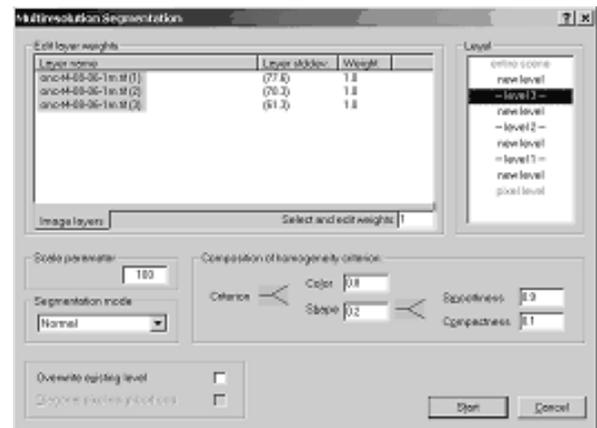
- Colunas 13 à 15: Terceiro nível de possibilidade de um objeto pertencer a uma determinada classe. Respectivamente, as colunas representam o nome da classe, a probabilidade do objeto pertencer a esta classe e a possibilidade do mesmo pertencer a esta classe;

Como já citado em outras partes deste texto a multissegmentação também traz grandes resultados na homogeneização das imagens a serem empregadas no processo de classificação. Para este trabalho foram utilizadas duas segmentações inter-relacionadas, uma utilizando um parâmetro de escala (ver página 46 – equação 1) de valor 35, e outra utilizando um parâmetro de escala de valor 100. Estas segmentações deram origem a dois planos de objetos inter-relacionados que foram utilizados respectivamente para a primeira classificação dos objetos e para o refinamento da classificação. As figuras 20 e 21 apresentam a tela de multissegmentação, dentro do ambiente do *E-Cognition*, bem como os campos para a manipulação dos parâmetros da multissegmentação.



Parâmetros utilizados:  
 Escala 35  
 Cor 0,7  
 Forma 0,3  
 Suavidade 0,7  
 Compactação 0,3

**Figura 20 – Primeira Segmentação**



Parâmetros utilizados:  
 Escala 100  
 Cor 0,8  
 Forma 0,2  
 Suavidade 0,9  
 Compactação 0,1

**Figura 21 – Segunda Segmentação**

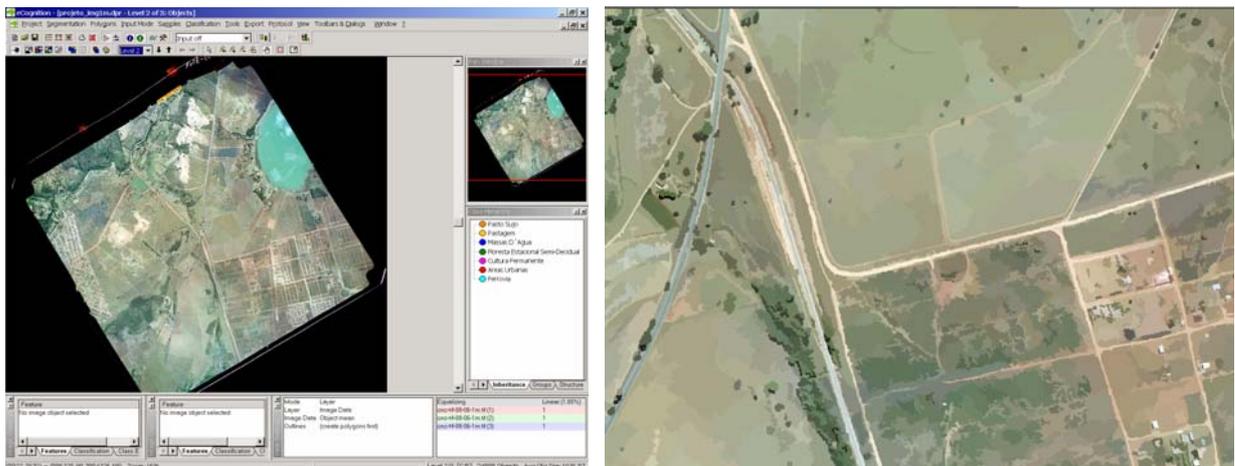
Na primeira segmentação, apesar do uso de um parâmetro de escala de valor relativamente alto, o objetivo era a suavização da imagem a partir de objetos mais homogêneos sem, contudo agregar muito os objetos, pois a partir desta primeira segmentação é que as primitivas seriam selecionadas para a composição dos objetos de treinamento do classificador.

Esta atividade seria mais facilitada caso fosse necessária somente a união das primitivas e não a desagregação das mesmas em objetos menores.

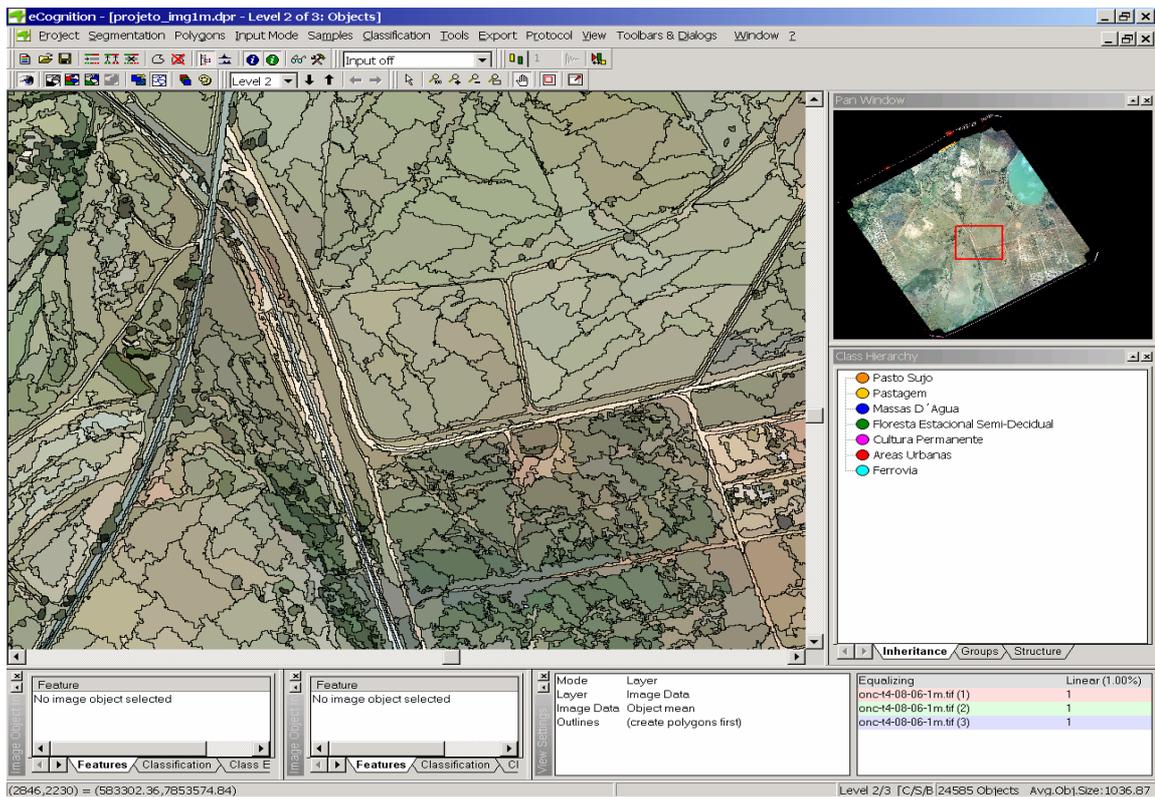
Já a segunda segmentação objetivou a criação de objetos bem suaves e homogêneos, tentando fazer com que a heterogeneidade inicial da imagem fosse diluída e os grandes domínios relativos aos temas de interesse pudessem estar mais claros numa primeira visão da imagem.

A figura 22 apresenta um extrato da porção da área total de testes, utilizada nos testes das etapas 1 e 2, no ambiente do *E-Cognition*.

A partir da segmentação com a utilização dos parâmetros elencados na figura 20, o primeiro nível de primitivas foi criado, dando origem a diversos objetos. Estes objetos estão exemplificados na figura 23.

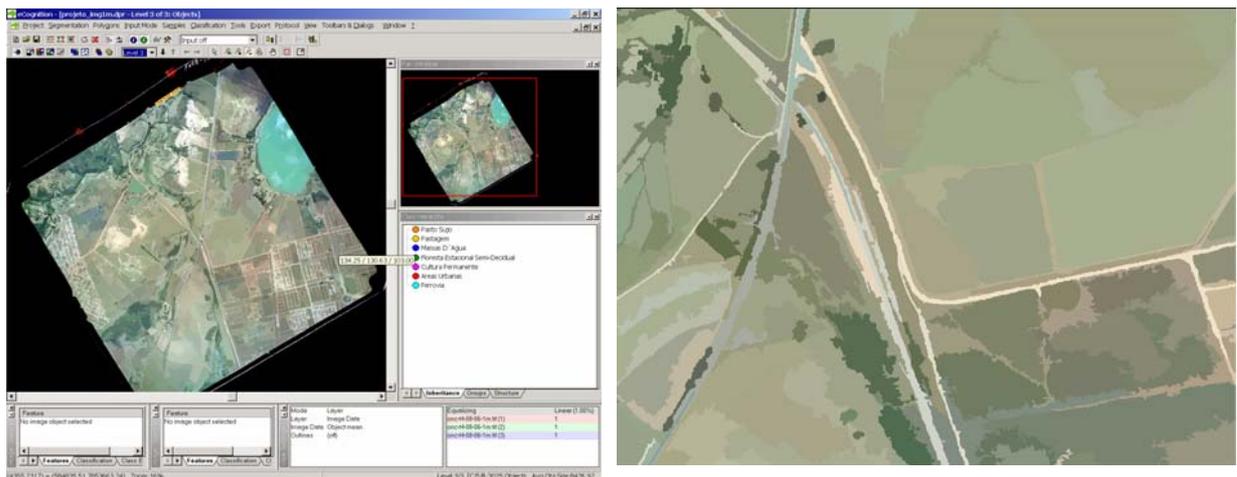


**Figura 22 - Imagem segmentada a partir do parâmetro de escala 35 – Duas Visões**

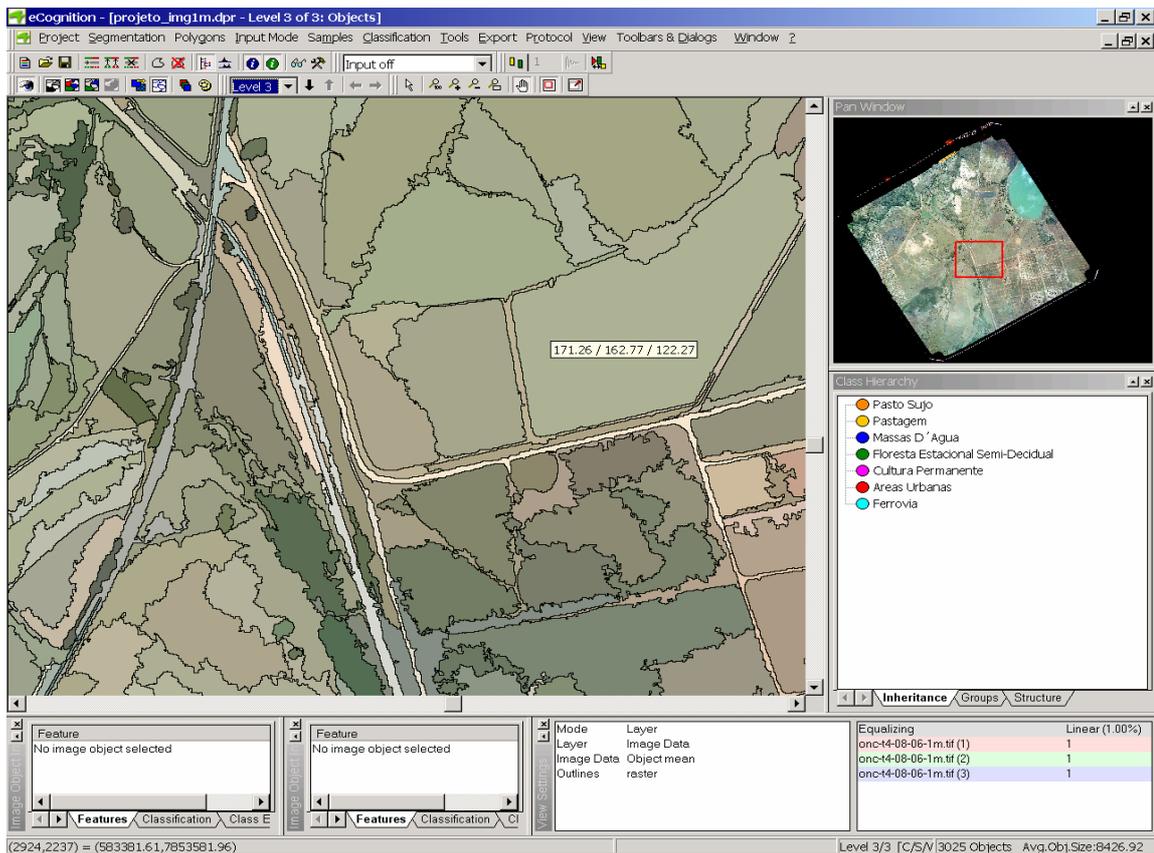


**Figura 23 - Objetos da segmentação - Escala 35**

As figuras 24 e 25 são homólogas as figuras 22 e 23 e apresentam respectivamente a imagem segmentada a partir dos parâmetros apresentados na figura 21 e os objetos criados a partir da imagem segmentada.



**Figura 24 - Imagem segmentada a partir do parâmetro de escala 100 – Duas Visões**



**Figura 25 - Objetos da segmentação - Escala 100**

Pela análise das figuras 23 e 25 pode-se claramente notar o decréscimo no número de objetos criados entre primeira segmentação, a escala 35, e a segunda segmentação gerada na escala de 100. O parâmetro de escala é um dos principais responsáveis pelo controle da homogeneização nas imagens segmentadas, dentro do *E-Cognition*. Sendo assim, pela adoção de um parâmetro de escala alto (100), foi possível a homogeneização da primeira imagem em objetos maiores, mais representativos dos padrões e arranjos geográficos dos objetos de interesse deste trabalho, ou seja, a cobertura vegetal e o uso da terra.

A segmentação a partir de um parâmetro de escala alto e gerado a partir de uma imagem já segmentada por um parâmetro de escala baixo possibilitou uma enorme homogeneização das áreas presentes na nova imagem segmentada. Com a imagem gerada, segmentada a partir do parâmetro de escala baixo, a heterogeneidade é maior e o número de objetos criados conseqüentemente também o é. Estes objetos, representados por regiões menores, tornam-se melhores para a escolha e seleção dos objetos que compoão os objetos-exemplo de treinamento da rede de classificação. Neste aspecto, foram selecionados poucos objetos como exemplos para cada uma das regiões de interesse, para que o classificador não imputasse na primeira iteração um número de incertezas grande para as observações classificadas. Da mesma forma, os objetos selecionados a partir da imagem segmentada foram tomados com

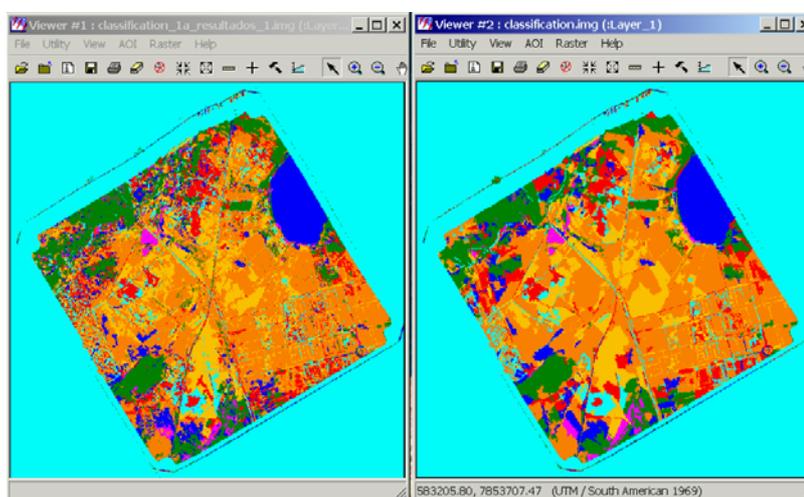
base no mapeamento temático gerado a partir do processo clássico, sendo que os polígonos selecionados tenderam a serem próximos em forma e área aos restituídos de forma manual.

Para a classificação da imagem segmentada no primeiro nível (escala 35) foram utilizadas 6 classes, sendo quatro referentes à cobertura vegetal e ao uso da terra, uma referente à infraestrutura, no caso a malha ferroviária, e uma referente à hidrografia, chamada de Massa D'água. As duas últimas classes foram utilizadas para auxiliar na caracterização do conhecimento aplicado às outras classes, bem como para diminuir o grau de incertezas da rede fuzzy para classes próximas. A tabela 6 mostra a quantidade de amostras utilizadas, para cada uma das imagens segmentadas, no processo de classificação fuzzy:

**Tabela 6 – Tabela de Classes Selecionadas**

Classe	Num. Amostras (35)	Num Amostras (100)
Cultura Perene	02	03
Ferrovias	02	02
Floresta Estacional Semi-Decidual	03	02
Massa D'água	03	02
Pastagem	04	02
Pasto Sujo	03	02

Com base nas amostras coletadas, a classificação foi executada primeiramente na imagem segmentada a partir do parâmetro de escala de valor baixo e os resultados desta classificação foram refinados, a partir da modificação por agregação, desagregação, inclusão e exclusão dos objetos de treinamento. Este refinamento foi aplicado à imagem segmentada a partir do parâmetro de escala de valor mais alto, dando origem às imagens classificadas apresentadas abaixo, na figura 26.



**Figura 26 – Classificação inicial e final respectivamente – E-Cognition**

Comparando-se a classificação final adquirida a partir do *E-Cognition*, com a classificação executada manualmente a partir da interpretação visual e processo clássico de vetorização pode-se chegar aos seguintes resultados, sumariados na tabela 7 apresentada a seguir:

**Tabela 7 – Resultado da Classificação no *E-Cognition***

Classe	Interpretação Visual	Num.Objetos Classificados E-Cognition	Erros	% Quantitativa	% Qualitativa
Cultura Perene	01	01	0	100 %	90 %
Floresta Estacional	09	08	01 (-)	89 %	75 %
Pastagem	10	08	02 (-)	80 %	72 %
Pasto Sujo	11	14	03 (+)	127 %	57 %

A porcentagem quantitativa expressa na tabela anterior, tabela 7, representa a proporção direta entre o número de objetos classificados a partir do *E-Cognition* e o número de objetos classificados a partir da interpretação visual. Da mesma forma, a porcentagem qualitativa expressa a relação entre as áreas calculadas em cima da base confeccionada pela interpretação visual e as mesmas calculadas sobre a nova base executada a partir do *E-Cognition*. O cálculo das áreas e sua manipulação em termos percentuais foi executada a partir do uso do software ArcMap.

Uma forma mais elegante de apresentar os resultados obtidos a partir do *E-Cognition* é a construção da matriz de erros ou a matriz de confusão para os resultados. Com o crescente uso de imagens de satélite para a construção de bases cartográficas e a necessidade da avaliação das precisões alcançadas a partir destes métodos, as matrizes de confusão tem se apresentado como o padrão para a avaliação destes resultados. A Tabela 8 apresenta a matriz de confusão para os resultados obtidos no *E-Cognition*.

**Tabela 8 – Matriz de Confusão - *E-Cognition***

	Cultura Perene	Floresta Estacional	Pastagem	Pasto Sujo	Total Linha
Cultura Perene	1	0	0	0	1
Floresta Estacional	1	9	0	0	10
Pastagem	1	0	10	1	12
Pasto Sujo	0	0	3	11	14
Total Coluna	3	9	13	12	37

Aplicando-se a divisão entre a soma da diagonal principal da matriz de erros, pelo total de registros da tabela tem-se a precisão total para a metodologia aplicada no *E-Cognition* de aproximadamente 84%.

Ainda, a matriz de confusão pode estabelecer a precisão de cada uma das classes adotadas, de forma individualizada, pela divisão da célula da diagonal principal em cada uma das colunas da matriz pelos seus totais de linhas ou colunas. Neste trabalho, dado o ponto de vista do usuário em estar utilizando os resultados da metodologia proposta, estará sendo utilizada a divisão dos registros individuais da diagonal principal pelos somatórios das linhas de cada uma das classes adotadas. As precisões individuais de cada uma das classes possuem os seguintes valores:

Cultura Perene	100,00%
Floresta Estacional	90,00%
Pastagem	83,33%
Pasto Sujo	78,57%

Estes resultados apresentam-se promissores, porém, como foram aplicados somente a área de testes dos segmentos 1 e 2, menor que a área total de testes (mosaico total do trecho 04 - aproximadamente 500 Km<sup>2</sup>), estes resultados serão comparados, no segmento 3, aos resultados obtidos a partir da utilização do *Erdas Imagine* no segmento 2. Caso os resultados desta metodologia, segmento 1, se apresentem melhores que os resultados obtidos no segmento 2, a partir do *Erdas Imagine*, a metodologia vencedora ainda será aplicada a toda a área de interesse e os resultados comparados em termos de tempo com o esforço gasto a partir do processo tradicional.

Para os testes do segmento 1, com a ortofoto 06 da faixa 08 do trecho 04 (Belo Horizonte-Sete Lagoas), foi utilizado um equipamento com as seguintes configurações:

Processador: Athlon AMD XP 2Ghz

Memória: 1024 Mb de memória RAM

Pl. de Vídeo: NVIDIA GeForce FX 5200 com 128Mb de memória dedicada

Discos: 2 Hds de 7200 RPM sendo um de 40Gb e outro de 120Gb

## 5.2. Resultados Alcançados – Erdas Imagine

No *Erdas Imagine* a segmentação implementada seguindo o modelo apresentado pela USDA apresentou bons resultados no sentido da homogeneização da imagem de entrada. Porém, a falta de um conceito de rede semântica de relacionamento dos objetos durante o processo de classificação fez com que a classificação fuzzy a partir do módulo “*knowledge engineer*” não fosse tão eficiente quanto a apresentada no ambiente do *E-Cognition*. Apesar do “*knowledge engineer*”, da mesma forma que o *E-Cognition*, rotular os objetos segmentados a partir de possibilidades e probabilidades dos mesmos pertencerem a uma ou mais classes, a falta de parâmetros espaciais no processo de segmentação implementado no *Erdas Imagine* fez com que os objetos de seu nível de primitivas não possuíssem inter-relacionamentos. Sendo assim, cada objeto é analisado no processo de classificação de forma isolada e não de forma contextualizada como acontece no ambiente do *E-Cognition*.

Shape	ID	Red	Green	Blue	BestClass	BestClass1	BestMember	SecondClass	SecondCl 1	SecondMem	ThirdClass	ThirdCla 1	ThirdMembe
Polygon	0	128	128	128	Areas Urbanas	6	0.88	Ferrovia	7	0.87	Pastagem	2	0.64
Polygon	1	0	0	255	Massas D'Aqua	3	0.38	Areas Urbana	6	0.2	Ferrovia	7	0.15
Polygon	2	0	255	0	Pastagem	2	0.84	Ferrovia	7	0.77	Areas Urbana	6	0.75
Polygon	3	0	128	128	Floresta Estacio	4	0.38	unclassified	-1	0	unclassified	-1	0
Polygon	4	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	5	128	128	128	Areas Urbanas	6	0.95	Ferrovia	7	0.89	Pastagem	2	0.49
Polygon	6	255	255	0	Pasto Sujo	1	0.57	Floresta Estac	4	0.49	Areas Urbana	6	0.32
Polygon	7	128	128	128	Areas Urbanas	6	0.52	Pasto Sujo	1	0.45	Floresta Estac	4	0.4
Polygon	8	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	9	128	128	128	Areas Urbanas	6	0.7	Ferrovia	7	0.6	Massas D'Aq	3	0.56
Polygon	10	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	11	0	255	0	Pastagem	2	0.81	Areas Urbana	6	0.79	Pasto Sujo	1	0.76
Polygon	12	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	13	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	14	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	15	0	128	128	Floresta Estacio	4	0.37	Pasto Sujo	1	0.11	unclassified	-1	0
Polygon	16	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	17	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	18	0	0	255	Massas D'Aqua	3	0.33	Areas Urbana	6	0.16	Ferrovia	7	0.12
Polygon	19	0	128	128	Floresta Estacio	4	0.13	unclassified	-1	0	unclassified	-1	0
Polygon	20	0	0	255	Massas D'Aqua	3	0.42	Areas Urbana	6	0.25	Ferrovia	7	0.19
Polygon	21	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	22	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	23	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	24	0	128	128	Floresta Estacio	4	0.43	Pasto Sujo	1	0.23	Areas Urbana	6	0.13
Polygon	25	0	128	128	Floresta Estacio	4	0.59	Pasto Sujo	1	0.19	unclassified	-1	0
Polygon	26	128	128	128	Areas Urbanas	6	0.91	Ferrovia	7	0.9	Pastagem	2	0.59
Polygon	27	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	28	0	0	0	unclassified	-1	0	unclassified	-1	0	unclassified	-1	0
Polygon	29	0	128	128	Floresta Estacio	4	0.63	Pasto Sujo	1	0.23	unclassified	-1	0

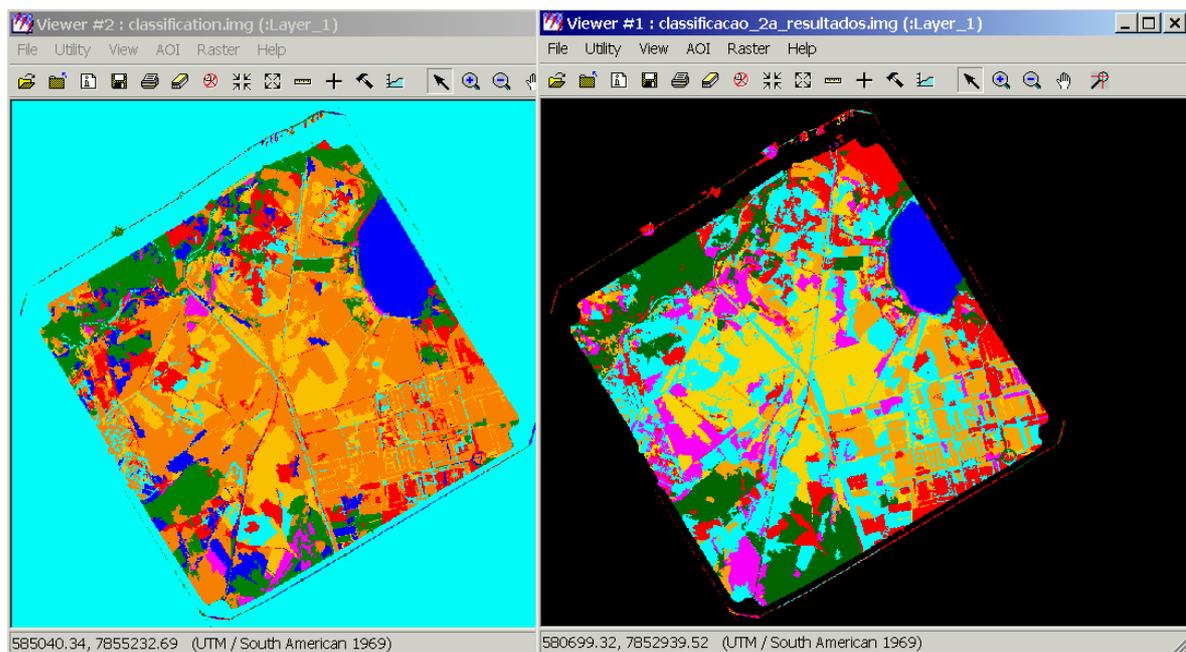
Figura 27 – Tabela de relacionamento dos objetos - Ecognition

Layer	Band	FILE PIXEL	LUT VALUE	HISTOGRAM	Red	Green	Blue	Opacity	Class_Names
1		4.000	113.000	2108139.000	1.00	0.84	0.00	1.00	Pastagem
2		3.000	85.000	1964423.000	1.00	0.00	1.00	1.00	Cultura Perene
3		9.000	255.000	2599794.000	0.00	1.00	1.00	1.00	Ferrovia

Figura 28 – Tabela de relacionamento dos objetos – Erdas Imagine

Analisando a figura 28 pode-se notar que no *Erdas Imagine* o objeto possui a possibilidade de figurando em 3 classes distintas como acontece no ambiente do *E-Cognition*. Porém o mesmo objeto não possui a probabilidade, representada na tabela de atributo dos objetos, figura 27, pelas colunas “*BestMember*”, de pertencer a uma dada classe para cada uma das classes possíveis. Isto significa dizer que, apesar da classificação no ambiente do *Erdas Imagine* ter sido realizada a partir de um conceito de lógica fuzzy, o resultado da classificação, expresso a partir da figura 28, não pôde ser refinado, como feito dentro do *E-Cognition*, a partir do estabelecimento de graus de pertinência.

O processo de refinamento da primeira classificação dentro do *Erdas Imagine*, a despeito da impossibilidade citada acima da filtragem de objetos por graus ou intervalos de probabilidade de um objeto pertencer a uma classe, foi executado da mesma forma que no *E-Cognition*, a partir da modificação por agregação, desagregação, inclusão e exclusão dos objetos de treinamento, dentro do módulo “*signature editor*” dando origem à imagem classificada apresentada na figura 29 em comparação a imagem classificada a partir do *E-Cognition*.



**Figura 29 – Classificação final no *E-Cognition* e no *Erdas Imagine* respectivamente**

Comparando-se a classificação final adquirida a partir do *Erdas Imagine*, com a classificação executada manualmente a partir da interpretação visual e processo clássico de vetorização pode-se chegar aos seguintes resultados, sumariados na tabela 9, a seguir:

**Tabela 9 – Resultado da Classificação no *Erdas Imagine***

Classe	Interpretação Visual	Num.Objetos Classificados E-Cognition	Erros	% Quantitativa	% Qualitativa
Cultura Perene	01	03	02 (+)	300 %	40 %
Floresta Estacional	09	06	03 (-)	66 %	58 %
Pastagem	10	14	04 (+)	140 %	42 %
Pasto Sujo	11	18	07 (+)	63 %	37 %

Da mesma forma que para o segmento 1 dos testes, pode-se construir a matriz de confusão para os resultados obtidos no *Erdas Imagine* de maneira a caracterizar sua precisão global e por classe. A Tabela 10 apresenta a matriz de confusão para os resultados obtidos no *Erdas Imagine*.

**Tabela 10 – Matriz de Confusão – *Erdas Imagine***

	Cultura Perene	Floresta Estacional	Pastagem	Pasto Sujo	Total
Cultura Perene	1	0	2	0	<b>3</b>
Floresta Estacional	3	9	0	0	<b>12</b>
Pastagem	1	0	10	3	<b>14</b>
Pasto Sujo	2	0	5	11	<b>18</b>
<b>Total Coluna</b>	<b>7</b>	<b>9</b>	<b>17</b>	<b>14</b>	<b>47</b>

A precisão total para a metodologia aplicada no *Erdas Imagine* é de aproximadamente 66%. Ainda, as precisões individuais de cada uma das classes possuem os seguintes valores:

Cultura Perene	33,33%
Floresta Estacional	75,00%
Pastagem	71,43%
Pasto Sujo	61,11%

Para os testes do segmento 2, com a ortofoto 06 da faixa 08 do trecho 04 (Belo Horizonte-Sete Lagoas), foi utilizado um equipamento com as seguintes configurações:

Processador: Athlon AMD XP 2Ghz

Memória: 1024 Mb de memória RAM

Pl. de Vídeo: NVIDIA GeForce FX 5200 com 128Mb de memória dedicada

Discos: 2 Hds de 7200 RPM sendo um de 40Gb e outro de 120Gb

### 5.3. Análise Relativa - *E-Cognition* Vs. Erdas Imagine

Como já adiantado ao longo dos dois primeiros segmentos deste capítulo, a multissegmentação do *E-Cognition* agrega um valor maior ao processo de classificação, a partir da criação da rede de hierarquização dos objetos e da análise espacial possibilitada por essa hierarquização.

Apesar dos resultados obtidos, no processo de classificação, pelos dois softwares terem apresentado uma boa resposta, a comparação das tabelas de desempenho quantitativo e qualitativo das classificações efetuadas apresenta vantagem para a solução implementada no ambiente do *E-Cognition*, conforme pode ser observado na tabela 11 abaixo.

**Tabela 11 – Comparação entre os resultados da Classificação – *E-Cognition* Vs. Erdas Imagine**

Classe	Interpretação Visual	% Quantitativa <i>E-Cognition</i>	% Quantitativa Erdas Imagine	% Qualitativa <i>E-Cognition</i>	% Qualitativa Erdas Imagine
Cultura Perene	01	100 %	300 %	90 %	40 %
Floresta Estacional	09	89 %	66 %	75 %	58 %
Pastagem	10	80 %	140 %	72 %	42 %
Pasto Sujo	11	127 %	63 %	57 %	37 %

Da mesma forma, a análise das matrizes de confusão para os testes dos segmentos 1 e 2 apresenta a vantagem da metodologia aplicada no ambiente do *E-Cognition* ao do *Erdas Imagine*.

**Tabela 12 – Comparação das Matrizes de Confusão – *E-Cognition* Vs. *Erdas Imagine***

<b>Classe</b>	<b>% <i>E-Cognition</i></b>	<b>% <i>Erdas Imagine</i></b>
Cultura Perene	100,00%	33,33%
Floresta Estacional	90,00%	75,00%
Pastagem	83,33%	71,43%
Pasto Sujo	78,57%	61,11%
<b>Precisão Global</b>	<b>83,78%</b>	<b>65,96%</b>

Em função do melhor rendimento apresentado pelo software *E-Cognition*, toda a metodologia descrita anteriormente foi implementada novamente nesta plataforma, porém, não mais em uma ortofoto isolada, mas sim em toda a base de dados existente para o trecho 04, remontando aproximadamente 500 Km<sup>2</sup> e 40 Gb de dados de imagem.

Após a aplicação da metodologia proposta à base de dados completa, os resultados alcançados apresentaram-se com um menor grau de sucesso em relação aos resultados apresentados nos testes do segmento 1, representados pela tabela 7 anteriormente apresentada. Os novos resultados para a avaliação de toda a área de teste referente ao trecho 04 do Projeto FERROVIAS podem ser traduzidos a partir da tabela 10 apresentada abaixo:

**Tabela 13 – Novos Resultados da Classificação no *E-Cognition* – Área Total**

<b>Classe</b>	<b>Interpretação Visual</b>	<b>Num.Objetos Classificados <i>E-Cognition</i></b>	<b>Erros</b>	<b>% Quantitativa</b>	<b>% Qualitativa</b>
Cultura Perene	47	51	04 (+)	108 %	83 %
Floresta Estacional	374	331	43 (-)	88 %	67 %
Pastagem	273	225	48 (-)	83 %	57 %
Pasto Sujo	318	417	99 (+)	131 %	43 %

Novamente, a matriz de confusão para os resultados relativos a toda a área de testes são apresentados na tabela 14, a seguir:

**Tabela 14 – Matriz de Confusão para a Área Total de Testes – *E-Cognition***

	Cultura	Floresta		Pasto	Total
	Perene	Estacional	Pastagem	Sujo	Linha
Cultura Perene	47	0	4	0	51
Floresta Estacional	23	374	0	20	417
Pastagem	32	4	273	12	321
Pasto Sujo	45	5	49	318	417
<b>Total Coluna</b>	<b>147</b>	<b>383</b>	<b>326</b>	<b>350</b>	<b>1206</b>

Mesmo com o incremento significativo de novas áreas e do número de objetos, os novos resultados da metodologia aplicada ao *E-Cognition* apresentaram-se promissores para a utilização de um processo automático de extração de feições na construção de bases de dados cartográficas. A tabela 15 apresenta a comparação final entre os resultados das matrizes de confusão das etapas 1, 2 e 4, respectivamente os testes com o *E-Cognition* na área de 50 Km<sup>2</sup>, os testes com o *Erdas Imagine* na área de Km<sup>2</sup> e os testes com o *E-Cognition* para a área de 500 Km<sup>2</sup>.

**Tabela 15 – Comparação entre os resultados das Matrizes de Confusão**

	Etapa 1	Etapa 2	Etapa 4
Classe	% <i>E-Cognition</i> (50 km <sup>2</sup> )	% <i>Erdas Imagine</i> (50 km <sup>2</sup> )	% <i>E-Cognition</i> (500 km <sup>2</sup> )
Cultura Perene	100,00%	33,33%	92,15%
Floresta Estacional	90,00%	75,00%	89,68%
Pastagem	83,33%	71,43%	85,04%
Pasto Sujo	78,57%	61,11%	76,25%
<b>Precisão Global</b>	<b>83,78%</b>	<b>65,96%</b>	<b>80,91%</b>

#### 5.4. Resultados Finais – EAFC Vs. Processo Convencional

Para a caracterização dos resultados finais obtidos a partir da utilização do *E-Cognition* comparativamente aos números de produção da base de dados existente, confeccionada a partir do processo convencional de interpretação visual e vetorização manual, é necessário primeiramente que sejam apresentados os números referentes à produção convencional. A tabela 11 apresenta um resumo dos principais números de produção de dados geográficos levantados junto às equipes de gerenciamento de projeto da CVRD para a análise e comparação com os esforços produtivos despendidos a partir do *E-Cognition*.

**Tabela 16 – Quantitativo de esforços do Projeto FERROVIAS – Processo Convencional**

<b>Código</b>	<b>Unidades</b>	<b>Quantidades</b>
01	Código do Trecho	Trecho 04
02	Quantidade de Faixas	08
03	Quantidade de Fotos	139
04	Quantidade de Km <sup>2</sup>	500 km <sup>2</sup>
05	Total de Operadores envolvidos	10
06	Total de Dias trabalhados / Mês	22 dias
07	Total de Horas trabalhadas / Dia	06 horas
08	Total de horas gastas na produção do Trecho 04	500 horas
09	Total de Dias gastos na produção do Trecho 04	8 dias

Devido a uma restrição do E-Cognition em processar imagens de tamanho grande, fato experimentado ainda durante os testes dos segmentos 1 e 2 onde foi utilizada uma área correspondente a 2% da área total dos testes do segmento 4, o ortofotomosaico de 40GB foi dividido em 38 pedaços regulares de aproximadamente 350 MB de tamanho cada um. O formato utilizado continuou sendo o formato Tiff não comprimido por ser o formato de intercâmbio universal de imagens entre softwares de processamento de imagens.

Cada um dos mosaicos demorou em média 3h para cada uma das segmentações (2) e posterior vetorização ou criação do nível das primitivas, além de mais 30 minutos para a classificação das imagens segmentadas. O refinamento do processo de classificação demorou mais uma hora para a edição dos objetos de treinamento e reclassificação.

Desta forma, cada mosaico demorou aproximadamente 7 horas e 30 minutos para sua segmentação, criação do nível das primitivas, classificação e refinamento. Isto remonta, para a soma dos 38 ortofotomosaicos recortados, um total de 285 horas. Voltando a tabela 11 pode-se notar que a metodologia aplicada a partir do E-Cognition foi 43% mais rápida do que os processos convencionais, que consumiram 500 horas de operadores para a execução total do trecho 04.

Caso a metodologia adotada fosse comparada a produção de um único operador para a execução do mesmo trecho, o processo automatizada leva vantagens sobre um único operador. Colocando-se ambas as horas gastas na produção, 6 horas por dia, a metodologia aplicada ao *E-Cognition* levaria 48 dias para a execução de toda a tarefa, enquanto um único operador levaria 83 dias para a execução de todo o trecho.

Entretanto, devido à quantidade de imprecisões alcançada pelo processo automático de extração de feições, a classificação resultante teve de ser re-trabalhada para que os problemas

de super e sub-classificação pudessem ser corrigidos, bem como a geometria dos polígonos gerados ser retificada.

Para esta correção, a base de dados resultante foi entregue a um operador que participou da produção da interpretação temática do trecho escolhido dentro da CVRD, utilizando o processo tradicional de vetorização manual. Um operador envolvido no processo foi escolhido para efetivamente a produção de correção da base gerada pelo processo automático tivesse a mesma produtividade que a apresentada na tabela 16. A correção do material produzido automaticamente foi feita de forma manual e este operador gastou mais 100 horas para a correção de toda a base de dados, aumentando o total de 285 horas para 385 horas de trabalho para a execução do trecho, aproximadamente 64 dias, na base de um operador trabalhando 6 horas por dia.

Estes números não provam a superioridade do processo de extração de feições de forma automatizada, frente aos processos clássicos de vetorização ou restituição de feições, tendo em vista que os resultados das comparações efetuadas foram apresentados na base da utilização de um operador humano apenas para a execução dos mesmos processos feitos automaticamente. Entretanto, estes resultados provam de forma clara a viabilidade atual dos processos automatizados nas atividades de classificação e extração de feições cartográficas. Principalmente no caso do *E-Cognition* os resultados desta pesquisa indicam que o mesmo agrega um enorme valor ao processo de classificação e EAFC a partir da inserção da técnica de segmentação baseada na multivariação.

## CAPÍTULO 6 – CONCLUSÕES E SUGESTÕES

A partir de todas as informações obtidas durante a pesquisa bibliográfica, desenho e definição da metodologia adotada neste trabalho e o efetivo teste a partir dos softwares em questão, *E-Cognition* e *Erdas Imagine 8.7*, várias conclusões puderam ser extraídas dos resultados alcançados.

### 6.1. A Resolução das Imagens Digitais

Efetivamente, a resolução espacial das imagens digitais é um condicionante dentro do processo de extração automática de feições. A maior resolução espacial característica das fotografias aéreas e imagens de alta resolução, basicamente dá origem a dois fenômenos ou fatores que podem ser considerados como complicadores, dentro do processo de EAFC, quais sejam, o grande tamanho das imagens como no caso do mosaico utilizado para a área de teste e a enorme heterogeneidade radiométrica presente nas imagens de alta resolução.

Nas imagens de baixa e média resolução, ao analisar-se o histograma das mesmas, é fácil notar que a variação da frequência das mesmas é pequena perto das frequências radiométricas das imagens de alta resolução que chegam a alcançar milhões de ocorrências por nível de cinza.

Desta forma, a etapa de segmentação do dado de entrada, ou seja, a imagem digital, torna-se condição essencial para que estes fatores possam ser minimizados na fase de classificação das imagens digitais.

### 6.2. A Segmentação de Imagens Digitais

O processo de segmentação, como visto ao longo deste texto, pode assumir várias nuances segundo a forma como se pretende extrair os objetos e segundo os objetos que se deseja extrair. Caso a forma como se pretenda extrair um determinado objeto seja baseada num conhecimento prévio do comportamento deste objeto e conseqüentemente de um modelo matemático e estatístico que melhor o possa representar, está se trabalhando no domínio dos sistemas “*top-down*” e o esforço computacional para o processo de segmentação é reduzido tendo em vista que o algoritmo irá procurar em toda a imagem digital pela ocorrência do

determinado padrão modelado. Esta abordagem, porém, somente registrará ou segmentará os objetos que estejam consoantes com o modelo matemático proposto.

No caso deste trabalho, ou seja, os sistemas chamados “*bottom-up*”, não se possui o conhecimento dos padrões comportamentais dos objetos a serem extraídos. Este é o caso de pesquisas em áreas geográficas “novas”, isto é, onde não exista cartografia de base ou outras bases de dados para a criação de um modelo de conhecimento para a área em questão. A EAFC para estes tipos de situações requer do algoritmo de segmentação um esforço computacional muito maior, pois o mesmo terá de calcular as possibilidades e probabilidades de todo o espaço dimensional da imagem digital.

A partir dos testes efetuados entre as soluções baseadas nos softwares *E-Cognition* e Erdas Imagine 8.7, a segmentação de imagens digitais a partir do algoritmo de multisegmentação apresenta resultados superiores àqueles efetuados a partir de segmentação baseada somente em um parâmetro como no caso da implementação no Erdas Imagine 8.7, onde somente foi levado em consideração o valor da radiometria de cada pixel e a agregação dos mesmos segundo uma distância baseada no “*threshold*” ou no limiar do valor radiométrico entre dois pixels adjacentes.

A multisegmentação, a partir dos resultados alcançados parece ser um caminho promissor para agregar valor ao processo de EAFC em imagens digitais de alta resolução, principalmente fotografias aéreas. Informações adicionais sobre este assunto podem ser obtidas em Baatz & Schape<sup>[14]</sup>.

### 6.3. A Classificação das Imagens Digitais

Devido a enorme heterogeneidade das imagens de alta resolução, principalmente das oriundas da digitalização de fotografias aéreas, os processos de classificação baseados apenas nos valores de cinza dos pixels destas imagens não são suficientes para a aplicação de métodos de EAFC. Segundo os resultados dos testes apresentados, tanto os processos de classificação não supervisionada quanto os de classificação supervisionada, baseados somente na radiometria da imagem digital não foram suficientes para caracterizar, num nível maior de confiança, a interpretação temática da base de dados utilizada para o teste em questão.

A incorporação da lógica fuzzy ao processo de classificação supervisionada, como no caso desta dissertação, traz grandes ganhos ao processo como um todo. Mais ainda, a partir da adoção da lógica fuzzy ou da “fuzzificação” dentro do processo de classificação do *E-Cognition* foi possível a criação de uma rede de relacionamento dos objetos criados na fase de multisegmentação.

Esta rede de relacionamentos, que atribuiu graus de pertinência a cada um dos objetos criados na camada de segmentação, tornou possível a classificação de um objeto em mais de uma classe simultaneamente. Dentro de um processo de classificação não baseado em lógica fuzzy um dado objeto seria classificado de uma maneira binária, ou seja, seria classificado em uma categoria correta ou em outra incorreta. A partir da adoção do modelo fuzzy no processo de classificação, o mesmo objeto pode ser classificado a partir de graus de pertinência maiores ou menores, ou seja, a inclinação do mesmo, em se enquadrar a uma determinada classe ou não.

De posse destas informações se torna muito mais fácil ao usuário estabelecer intervalos de confiança para cada uma das categorias a serem alcançadas, respeitando-se as complexidades e heterogeneidades dos objetos a estarem presentes nas categorias. Como exemplo pode-se citar neste trabalho a presença das classes Pastagem e Pasto Sujo. A classe de Pastagem normalmente apresenta-se como um classe bastante homogênea e a filtragem da mesma pode ser feita a partir de intervalo de confiança alto, acima dos 80% de possibilidade de um objeto pertencer a esta classe. Já o Pasto Sujo, caracterizado pela presença de outras classes em sua área, é uma classe extremamente heterogênea que não pode ser filtrada somente por um intervalo de confiança alto, que expressa a integridade da classificação. Para tanto foi utilizada a filtragem a partir de áreas menores que 1 a 4 m<sup>2</sup> e a reagregação da classificação para que os pastos sujos, pela representação de seus objetos, se tornassem mais homogêneos. Ainda existem outras técnicas como as baseadas em redes neurais para o treinamento e aprimoramento de redes de classificação. Porém, as mesmas não foram mais explicitamente citadas ao longo deste texto, pois as mesmas dão sua maior contribuição primeiramente aos sistemas “*top-down*” onde uma modelagem mais intensa dos objetos a serem extraídos se faz mais necessária e em aplicações de detecção de mudanças onde, a partir de séries históricas, temporais ou comportamentais, a rede de treinamento possui conjuntos de dados de aprendizado capazes de alimentar as redes neurais e seu aprendizado.

#### 6.4. A EAFC e o Processo de Produção Cartográfica

Pelo aspecto do tempo de execução, o processo de EAFC dos 38 mosaicos de imagens existentes para as áreas teste se mostrou mais rápido que os processos convencionais, baseados na interpretação visual e na vetorização manual dos temas de interesse. A diferença de 33 dias entre um processo e outro parece dar ampla vantagem para o processo automático de extração de feições. Porém, a análise quantitativa e qualitativa dos resultados finais mostra que a saída bruta dos resultados, antes da revisão dos mesmos, apresenta erros de super e sub-

classificação e de edição de forma de polígonos, os quais representam mais 17 dias no fluxograma de trabalho da EAFC ou quase que 30% a mais do número de dias necessários para a classificação totalmente automatizada das imagens. Mesmo assim, o desempenho em termos produtivos do processo de EAFC dos temas propostos comparados ao desempenho de produção de apenas um operador humano desempenhando a mesma atividade para todo o trecho selecionado como área de teste deste projeto apresentou uma superioridade de 13 dias, ou seja, um ganho de produção de 20% do tempo entre o processo automatizado mais bem sucedido e o processo convencional.

Devido aos prazos de execução de projetos desta natureza, um maior número de operadores pode ser empregado para o alcance de maior produtividade. Na mesma linha de raciocínio tecida anteriormente, o emprego de dois operadores para a execução da área de teste diminuiria de 80 para 40 dias o tempo total de execução da área de teste. Entretanto, para que o mesmo raciocínio fosse empregado no aumento da produtividade do processo automatizado de extração de feições de interesse, licenças adicionais deveriam ser adquiridas.

Tendo em vista o valor da hora paga a um técnico de edição cartográfica, operador deste tipo de atividades, o investimento no aumento do efetivo humano torna-se muito menos dispendioso que a compra de novas licenças do *E-Cognition* para o incremento da produção automatizada. Este raciocínio procede, pois o investimento em hardware seria idêntico para a compra de um equipamento para ser operado por um segundo operador ou para a execução de uma segunda licença em modo concorrente com a primeira.

Um raciocínio contrário baseado não mais na área total, mas sim na primeira ortofoto utilizada como gabarito para os ensaios referentes ao processo metodológico adotado para este trabalho (a ortofoto 06 da faixa 08) mostra que, para áreas menores, no caso da ortofoto citada uma área de aproximadamente nove km<sup>2</sup>, o processo automatizado de extração de feições não apresenta ganhos de produtividade em relação ao processo convencional. Utilizando-se a mesma métrica de produção, um operador executa a interpretação e vetorização de uma área de 9 Km<sup>2</sup> em aproximadamente 9 horas enquanto que o processo de EAFC baseado no *E-Cognition* leva 7 horas e 30 minutos para os resultados finais refinados sem as correções manuais provenientes da re-edição.

## 6.5. Sugestão para Trabalhos Futuros

Os resultados apresentados mostram que, além da multisegmentação ser um caminho promissor no aumento da eficiência na extração de feições de forma automática, a EAFC

também se apresenta como um caminho em fase de maturação para o aumento da eficiência no processo de produção cartográfica.

Apesar deste trabalho ter se fixado a um pequeno número de classes e a dois temas específicos, a cobertura vegetal e o uso do solo, os resultados apresentados mostraram uma tendência positiva da aplicação deste tipo de metodologia a pequenos projetos cartográficos.

Devido aos altos preços praticados pelos fornecedores de mercado na comercialização de softwares do tipo dos empregados nesta dissertação muitas empresas ainda não investem em pesquisas nesta linha e mantêm seus investimentos no emprego de um maior número de mão de obra especializada, principalmente para grandes projetos.

Há que se ressaltar ainda que o material humano se torna cada vez mais indispensável aos processos de EAFC, tanto na fase de preparo das estratégias metodológicas quanto na fase final de revisão dos resultados. Esta necessidade é bastante similar à própria necessidade da cartografia, a partir de seus profissionais, ao início e final de grandes projetos de engenharia, onde primeiramente se deve conhecer a fundo a região onde se pretende implantar um dado empreendimento e ao final visitar a implantação e medir o grau de aderência das determinações da fase de projeto à realidade executada. Entretanto a especialização necessária para o envolvimento destes profissionais ao processo de EAFC cria naturalmente uma barreira muitas vezes difícil de ser transposta.

Para tanto, além do aprofundamento técnico e metodológico necessário ao desenvolvimento dos processos de EAFC estão também o aumento numérico de pesquisas no Brasil e maior divulgação de resultados, satisfatórios ou não, para que novas pesquisas possam ser direcionadas para as melhores práticas ou desviadas de caminhos de insucesso.

Como sugestões para trabalhos futuros esta dissertação destaca ainda a necessidade de pesquisas a partir de duas linhas de ação distintas: A primeira, devido à diversidade de padrões temáticos existentes no Brasil para a parte de cobertura vegetal, poderia ser estendida aos moldes da metodologia apresentada neste trabalho para diferentes áreas geográficas compreendendo os principais padrões temáticos existentes no País de forma a caracterizar a viabilidade desta metodologia para qualquer área de interesse no Brasil. A segunda, devido ao grande número de temas de interesse na produção cartográfica não só vinculada ao apoio a projetos de cunho ambiental mas também a produção de bases cartográficas em suporte a atividades de cadastro e outras, poderia ser estendida para outras classes de objetos, principalmente para os chamados “man-made” ou construídos pelo homem como no caso de Edificações e Sistemas Viários que como apresentados ao longo da revisão bibliográfica desta dissertação apresentam-se com um alto grau de interesse por parte da comunidade científica mundial.

Tendo em vista especificamente a motivação desta dissertação na criação de instrumentos que possibilitem uma maior agilidade na confecção e análise de dados para fins ambientais, os resultados obtidos para ambas as metodologias, independentemente da necessidade de re-trabalhos, apresentada ao longo do texto, sinalizam positivamente para a adoção da EAFC como uma forma confiável de geração de bases de conhecimento e análise de projetos ambientais de forma rápida e de baixo custo, tendo em vista que os graus de confiança ou precisão conseguidos pela adoção da metodologia proposta asseguram análises robustas sem a necessidade de inspeções aos locais dos projetos.

# REFERÊNCIAS BIBLIOGRÁFICAS

## Livros

- [1] AGOURIS, P.; GRUEN, A.; KUEBLER, O. Automatic Extraction of Man-Made Objects from Aerial and Space Images. Berlin: Birkhäuser, 1995. 321 p.
- [2] AGUADO, A.; NIXON, M. Feature Extraction & Image Processing. Oxford: Newnes, 2002. 350 p.
- [3] BETHEL, J.S.; McGLONE, J.C.; MIKHAIL, E.M. Introduction to Modern Photogrammetry. EUA: John Wiley & Sons, Inc., 2001. 479 p.
- [4] DEWITT, B.A.; WOLF, P.R. 3a ed. Elements of Photogrammetry. EUA: McGraw-Hill, 2000. 608 p. American Society for Photogrammetry and Remote Sensing, 1994. 413 p.
- [5] FENSTERMARKER, K.L. Remote Sensing Thematic Accuracy Assessment: A Compendium:
- [6] GRAHAM, R. Digital Imaging. Malta: Whittles Publishing Services, 1998. 212 p.
- [7] GREVE, C. Digital Photogrammetry: An Addendum to the Manual of Photogrammetry. Maryland: American Society for Photogrammetry and Remote Sensing, 1996. 247 p.
- [8] KIEFER, R.W.; LILLESAND, T.M. 4a ed. Remote Sensing and Image Interpretation. EUA: John Wiley & Sons, Inc., 2000. 724 p.
- [9] SCHENK, T. Digital Photogrammetry. Ohio: TerraScience, 1999. 428 p. (vol. 1)

## Documentos Publicados na Internet

- [10] AGGARWAL, J. K. et al. A comparative study of three paradigms for object recognition - Bayesian statistics, neural networks and expert systems. Disponível em: [http://www.lans.ece.utexas.edu/papers/festschrift\\_bookch96.ps.Z](http://www.lans.ece.utexas.edu/papers/festschrift_bookch96.ps.Z). Acesso em: 21 de fev. 2005.
- [11] ALBUQUERQUE, M. P. ;ALBUQUERQUE, M. P. Processamento de Imagens: Métodos e Análises. Disponível em: <http://www.cbpf.br/cat/download/publicacoes/pdf/ProcessamentoImagens.PDF>. Acesso em: 21 de fev. 2005.
- [12] ANDRADE, A. F. ;BOTELHO M. F. Classificação de imagens de alta resolução integrando variáveis espectrais e forma utilizando redes neurais artificiais. Disponível em:

[http://lagavulin.ltid.inpe.br:1905/col/ltid.inpe.br/sbsr/2003/03.27.11.57/doc/02\\_182.PDF](http://lagavulin.ltid.inpe.br:1905/col/ltid.inpe.br/sbsr/2003/03.27.11.57/doc/02_182.PDF).

Acesso em: 21 de fev. 2005.

[13] ARMENAKIS, C. A semi-automated approach for the recognition and extraction of water features from Landsat 7 imagery in northern Canada. Disponível em:

[http://dipa.spatial.maine.edu/NG2I03/CD\\_Content/EA/Armenakis\\_Costas\\_01.pdf](http://dipa.spatial.maine.edu/NG2I03/CD_Content/EA/Armenakis_Costas_01.pdf). Acesso em: 21 de fev. 2005.

[14] BAATZ, M. ;SCHAPE, A. Multiresolution Segmentation: an optimization approach for high quality multi-scale image segmentation. Disponível em:

[http://www.agit.at/papers/2000/baatz\\_FP\\_12.pdf](http://www.agit.at/papers/2000/baatz_FP_12.pdf). Acesso em: 21 de fev. 2005.

[15] BAHR, H. P. ; QUINT, F. Feature extraction for map based image interpretation.

Disponível em: <http://www.ubka.uni-karlsruhe.de/cgi-bin/psgunzip/1994/bau-verm/4/4.pdf>.

Acesso em: 21 de fev. 2005.

[16] BANON, G. J. F. ;BARRERA, J. Bases da Morfologia Matemática para análise de imagens binárias. Disponível em: [http://iris.sid.inpe.br:1912/rep-](http://iris.sid.inpe.br:1912/rep/)

[/dpi.inpe.br/banon/1998/06.30.17.56](http://dpi.inpe.br/banon/1998/06.30.17.56). Acesso em: 21 de fev. 2005.

[17] BLUNDELL, S. ; OPITZ, D. W. An intelligent user interface for feature extraction from remotely sensed images. Disponível em:

[http://www.cs.umt.edu/CS/FAC/OPITZ/papers/opitz\\_asprs99.ps](http://www.cs.umt.edu/CS/FAC/OPITZ/papers/opitz_asprs99.ps). Acesso em: 21 de fev. 2005.

[18] BOTANICAL INSTITUTE. Vegetation and remote sensing - Classification Disponível

em: <http://www.uib.no/bot/kurs/bb209/classification.pdf>. Acesso em: 21 de fev. 2005.

[19] BRUMBY, S. P. et al. Evolving land cover classification algorithms for multi-spectral and multi-temporal imagery. Disponível em: <http://nis->

[www.lanl.gov/~jt/Papers/brumby\\_SPIE4480-14.pdf](http://www.lanl.gov/~jt/Papers/brumby_SPIE4480-14.pdf). Acesso em: 21 de fev. 2005.

[20] CAETANO, M. et al. Cartografia de Ocupação do Solo com Imagens de Satélite: estado da arte. Disponível em:

[http://www.igeo.pt/Igeo/portugues/Novidades\\_eventos/eventos/esig2002/p092.pdf](http://www.igeo.pt/Igeo/portugues/Novidades_eventos/eventos/esig2002/p092.pdf). Acesso em: 21 de fev. 2005.

[21] CANDEIAS, A. L. ;SOUSA, E. B. Aplicação da Morfologia Matemática na extração automática de curva de nível de carta topográfica. Disponível em:

<http://iris.sid.inpe.br:1908/col/sid.inpe.br/deise/1999/02.01.15.39/doc/T8.DOC>. Acesso em: 21 de fev. 2005.

[22] CANDEIAS, A. L. Aplicação da Morfologia Matemática à Análise de Imagens de Sensoriamento Remoto. Disponível em: . Acesso em: 21 de fev. 2005.

- [23] CAROSIO, A. ; GRAEFF, B. Automatic interpretation of raster-based topographic maps. Disponível em: [http://www.fig.net/pub/fig\\_2002/Ts3-10/TS3\\_10\\_graeff\\_carosio.pdf](http://www.fig.net/pub/fig_2002/Ts3-10/TS3_10_graeff_carosio.pdf). Acesso em: 21 de fev. 2005.
- [24] CENTENO, J. A. S. Mapeamento de áreas permeáveis usando uma metodologia orientada a regiões e imagens de alta resolução. Disponível em: [http://www2.prudente.unesp.br/rbc/\\_pdf\\_55\\_2003/55\\_1\\_06.pdf](http://www2.prudente.unesp.br/rbc/_pdf_55_2003/55_1_06.pdf). Acesso em: 21 de fev. 2005.
- [25] CHAO, H. ; TRINDER, J.C. Feature extraction in residential areas by knowledge modeling. Disponível em: <http://www.gisdevelopment.net/aars/acrs/2000/ts9/imgp0016.shtml>. Acesso em: 21 de fev. 2005.
- [26] CHEN, Q. A geostatistical based segmentation approach for remotely sensed images. Disponível em: <http://definiens-imaging.com/documents/publications/acrs030620.pdf>. Acesso em: 21 de fev. 2005.
- [27] CIARLO, A. ;FERNER, D. eCognition Evaluation - Object oriented image analysis. Disponível em: [http://earth.esa.int/rtd/Tools/eCognition/eCognition\\_Evaluation.ppt](http://earth.esa.int/rtd/Tools/eCognition/eCognition_Evaluation.ppt). Acesso em: 21 de fev. 2005.
- [28] DARWISH, A. ;LEUKERT, K. Image Segmentation for the Purpose Of Object-Based Classification. Disponível em: [http://definiens-imaging.com/documents/publications/FR07\\_1420.PDF](http://definiens-imaging.com/documents/publications/FR07_1420.PDF). Acesso em: 21 de fev. 2005.
- [29] DAVIS, R. What is a knowledge representation? Disponível em: <http://medg.lcs.mit.edu/ftp/psz/aimag-final.ps>. Acesso em: 21 de fev. 2005.
- [30] DI, K. et al. automatic shoreline extraction form high-resolution ikonos satellite imagery. Disponível em: [http://shoreline.eng.ohio-state.edu/publications/di\\_asprs03.pdf](http://shoreline.eng.ohio-state.edu/publications/di_asprs03.pdf). Acesso em: 21 de fev. 2005.
- [31] DILLABAUGH, C. Semi-Automatic extraction of rivers from digital imagery. Disponível em: <http://www.kluweronline.com/article.asp?PIPS=5092789&PDF=1>. Acesso em: 21 de fev. 2005.
- [32] DRAPER, B. A. ; BEVERIDGE, J. R. Image understanding research at Colorado State University. Disponível em: [http://www.cs.colostate.edu/~draper/publications/draper\\_iuw97.pdf](http://www.cs.colostate.edu/~draper/publications/draper_iuw97.pdf). Acesso em: 21 de fev. 2005.
- [33] EBERT, A. ;HELMSCHROT, J. An object-oriented classification approach for land use analysis of the Ruhuna Basin, Sri Lanka using Landsat ETM data. Disponível em: <http://www.definiens-imaging.com/documents/an/srilanka.pdf>. Acesso em: 21 de fev. 2005.

- [34] ERDAS INC. Erdas imagine expert classifier overview Disponível em: <http://www.gis.usu.edu/unix/imagine/ExpertClassifier.pdf>. Acesso em: 21 de fev. 2005.
- [35] ERDAS INC. White paper Disponível em: . Acesso em: 21 de fev. 2005.
- [36] FARIA, S. D. Uma Abordagem Morfológica para Casamento de Padrões. Disponível em: [dpi.inpe.br/faria/1997/04.16.15.30](http://dpi.inpe.br/faria/1997/04.16.15.30). Acesso em: 21 de fev. 2005.
- [37] FORSSÉN, P. Detection of man-made objects in satellite images. Disponível em: <http://www.isy.liu.se/cvl/ScOut/Masters/PaperInfo/forssen97.html>. Acesso em: 21 de fev. 2005.
- [38] FRITSCH, D. ; STALLMANN D. Rigorous photogrammetric processing of high resolution satellite imagery. Disponível em: [http://www.ifp.uni-stuttgart.de/publications/2000/Stallmann\\_1576.pdf](http://www.ifp.uni-stuttgart.de/publications/2000/Stallmann_1576.pdf). Acesso em: 21 de fev. 2005.
- [39] FUA, P. ; HANSON, A. J. An optimization framework for feature extraction. Disponível em: <http://cvlab.epfl.ch/publications/fua-hanson-mva91.pdf>. Acesso em: 21 de fev. 2005.
- [40] GALO, M. ; DAL POZ, A. P. Metodologias para a avaliação geométrica de feições cartográficas. Disponível em: [http://www2.prudente.unesp.br/dcartog/galo/fct\\_artigos\\_pdf.htm](http://www2.prudente.unesp.br/dcartog/galo/fct_artigos_pdf.htm). Acesso em: 21 de fev. 2005.
- [41] GIADA, S. et al. Information extraction from very high resolution satellite imagery over Lukole refugee camp, Tanzania. Disponível em: <http://definiens-imaging.com/documents/publications/giada-et-al2003.pdf>. Acesso em: 21 de fev. 2005.
- [42] GIRALDIL, G. A. et al. Segmentação e modelos de contornos ativos. Disponível em: <http://virtual01.lncc.br/monografia/monografia2/monografia2.html>. Acesso em: 21 de fev. 2005.
- [43] GRANZOW, E. Automatic feature recognition. Disponível em: [http://riker.unm.edu/DASH\\_new/pdf/Technical%20Notes/Automatic%20Feature%20Recognition.PDF](http://riker.unm.edu/DASH_new/pdf/Technical%20Notes/Automatic%20Feature%20Recognition.PDF). Acesso em: 21 de fev. 2005.
- [44] GRAY, R. M. et al. Image classification by a Two Dimensional Hidden Markov Model. Disponível em: <http://www.stat.psu.edu/~jjali/pub/sp00.pdf>. Acesso em: 21 de fev. 2005.
- [45] GUINDON, B. Computer-based aerial image understanding: a review and assessment of its application to planimetric information extraction from very high resolution satellite images. Disponível em: <http://ess.nrcan.gc.ca/esic/ccrpub-cctpub/pdf/1794.pdf>. Acesso em: 21 de fev. 2005.
- [46] HEIPKE, C. Digital Photogrammetric Workstations - A review of the state-of-the-art for topographic applications. Disponível em: [http://www.ipi.uni-hannover.de/html/publikationen/2001/heipke/hei\\_dpws.pdf](http://www.ipi.uni-hannover.de/html/publikationen/2001/heipke/hei_dpws.pdf). Acesso em: 21 de fev. 2005.

- [47] HINZ, S. Automatic extraction of urban road networks from multi-view aerial imagery. Disponível em: [http://www.photo.verm.tu-muenchen.de/site\\_lpf/site\\_new/download/pub/2003/hinz\\_isprs03.pdf](http://www.photo.verm.tu-muenchen.de/site_lpf/site_new/download/pub/2003/hinz_isprs03.pdf). Acesso em: 21 de fev. 2005.
- [48] HOFMANN, P. Detecting buildings and roads from IKONOS and DEM data with eCognition - Tsukuba, Japan. Disponível em: <http://www.definiens-imaging.com/documents/an/tsukuba.pdf>. Acesso em: 21 de fev. 2005.
- [49] HOFMANN, P. eCognition and GIS feature extraction from VHR imagery. Disponível em: <http://www.definiens-imaging.com/documents/an/featureextraction.pdf>. Acesso em: 21 de fev. 2005.
- [50] HOFMANN, P. Using ecognition to detect informal settlements from ikonos imagery - Cape town, South Africa. Disponível em: <http://www.definiens-imaging.com/documents/an/capetown.pdf>. Acesso em: 21 de fev. 2005.
- [51] HUIPING, H. et al. Analysis to the Relationship of Classification Accuracy Segmentation Scale Image Resolution. Disponível em: [http://definiens-imaging.com/documents/publications/I\\_D08\\_07.PDF](http://definiens-imaging.com/documents/publications/I_D08_07.PDF). Acesso em: 21 de fev. 2005.
- [52] IBRAHIM, A. E. An Intelligent Framework for Image Understanding. Disponível em: <http://www.engr.uconn.edu/~ibrahim/publications/image.html>. Acesso em: 21 de fev. 2005.
- [53] INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Aula 5 - Classificação. Disponível em: <http://www.dpi.inpe.br/spring/usuario/aula05.pdf>. Acesso em: 21 de fev. 2005.
- [54] INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. Segmentação de Imagens. Disponível em: [http://www.dpi.inpe.br/spring/usuario/c\\_segmen.htm](http://www.dpi.inpe.br/spring/usuario/c_segmen.htm). Acesso em: 21 de fev. 2005.
- [55] IPPOLITI, G. ;GAGGERO, M. R. Classificação digital de fotografias verticais para estimativa da cobertura do solo. Disponível em: [http://lagavulin.ltid.inpe.br:1905/col/ltid.inpe.br/sbsr/2003/03.27.11.57/doc/01\\_035.PDF](http://lagavulin.ltid.inpe.br:1905/col/ltid.inpe.br/sbsr/2003/03.27.11.57/doc/01_035.PDF). Acesso em: 21 de fev. 2005.
- [56] KHOTANZAD, A. ;ZINK, E. Contour Line and Geographic Feature Extraction from USGS Color Topographical Paper Maps. Disponível em: <http://ieeexplore.ieee.org/iel5/34/26006/01159943.pdf?isNumber=26006&prod=JNL&arnumber=1159943&arSt=+18&ared=+31&arAuthor=Khotanzad%2C+A.%3B+Zink%2C+E..>. Acesso em: 21 de fev. 2005.

- [57] LANDES, S. ; QUINT, F. Colour aerial image segmentation using a bayesian homogeneity predicate and map knowledge. Disponível em: <http://www.ubka.uni-karlsruhe.de/indexer-vvv/1996/bau-verm/4>. Acesso em: 21 de fev. 2005.
- [58] LANDGREBE, D. A. ; MADHOK, V. A process model for remote sensing data analysis. Disponível em: [http://dynamo.ecn.purdue.edu/~landgreb/Madhok9\\_01.pdf](http://dynamo.ecn.purdue.edu/~landgreb/Madhok9_01.pdf). Acesso em: 21 de fev. 2005.
- [59] LETOURNEL, V. ; MAÎTRE, H. ; PRADEILLES, F. ; SANKUR, B. Feature extraction for quality assessment of aerial image segmentation. Disponível em: [http://www.busim.ee.boun.edu.tr/~sankur/SankurFolder/isprs2002\\_juillet29.pdf](http://www.busim.ee.boun.edu.tr/~sankur/SankurFolder/isprs2002_juillet29.pdf). Acesso em: 21 de fev. 2005.
- [60] LOHMANN, P. et al. Land Cover Classification using High Resolution IKONOS Data. Disponível em: <http://www.ipi.uni-hannover.de/html/publikationen/2001/Jacobsen/JacWegOEEPE.pdf>. Acesso em: 21 de fev. 2005.
- [61] MAYER, H. Object extraction for digital photogrammetric workstations. Disponível em: <http://www.isprs.org/istanbul2004/comm2/papers/165.pdf>. Acesso em: 21 de fev. 2005.
- [62] McKEOWN Jr., D. ; Automated cartographic feature attribution using panchromatic and hyperspectral imagery. 1998. Disponível em: [http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic\\_Feature\\_Extraction](http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic_Feature_Extraction). Acesso em: 21 de fev. 2005.
- [63] McKEOWN Jr., D. M. Construction of synthetic environments for advanced distributed simulation. 2000. Disponível em: <http://www.maps.cs.cmu.edu/RCVW/present/present.htm>. Acesso em: 21 de fev. 2005.
- [64] MCKEOWN Jr., D. M. Integration of photogrammetric cues into cartographic feature extraction. Disponível em: <http://www.maps.cs.cmu.edu/papers/McKe-McGI93.html>. Acesso em: 21 de fev. 2005.
- [65] McKEOWN Jr., D. M. Research in automated analysis of remotely sensed imagery. 1993. Disponível em: [http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic\\_Feature\\_Extraction](http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic_Feature_Extraction). Acesso em: 21 de fev. 2005.
- [66] McKEOWN Jr., D. M. Research in automated analysis of remotely sensed imagery. 1994. Disponível em: [http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic\\_Feature\\_Extraction](http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic_Feature_Extraction). Acesso em: 21 de fev. 2005.

- [67] McKEOWN Jr., D. M. Research in automated analysis of remotely sensed imagery. 1996. Disponível em:  
[http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic\\_Feature\\_Extraction](http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic_Feature_Extraction). Acesso em: 21 de fev. 2005.
- [68] McKEOWN Jr., D. M. Research in automated analysis of remotely sensed imagery. 1997. Disponível em:  
[http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic\\_Feature\\_Extraction](http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic_Feature_Extraction). Acesso em: 21 de fev. 2005.
- [69] McKEOWN Jr., D. M. Top ten lessons learned in automated cartography. 1996. Disponível em:  
[http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic\\_Feature\\_Extraction](http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic_Feature_Extraction). Acesso em: 21 de fev. 2005.
- [70] McKEOWN Jr., D. Research in image understanding and automated cartography. 1998. Disponível em:  
[http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic\\_Feature\\_Extraction](http://www.maps.cs.cmu.edu/papers/papers.html#Cartographic_Feature_Extraction). Acesso em: 21 de fev. 2005.
- [71] MEDEIROS, N. G. et al. Segmentação morfológica de imagens utilizando o gradiente morfológico multi-escala. Disponível em:  
[http://www2.prudente.unesp.br/rbc/\\_pdf\\_54\\_2002/54\\_08.pdf](http://www2.prudente.unesp.br/rbc/_pdf_54_2002/54_08.pdf). Acesso em: 21 de fev. 2005.
- [72] MEDEIROS, N. G. Segmentação watershed utilizando a técnica dos mínimos impostos. Disponível em: [http://geodesia.ufsc.br/geodesia-online/arquivo/GeoColoq\\_2003/artigos/T144.pdf](http://geodesia.ufsc.br/geodesia-online/arquivo/GeoColoq_2003/artigos/T144.pdf). Acesso em: 21 de fev. 2005.
- [73] MITTELBERG, B. PIXEL VERSUS OBJECT: A method comparison for analysing urban areas with VHR data. Disponível em: <http://www.definiens-imaging.com/documents/an/mittelberg.pdf>. Acesso em: 21 de fev. 2005.
- [74] MOHAMMADZADEH, A. et al. Automatic linear feature extraction of iranian roads from high resolution multi-spectral satellite imagery. Disponível em:  
<http://www.isprs.org/istanbul2004/comm3/papers/371.pdf>. Acesso em: 21 de fev. 2005.
- [75] MORAES, R. M. Uma Arquitetura de Sistemas Especialistas Nebulosos Utilizando Operadores da Morfologia Matemática. Disponível em:  
[http://www.de.ufpb.br/~ronei/tese/tesedf\\_pdf.zip](http://www.de.ufpb.br/~ronei/tese/tesedf_pdf.zip). Acesso em: 21 de fev. 2005.
- [76] MUSTIÈRE, S. et al. Learning abstraction and representation knowledge. Disponível em:  
<http://www-poleia.lip6.fr/~zucker/Papers/MSL2000.pdf>. Acesso em: 21 de fev. 2005.

- [77] NARDONE, M. Sobre a Álgebra de Imagens. Disponível em:  
[iris.sid.inpe.br:1912/col/dpi.inpe.br/banon/1998/06.30.17.56/doc/cap2\\_36.pdf+Sobre+a+%C3%81lgebra+de+Imagens&hl=pt-BR](http://iris.sid.inpe.br:1912/col/dpi.inpe.br/banon/1998/06.30.17.56/doc/cap2_36.pdf+Sobre+a+%C3%81lgebra+de+Imagens&hl=pt-BR) . Acesso em: 21 de fev. 2005.
- [78] NEUBERT, M. ;MEINEL, G. Evaluation of segmentation programs for high resolution remote sensing applications. Disponível em: <http://www.ioer.de/PubIPDF/neubert3.pdf>. Acesso em: 21 de fev. 2005.
- [79] OPTIZ, D. et al. Feature extraction from digital imagery: a hierarchical method. Disponível em: [http://www.wru.umt.edu/~scmason/feature\\_ext.pdf](http://www.wru.umt.edu/~scmason/feature_ext.pdf). Acesso em: 21 de fev. 2005.
- [80] PARACCHINI, M. L. et al. Development of a pan-European database of rivers and catchments: a GIS application in support to European water monitoring activities. Disponível em: <http://www.proland.iung.pulawy.pl/Materials/WP1/Paracchini.doc>. Acesso em: 21 de fev. 2005.
- [81] PEKKARINEN, A. Image segmentation in multisource forest inventory. Disponível em: <http://ethesis.helsinki.fi/julkaisut/maa/mvaro/vk/pekkarinen/imageseg.pdf>. Acesso em: 21 de fev. 2005.
- [82] PUC-MG. Processamento digital de imagens. Disponível em:  
<http://www.inf.pucminas.br/projetos/latim/estudobiblio/resumopi.htm#classificacao>. Acesso em: 21 de fev. 2005.
- [83] Representação de conhecimento Disponível em:  
<http://genesis.nce.ufrj.br/dataware/GestaoConhecimento/Apresentacoes/RepresentacaoConhecimento.ppt>. Acesso em: 21 de fev. 2005.
- [84] Representação de Conhecimento Disponível em:  
<http://www.cce.ufpr.br/~hamilton/iaed/iaed0002.htm>. Acesso em: 21 de fev. 2005.
- [85] SAE-UI, P. Topographic map model feature recognition. Disponível em:  
<http://www.inf.ed.ac.uk/publications/thesis/online/IM030054.pdf>. Acesso em: 21 de fev. 2005.
- [86] SOBRAL, J. L. Segmentação de imagens. Disponível em:  
<http://gec.di.uminho.pt/lesi/vpc0203/Aula06Segmenta%C3%A7%C3%A3o.pdf>. Acesso em: 21 de fev. 2005.
- [87] STURM, U. Análise da ocupação em áreas de preservação permanente (app) na área urbana do município de Matinhos utilizando a imagem ikonos II. Disponível em:  
<http://definiens-imaging.com/documents/publications/uli.pdf>. Acesso em: 21 de fev. 2005.
- [88] TAYLOR, K. ;WRIGHT, D. Southern Wind River Landscape Feature Extraction for Risk Assessment. Disponível em:

[http://www.gis.usu.edu/ArcWebpage/inside\\_table/2003Presentations/NASAREports/USUTN C.pdf](http://www.gis.usu.edu/ArcWebpage/inside_table/2003Presentations/NASAREports/USUTN C.pdf). Acesso em: 21 de fev. 2005.

[89] THURSTON, J. GIS and remote sensing: new trends in feature and object recognition. Disponível em: <http://www.integralgis.com/pdf/GIS%20and%20Remote%20Sensing.pdf>.

Acesso em: 21 de fev. 2005.

[90] TOMASELLI, A. M. G. Extração de feições cartográficas. Disponível em:

[http://geodesia.ufsc.br/geodesia-online/arquivo/Cobrac\\_2002/013/013.htm#top](http://geodesia.ufsc.br/geodesia-online/arquivo/Cobrac_2002/013/013.htm#top). Acesso em: 21 de fev. 2005.

[91] TOMASELLI, A. M. G. Uma abordagem semi-automática para extração de feições cartográficas. Disponível em: [http://www2.prudente.unesp.br/rbc/\\_pdf\\_53\\_2001/53\\_02.pdf](http://www2.prudente.unesp.br/rbc/_pdf_53_2001/53_02.pdf).

Acesso em: 21 de fev. 2005.

[92] TOMMASELLI, A. M. G. Uma estratégia para extração semi-automática de feições com análise do M.N.E. Disponível em:

<http://calvados.c3sl.ufpr.br/bcg/include/getdoc.php?id=147&article=54&mode=pdf>. Acesso em: 21 de fev. 2005.

[93] VALERIANO, M. M. Extração de rede de drenagem e divisores por processamento digital de dados topográficos. Disponível em:

<http://iris.sid.inpe.br:1908/col/dpi.inpe.br/lise/2001/09.19.07.26/doc/0517.524.084.pdf>.

Acesso em: 21 de fev. 2005.

[94] VOSSSELMAN, G. Cartographic feature extraction. Disponível em:

<http://www.itc.nl/personal/vosselman/papers/vosselman1998.bonn.pdf>. Acesso em: 21 de fev. 2005.

[95] WALLACE, S. J. et al. Automatic differentiation of linear features extracted from remotely sensed imagery. Disponível em: [http://www.icg.tu-](http://www.icg.tu-graz.ac.at/pcv02/wallace_isprs_graz_paper.pdf)

[graz.ac.at/pcv02/wallace\\_isprs\\_graz\\_paper.pdf](http://www.icg.tu-graz.ac.at/pcv02/wallace_isprs_graz_paper.pdf);internal&action=\_framecontent.action&Target=\_blank. Acesso em: 21 de fev. 2005.

[96] WANDERLEY, J. F. Segmentação de imagens. Disponível em: <http://www.tecgraf.puc-rio.br/~scuri/inf1378/pub/segmentacao.pdf>. Acesso em: 21 de fev. 2005.

[97] WIDAYATI, A. ;VERBIST, B. MEIJERINK, A. Application of combined pixel-based and spatial-based approaches for improved mixed vegetation classification using ikonos.

Disponível em: <http://www.gisdevelopment.net/aars/acrs/2002/sol/147.pdf>. Acesso em: 21 de fev. 2005.

[98] WILSON, E. ;CIVCO, D. Researchers at The University of Connecticut use eCognition to improve land use information derived from Landsat and IKONOS. Disponível em:

<http://www.definiens-imaging.com/documents/an/connecticut.pdf>. Acesso em: 21 de fev. 2005.

[99] ZHITAO, X. Analysis and comparison on Image Feature Detectors Disponível em: . Acesso em: 21 de fev. 2005.

## Periódicos

[100] CANNY, J. A Computational Approach to Edge Detection, IEEE Trans. Pattern Analysis and Machine Intelligence, v. 8, n. 6, p. 679-698, 1986.

[101] FÖRSTNER, W.; GÜLCH E. A Fast Operator for Detection and Precise Location of Distinct Points, Corners and Centers of Circular Features. In: Proceedings ISPRS Intercommission Workshop on "Fast Processing of Photogrammetric Data", Interlaken, June 1987.

[102] FU, K.S.; MUI, J.K. A survey of image segmentation. Pattern Recognition, v. 13, n. 1, p. 3-16, 1981.

[103] HARALICK, R.M.; SHAPIRO, L.G. Survey: Image Segmentation Techniques. Computer Vision, Graphics, and Image Processing, v.29, n. 1, p. 100-132, 1985.

[104] KASS, M. et al. Snakes: Active Contour Models, Proc. 1st International Conference on Computer Vision, p. 259-268, 1987.

[105] OHLANDER, R. et al. Picture Segmentation Using A Recursive Region Splitting Method, Computer Graphics and Image Processing, v. 8, p. 313-333, 1978.

[106] OHTA, Y-U. et al. Color Information for Region Segmentation, Computer Graphics and Image Processing, v. 13, p. 222-241, 1980.

[107] PAL, N.R.; PAL, S.K. A review on image segmentation techniques. Pattern recognition, v. 26, n. 9, p. 1277-1294, 1993.