

**ABORDAGENS COGNITIVAS E MINERAÇÃO DE DADOS
APLICADAS A DADOS ÓPTICOS ORBITAIS E DE LASER PARA
A CLASSIFICAÇÃO DE COBERTURA DO SOLO URBANO**

Fernando Leonardi

Proposta de Dissertação de Mestrado em Sensoriamento Remoto orientada pelas
Doutoras Cláudia Maria de Almeida e Leila Maria Garcia Fonseca.

INPE
São José dos Campos
2009

RESUMO

Muitos métodos para classificação de imagens de sensoriamento remoto têm sido desenvolvidos desde o lançamento dos primeiros satélites. Esses métodos foram muito eficientes até a década de 1990 e continuam sendo para muitas aplicações com o uso de satélites de média e baixa resolução espacial. Mas com o lançamento dos satélites de alta resolução, voltados, entre outros temas, para o estudo do ambiente intra-urbano, surgiu a necessidade de uma nova abordagem para interpretação das imagens, em função desses sensores capturarem detalhes de cenas muito heterogêneas, como é o caso das áreas urbanas, caracterizadas por uma grande variação interna das classes. Diante disso, a abordagem orientada a objeto e baseada em segmentação multiresolução tem se mostrado bastante eficiente para a discriminação da grande quantidade de alvos urbanos representados em imagens de alta resolução espacial. Porém, esse tipo de classificação exige a experiência de um especialista para operar o sistema. Uma técnica que pode facilitar o trabalho do especialista no sentido de automatizar algumas rotinas da classificação é a mineração de dados, que utiliza técnicas que permitem explorar um conjunto de dados, extraindo ou ajudando a evidenciar padrões de interesse nestes dados e auxiliando na descoberta de conhecimento. Nesse sentido, empregar abordagens cognitivas (rede semântica multinível, lógica fuzzy, análise orientada a objeto) e mineração de dados (algoritmos genéticos, redes neurais) para classificação de cobertura do solo urbano a partir de dados ópticos orbitais e de perfilamento a laser possui potencial para a geração de resultados mais precisos do que os métodos de classificação de imagens empregados convencionalmente.

SUMÁRIO

	<u>Pág.</u>
LISTA DE FIGURAS	3
LISTA DE TABELAS	4
CAPÍTULO 1	5
INTRODUÇÃO.....	5
1.1 Objetivo Geral.....	6
1.2 Objetivos Específicos	7
CAPÍTULO 2	8
FUNDAMENTAÇÃO TEÓRICA	8
2.1 Dados Aerotransportados de Perfilamento a Laser.....	8
2.1.1 Processamento dos Dados Laser	10
2.2 Segmentação	11
2.2.1 Segmentação Baseada em Multiresolução	11
2.2.2 Definição dos Parâmetros Ótimos de Segmentação por Algoritmos Genéticos....	13
2.2.3 Métodos Inovadores de Segmentação Baseados em Morfologia Matemática	14
2.2.4 Refinamento de Segmentação de Objetos com Geometria Regular Baseado em Classificação.....	15
2.3 Classificação Orientada a Objeto.....	16
2.3.1 Sistemas Especialistas	17
2.3.2 Rede Semântica.....	18
2.3.3 Lógica Fuzzy.....	19
2.3.4 Mineração de Dados.....	20
2.3.5 Mapa de Incerteza e Coeficiente de Concordância Kappa.....	23
CAPÍTULO 3	24
Material e Métodos	24
3.1 Área de Estudo.....	24
3.2 Dados de Entrada	26
3.3 Metodologia.....	27
3.4 Estimativa dos Parâmetros de Segmentação no Aplicativo SPT	29
3.5 Importação dos Dados de Laser e Ópticos na Plataforma Definiens 7.0	29
3.5.1 Classificação	29
CAPÍTULO 4.....	32
RESULTADOS ESPERADOS E CRONOGRAMA	32
REFERÊNCIAS BIBLIOGRÁFICAS	33

LISTA DE FIGURAS

Figura 2.1 - Sistema de perfilamento a laser em operação.....	9
Figura 2.2 - Segmentação de imagem utilizando três diferentes parâmetros de escala..	12
Figura 2.3 - Resultado da segmentação de dados de laser com base no primeiro eco. ..	14
Figura 2.4 - Comparação entre a) segmentação convencional e b) re-segmentação.	15
Figura 2.5 - Método de re-segmentação pós-classificação por meio de casamento de modelos.....	16
Figura 2.6 - (a) Rede semântica de tipos de coberturas de edificações (agregação); (b) Rede semântica de tipos de vegetação intra- urbana (hereditariedade).	18
Figura 2.7 - Exemplos de funções <i>fuzzy</i> : a) triangular, b) trapezoidal e c) gaussiana. ...	20
Figura 2.8 - Etapas do processo de KDD ou DCBD.	21
Quadro 2.9 - Tarefas de KDD e técnicas para mineração de dados.	22
Figura 3.1 - Área de estudo.	24
Figura 3.2 – a) Área de estudo retratada para uma imagem IKONOS e b) Delimitação da área de estudo.....	25
Figura 3.3 - Diagrama de blocos da metodologia proposta.....	28
Quadro 3.4 - Classes de cobertura do solo urbano selecionadas para o estudo.	31

LISTA DE TABELAS

Tabela 2.1 - Qualidade da classificação associada a intervalos de valores do índice Kappa.....	23
Tabela 3.1 - Características do satélite IKONOS-II.	26
Tabela 3.2 - Características do sensor a bordo do satélite IKONOS.....	26
Tabela 4.1 - Cronograma de atividades.	32

CAPÍTULO 1

INTRODUÇÃO

O reconhecimento de padrões de mudanças no uso e cobertura do solo pode fornecer elementos para responder várias questões relevantes. Dentre as aplicações, o planejamento urbano para as prefeituras é um bom exemplo. A partir da identificação de uma área que está sofrendo intensa verticalização, é possível planejar mudanças no padrão de atendimento do transporte público em função da previsão do aumento do número de passageiros. Este procedimento pode ser feito por meio da análise multitemporal de mapas de uso e cobertura do solo intra-urbano (PINHO, 2005).

A elaboração destes mapas exige dados detalhados, precisos e que possam ser atualizados continuamente. A área intra-urbana é um dos sistemas mais dinâmicos e variados do nosso planeta, por ser resultado da ação humana em um ambiente natural. Dada a rapidez com que ocorrem as alterações de algumas áreas da superfície terrestre, principalmente áreas urbanas, faz-se necessária a contínua atualização.

A partir do mapeamento de uso e cobertura do solo atualizado, é possível extrair e analisar informações, planejar investimentos, monitorar as necessidades de infraestrutura e equipamentos sociais e executar políticas públicas necessárias para o desenvolvimento sustentável, com qualidade de vida para a população.

Os dados de sensoriamento remoto apresentam-se como uma das fontes mais tradicionais para geração de mapas de uso e cobertura do solo. Porém, trabalhos voltados para áreas urbanas só puderam ser mais detalhados a partir do uso das imagens de alta resolução espacial, o que aconteceu a partir da década de 1990 com o lançamento dos satélites de alta resolução, como o IKONOS II em 1999, por exemplo, que representou um momento de grande inovação para o sensoriamento remoto do espaço intra-urbano. Muitos métodos de classificação têm sido desenvolvidos desde as primeiras observações da Terra por sensoriamento remoto orbital (DESCLÉE et al.,

2006). Porém, a utilização das imagens obtidas por esses novos sensores de alta resolução impõe novos desafios para a classificação automática de uso e cobertura do solo intra-urbano.

Os tradicionais classificadores, a exemplo do método pixel-a-pixel, apresentam grande limitação quando se utilizam imagens que captam detalhes de cenas muito heterogêneas (áreas urbanas) e com grande variação interna das classes.

Surge, portanto, a necessidade de exploração de métodos alternativos que não se limitem apenas a atributos espectrais. Entre estes métodos, destaca-se a análise orientada a objetos. A classificação orientada a objeto realiza uma análise sobre objetos ou segmentos da imagem, que podem ser caracterizados por diferentes atributos espectrais e espaciais, tais como relações topológicas, textura, forma, tamanho, entre outras (DEFINIENS, 2006).

Outra abordagem utilizada para facilitar o trabalho do especialista no sentido de automatizar algumas rotinas da classificação é a mineração de dados. Esta técnica utiliza técnicas que permitem explorar um conjunto de dados, extraíndo ou ajudando a evidenciar padrões de interesse nestes dados e auxiliando na descoberta de conhecimento (KORTING et al., 2008).

Nesse sentido, empregar abordagens cognitivas (rede semântica multinível, lógica fuzzy, análise orientada a objeto e mineração de dados (algoritmos genéticos, redes neurais) para classificação de cobertura do solo urbano possui potencial para a geração de resultados mais precisos do que os métodos de classificação de imagens empregados convencionalmente.

1.1 Objetivo Geral

O objetivo deste trabalho consiste em empregar abordagens cognitivas (rede semântica multinível, lógica fuzzy, classificação orientada a objeto) e técnicas de mineração de dados (algoritmos genéticos, redes neurais) com o intuito de desenvolver uma metodologia semi-automatizada de classificação de cobertura do solo urbano de parte da

região central da cidade de Uberlândia (MG), a partir de dados ópticos orbitais e de perfilamento a laser.

1.2 Objetivos Específicos

- a) Explorar metodologias inovadoras de segmentação baseadas em operadores morfológicos para aplicação aos dados laser.
- b) Determinar os parâmetros ótimos de segmentação da plataforma Definiens, como pesos para as bandas, fator de escala, cor, forma, compacidade e suavidade, por meio de algoritmos genéticos.
- c) Aplicar e avaliar metodologias para o refinamento da segmentação baseadas em classificação, seja por fusão de objetos ou redefinição automática de bordas.
- d) Aplicar e avaliar o algoritmo C4.5 para a seleção automática de atributos e definição dos intervalos ótimos de cada atributo em relação às classes de cobertura do solo urbano.
- e) Avaliar comparativamente a acurácia de uma classificação semi-automatizada incluindo dados ópticos orbitais e de perfilamento a laser em relação à acurácia de uma classificação semi-automatizada excluindo os dados de perfilamento a laser, a fim de se determinar a significância da contribuição dos dados de laser para a melhora da acurácia da classificação.

CAPÍTULO 2

FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, será apresentada uma revisão sobre processamento de dados laser e sobre as técnicas de segmentação baseada em multiresolução e classificação orientada a objeto, que são fundamentais para entendimento da metodologia do trabalho.

2.1 Dados Aerotransportados de Perfilamento a Laser

O sistema aerotransportado de perfilamento a laser ou de varredura a laser (laser scanning) foi desenvolvido com a finalidade de estimar a distância entre o sensor e a superfície, e assim, determinar a posição do local onde o pulso laser atinge a superfície. O sensor mede a intensidade do sinal de retorno e o tempo decorrido entre a emissão e a captação do retorno, que é usado para calcular a distância sensor-objeto, considerando que o pulso laser se propaga à velocidade da luz (BALTSAVIAS, 1999). Como a varredura é efetuada a partir da aeronave, não somente a superfície do terreno, mas também outros objetos acima da mesma, como copas das árvores e telhados, são igualmente medidos. A técnica para o processamento de informação nesses sistemas, também conhecida como mapeamento digital a laser, é denominada de LIDAR (*Light Detection And Ranging*).

O sensor é instalado em plataformas móveis, tais como aviões ou helicópteros (Figura 2.1), que se deslocam acima da superfície, necessitando obrigatoriamente da determinação de um conjunto de parâmetros como: posição da aeronave, atitude do sensor no momento do registro dos dados e registro da distância entre o sensor a cada pulso emitido sobre a superfície do terreno (SCHIMALESKY, 2007).




Figura 2.1 - Sistema de perfilamento a laser em operação.

Fonte: SBGMAPS (2009).

Segundo Baltsavias (1999), para suprir essa necessidade, o sistema de varredura a laser pode ser dividido em três componentes principais: a unidade de medição a laser propriamente dita, encarregada de emitir e receber o sinal laser, além de duas unidades de posicionamento auxiliar: o Sistema de Posicionamento Global (*Global Positioning System – GPS*) e o Sistema de Medição Inercial (*Inertial Measurement Unit – IMU*).

Para o cálculo da posição de cada ponto, o instrumento registra, além do tempo, a orientação do sensor no instante da emissão/registo do pulso e a posição exata da aeronave que carrega o sensor. Conhecendo-se os parâmetros necessários, a distância pode ser calculada mediante a Equação 2.1:

$$\Delta S = \frac{1}{2} * c * \Delta t, \quad (2.1)$$

em que:

ΔS = distância;

c = velocidade da luz;

Δt = intervalo de tempo.

Dois conceitos são consagrados em termos de modelos que podem ser produzidos a partir de dados de perfilamento a laser. Quando os dados referem-se aos pontos que atingiram o terreno, fala-se em Modelo Digital do Terreno (MDT). Quando o modelo inclui além do terreno, os objetos a ele superpostos, fala-se em Modelo Digital da Superfície (MDS).

O mapeamento digital a laser (LIDAR) é capaz de gerar modelos digitais densos e precisos, tanto da topografia do terreno como da estrutura vertical da superfície. Os pontos são levantados diretamente no terreno, e o modelo digital do terreno gerado não tem escala, mas sim uma precisão aproximadamente de 50 cm na planimetria e 15 cm na altimetria, variando conforme os modelos dos sensores (MARTINS et al., 2004).

2.1.1 Processamento dos Dados Laser

Após a coleta dos dados necessários, inicia-se a operação de processamento, na qual cada sistema conta com um programa para processar essa massa de dados. Atualmente, os procedimentos para efetuar tal tarefa já estão implementados em plataformas comerciais, tornando o processo totalmente automatizado e de fácil execução.

Uma vez descarregados os dados dos componentes do sistema laser, inicia-se a tarefa de integrá-los. O operador do sistema necessita somente indicar ao programa onde se encontra cada informação no diretório e onde serão armazenados os resultados do processamento. Para diferenciar quais informações correspondem ao relevo ou a qualquer outro fenômeno geográfico ou objeto presente na superfície estudada, há a necessidade da operação de filtragem. A filtragem é de grande importância, principalmente quando o objetivo de emprego dos dados é a construção de um modelo numérico de elevações correspondente à topografia da região em estudo. Qualquer outra informação contida na massa de dados coletados pelo sensor daria origem a um modelo distinto, genericamente conhecido como “Modelo Digital do Terreno”, onde o atributo representado não necessariamente é o relevo da área de estudo, já que pode representar qualquer outro atributo presente na região (NEGRON et al., 2003).

Durante a coleta de dados, o sistema consegue registrar um dado que identifica o tipo de eco do pulso, emitido ao interagir com qualquer objeto presente na área de estudo. Esta capacidade de registrar diferentes tipos de eco de cada pulso laser permite aplicar algumas técnicas de filtragem, a fim de identificar quais pontos registrados como primeiro, segundo ou terceiro eco de pulso refletido representam mais adequadamente a topografia da superfície estudada (NEGRON et al., 2003).

Os dados oriundos de perfilamento por laser constituem o Modelo Digital de Superfície (MDS) e o Modelo Digital de Terreno (MDT).

Segundo Burrough (1986), MDT é uma representação matemática da distribuição espacial da característica de um fenômeno vinculada a uma superfície real.

Já o Modelo Digital de Superfícies (MDS) não somente representa a superfície do terreno, como os Modelos Digitais do Terreno (MDT), como também representa construções e outros objetos, como árvores (HAALA, 1999).

Sendo assim, o MDS que será utilizado no trabalho é o modelo de altitudes, que incorpora os valores de elevação (z) das feições naturais e artificiais que se encontram acima da superfície nua do terreno, como edificações, árvores e torres de energia.

2.2 Segmentação

A segmentação é o processo de particionamento da imagem em regiões homogêneas que, geralmente, representam objetos de interesse (DESCLÉE et al., 2006). Na classificação baseada em objeto, a segmentação é a primeira etapa do processamento para gerar os segmentos a serem classificados.

2.2.1 Segmentação Baseada em Multiresolução

A abordagem em multiresolução consiste em analisar os objetos da imagem em diferentes níveis de resolução. Ela é fundamentada no fato de que objetos pequenos podem ser adequadamente analisados em uma resolução mais fina, enquanto que objetos maiores podem ser adequadamente analisados em uma resolução mais grosseira. A segmentação pode ser realizada em múltiplas resoluções, pela variação de parâmetros do algoritmo de segmentação, que altera o nível de resolução do processamento.

O sistema Definiens usa a abordagem de segmentação baseada em multiresolução (BAATZ; SCHÄPE, 2000). Este sistema usa uma função que inclui três tipos de parâmetros definidos pelo usuário (compacidade, suavidade e escala) para definir o nível de resolução. O parâmetro compacidade representa quão compactos estão os

pixels de um determinado objeto. Um objeto de forma retangular é mais compacto que um objeto com forma de uma “estrela”. A suavidade representa o grau de irregularidade do contorno de um objeto. E o parâmetro fator de escala controla o tamanho de cada objeto, de modo que este corresponda a uma Unidade Mínima de Mapeamento (*Minimal Mapping Unit - MMU*).

A segmentação em multiresolução realiza a fusão de regiões (*region-merging*), na qual os segmentos da imagem são agrupados par a par. Inicialmente, um pixel individual é sinônimo de um objeto da imagem ou de uma região. Nos passos seguintes, pequenos objetos da imagem são agregados, gerando outros maiores. Em cada passo, o par adjacente do objeto da imagem é fundido, segundo um patamar de crescimento definido para a heterogeneidade. O processo ocorre também segundo um critério de homogeneidade, descrevendo a semelhança dos objetos vizinhos (HOFFMANN; VEGT, 2001).

Na Figura 2.2, Antunes et al. (2003) exemplificam diferentes graus de generalização para três imagens: A, B e C. As relações entre os objetos dependem de conhecimento do usuário, além do fato de que a forma dos objetos pode fornecer dicas para a interpretação da imagem. Forma e cor permitem a percepção associativa dos objetos e a identificação de sua provável classe.




Figura 2.2 - Segmentação de imagem utilizando três diferentes parâmetros de escala.

Fonte: Antunes et al. (2003).

2.2.2 Definição dos Parâmetros Ótimos de Segmentação por Algoritmos Genéticos

Os parâmetros do algoritmo de segmentação são definidos de forma que os segmentos sejam coerentes com os objetos de interesse em uma dada aplicação. No entanto, nem sempre a escolha dos parâmetros da segmentação é fácil, o que acarreta uma demorada e frustrante série de tentativas e erros (FREDRICH; FEITOSA, 2008).

Segundo Fredrich e Feitosa (2008), a clássica definição para Algoritmos Genéticos (AG) reporta-se a algoritmos estocásticos de pesquisa e otimização baseada na herança genética e disputa darwinista para a sobrevivência. Eles devem ser encarados, no entanto, como uma heurística para encontrar a melhor solução para um problema, conduzida pela pesquisa paralela, e não por exaustão ou um incômodo e demorado processo de tentativa e erro.

Os AG são métodos que simulam, através de rotinas computacionais, os processos de evolução natural e genética, buscando resolver problemas de otimização, em que o espaço de busca é muito grande e os métodos convencionais não se demonstram eficientes. O algoritmo básico foi estruturado de forma que as informações referentes a um determinado sistema pudessem ser codificadas de maneira análoga aos cromossomos biológicos (BATISTA; GUIMARÃES, 2005).


Feitosa et al. (2006) propõem um método automático para determinar os parâmetros ideais (próximos àqueles fornecidos pelo analista) de segmentação usando a técnica de AG. A escolha é realizada por uma função de adequação, que mede o nível de concordância geométrica entre os resultados da segmentação e um conjunto amostral de objetos fornecido pelo analista. Resultados mostram que o método tem um bom desempenho para objetos homogêneos.

Algoritmos Genéticos, por serem algoritmos aproximativos, têm melhor desempenho em relação aos algoritmos ótimos, e por isso são uma boa alternativa aos métodos tradicionais na área de segmentação de imagens de Sensoriamento Remoto.

2.2.3 Métodos Inovadores de Segmentação Baseados em Morfologia Matemática

Segundo Soille (1999), a Morfologia Matemática (MM) pode ser definida como uma teoria para a análise de estruturas espaciais. É chamada de morfologia, porque visa analisar a forma dos objetos. É matemática, no sentido de que a análise está baseada em teoria ajustada, na geometria e na álgebra. Porém, a MM não é apenas uma teoria, mas é também uma poderosa técnica de análise de imagens.

Vários trabalhos têm sido desenvolvidos utilizando os operadores morfológicos para segmentar imagens. Tarsha-Kurdi et al. (2006) propõem um método de detecção automática de edificações em dados laser scannig aerotransportados, usando somente o primeiro eco/retorno sem qualquer outro dado externo. A Figura 2.3 ilustra um dos resultados obtidos pelos autores.



(a) Imagem

(b) MDS

(c) Edificações detectadas


Figura 2.3 - Resultado da segmentação de dados de laser com base no primeiro eco.

Fonte: Tarsha-Kurdi et al. (2006).

Bartels et al. (2006) desenvolveram um algoritmo de segmentação não supervisionado (*skewness balancing*) para separar eficientemente pontos no terreno e pontos de objetos da superfície a partir da nuvem de pontos LIDAR de alta resolução, por meio da exploração de medidas de distribuição. Os resultados mostram que o algoritmo proposto é robusto e tem potencial para diversas aplicações, inclusive comerciais.

2.2.4 Refinamento de Segmentação de Objetos com Geometria Regular Baseado em Classificação

A re-segmentação tem como objetivo reorganizar um conjunto de polígonos, agregando elementos deste conjunto para gerar objetos com características morfológicas e geométricas adequadas ao contexto da aplicação (KORTING, 2007). A re-segmentação também pode implicar na redefinição das bordas de elementos previamente segmentados, de forma a diminuir o seu ruído e torná-las mais lineares (UBA, 2008). Korting (2007) apresenta uma metodologia para re-segmentação de objetos regulares em imagens urbanas de alta resolução baseada em grafos. Atualmente, os métodos estão implementados no ambiente TerraLib, o que facilita a sua aplicação. A Figura 2.4 apresenta a comparação entre a segmentação convencional e a re-segmentação obtida pela metodologia proposta por Korting (2007).



a) Segmentação Convencional

b) Re-segmentação

Figura 2.4 - Comparação entre a) segmentação convencional e b) re-segmentação.

Fonte: Korting (2007).

O método proposto por Uba (2008) tem como entrada uma ou mais bandas espectrais (Figura 2.5 (a)) e um conjunto de polígonos resultantes de uma super-segmentação (Figura 2.5 (b)). Para facilitar a detecção dos objetos, são tomadas amostras de classe telhado (Figura 2.5 (c)), e na seqüência, uma etapa de classificação é realizada (Figura 2.5 (d)). Em seguida, é feita a conversão da imagem classificada para dado vetorial (Figura 2.5 (e)). Com base em técnicas de casamento de modelos (*template matching*) e contornos ativos, os polígonos das classes de interesse são processados e redefinidos,

para que melhor representem os objetos presentes na imagem (Figura 2.5 (f)). Por fim, os retângulos obtidos são sobrepostos à cena (Figura 2.5 (g)), e regiões de referência são adquiridas para a avaliação (Figura 2.5 (h)).

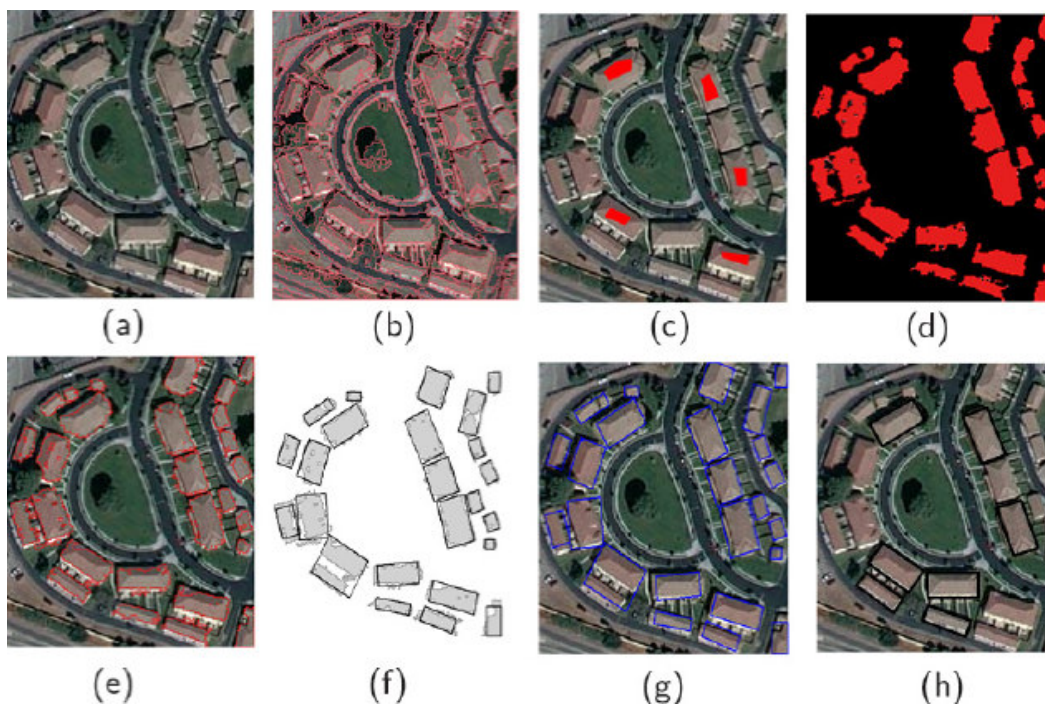


Figura 2.5 - Método de re-segmentação pós-classificação por meio de casamento de modelos.

Fonte: Uba (2008).

2.3 Classificação Orientada a Objeto

Na classificação orientada a objeto, a análise é realizada sobre objetos ou segmentos na imagem, e não sobre pixels individualmente. Na imagem, um objeto representa uma entidade que pode ser individualizada, tem atributos próprios e as mesmas propriedades da classe que lhe deu origem (DEFINIENS, 2006).

A análise orientada a objeto baseia-se em dois passos: segmentação em multiresolução e classificação. No primeiro, são criados objetos em diferentes escalas (segmentação em diferentes níveis). No segundo passo, os objetos passam a se relacionar através da definição da rede hierárquica (herança dos atributos que descrevem a classe) e da rede semântica (estrutura lógica de relação entre as classes).

Segundo Schwarz et al. (2002), o modelo de classificação de imagens orientado a objeto pode ser resumido como segue:

- as imagens são segmentadas em diferentes níveis com distintos detalhes;
- a hierarquia de classe e a descrição da classificação são definidas;
- sobre a imagem segmentada, realiza-se a classificação com base na hierarquia e nos descritores de classes propostos; e
- a exatidão temática da classificação é analisada.

2.3.1 Sistemas Especialistas

Os sistemas especialistas podem ser entendidos como uma das subáreas da Inteligência Artificial e se relacionam à concepção de plataformas que usam o conhecimento simbólico para simular o comportamento dos especialistas humanos. A idéia é o desenvolvimento de programas que possibilitem a utilização dos conhecimentos dos especialistas, nos quais seja permitido o armazenamento e o seqüenciamento de informações, bem como a auto-aprendizagem (PY, 2009). Um SE irá possuir uma base de conhecimento (BC), formada de fatos, regras e heurísticas sobre o domínio, tal como um especialista humano o faria, e deve ser capaz de oferecer sugestões e conselhos aos usuários e também adquirir novos conhecimentos e heurísticas com essa interação (FLORES, 2003).

Um ponto bastante importante no projeto de um sistema especialista é a escolha do método de representação de conhecimento. Existem três modelos conceituais para a realização dessa tarefa: Lógica, Redes Semânticas e Tabelas ou “Frames”. Como o aplicativo utilizado nesta pesquisa emprega redes semânticas no processo de interpretação de imagens (BENZ et al., 2004), aspectos teóricos importantes sobre esse tema serão apresentados na seqüência.

2.3.2 Rede Semântica

Conforme exposto anteriormente, na classificação orientada a objeto, os objetos passam a se relacionar através da definição da rede hierárquica (herança dos atributos que descrevem a classe) e da rede semântica (estrutura lógica de relação entre as classes). Para a classificação, o objeto é atribuído à classe para a qual o grau de pertinência é maior, sendo que este valor é determinado por meio de lógica fuzzy (PINHO, 2005).

Uma rede semântica é uma notação gráfica, composta por nós interconectados. Nesta representação, as classes herdam atributos e comportamentos das superclasses que as contêm. A Figura 2.6 (a) ilustra um exemplo de uma rede semântica (PINHO, 2005).

Nas redes semânticas hereditárias, os objetos com características em comum são agrupados em classes, onde as classes de um nível inferior (subclasses) herdam as características da classe do nível superior (superclasse). Na Figura 2.6 (b), há um exemplo de uma rede semântica hereditária, representando classes de vegetação em ambientes intra-urbanos a partir da interpretação de uma imagem de alta resolução espacial. Nesta rede semântica, os objetos das subclasses Arbórea, Arbustiva e Rasteira herdam o atributo NDVI¹ alto da superclasse Vegetação (PINHO, 2005).

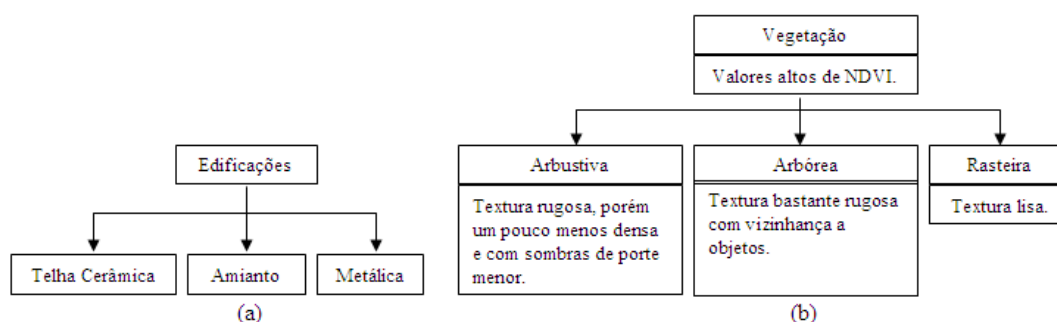


Figura 2.6 - (a) Rede semântica de tipos de coberturas de edificações (agregação); (b) Rede semântica de tipos de vegetação intra-urbana (hereditariedade).

¹ *Normalised Difference Vegetation Index* (Índice de Vegetação por Diferença Normalizada) é um índice de vegetação que é calculado a partir da reflectância (razão entre o fluxo radiante refletido pelo incidente em uma superfície - ρ) das bandas do vermelho e do infravermelho próximo. Este índice é calculado pela seguinte equação: $NDVI = (\rho_{\text{infravermelho próximo}} - \rho_{\text{vermelho}}) / (\rho_{\text{infravermelho próximo}} + \rho_{\text{vermelho}})$ (JENSEN, 2000).

2.3.3 Lógica Fuzzy

Lógica fuzzy é uma abordagem precisa da incerteza e aproximação de raciocínio. Mais especificamente, pode ser vista como uma tentativa de formalização/mecanização das duas notáveis capacidades humanas. Em primeiro lugar, a capacidade de conversar, raciocinar e tomar decisões racionais em um ambiente de incerteza, insegurança, falta de informação, informações conflitantes, parcialidade da verdade e parcialidade da possibilidade - em suma, em um ambiente de informação imperfeita. Em segundo, a capacidade de executar uma grande variedade de tarefas físicas e mentais sem quaisquer medições e cálculos (ZADEH, 2008).

Em uma formal definição de um conjunto fuzzy, pressupõe-se que $X = \{x\}$ é um conjunto finito (ou espaço) de pontos, os quais poderiam ser elementos, objetos ou propriedades; um subconjunto fuzzy, A de X , é definido por uma função, μ_A , ordenado em pares (MACBRATNEY; ODEH, 1997)(Equação 2.2):

$$A = \{x, \mu_A(x)\} \text{ para cada } x \in X \quad (2.2)$$

Na lógica fuzzy, o grau de pertinência é representado por uma aproximação de uma função gaussiana. Os objetos que possuem valores de atributos próximos ao centro da curva terão graus de pertinência altos, enquanto os objetos com valores mais próximos às extremidades da curva possuirão graus de pertinência baixos. Utilizando regras fuzzy, um objeto pode estar associado a várias classes com diferentes graus de pertinência. Dessa forma, a função de pertinência é responsável pelo mapeamento dos valores de um conjunto Y para o conjunto X , variando de 0 (não pertence) a 1 (pertence), e a classe considerada é aquela cujo grau de pertinência é maior (FLANDERS et al., 2003).

Segundo MacBratney e Odeh (1997), as operações aplicadas sobre os conjuntos fuzzy são basicamente as mesmas aplicadas em conjuntos booleanos. Na Figura 2.7, são apresentados alguns exemplos de funções fuzzy.




Figura 2.7 - Exemplos de funções *fuzzy*: a) triangular, b) trapezoidal e c) gaussiana.

Fonte: MacBratney e Odeh (1997).

2.3.4 Mineração de Dados

Mineração de dados refere-se à extração ou “mineração” de conhecimento proveniente de grandes quantidades de dados. Em muitos casos, considera-se o termo Mineração de Dados como sinônimo de *Knowledge Discovery in Databases* (KDD) ou Descoberta de Conhecimento em Bancos de Dados (DCBD). Na verdade, KDD é um processo mais amplo (HAN; KAMBER, 2000). A DCBD consiste no processo de identificar padrões que sejam válidos, previamente desconhecidos, potencialmente úteis e compreensíveis, visando melhorar o entendimento de um problema ou um procedimento de tomada de decisão (FAYYAD et al., 1996).

Mineração de dados é a etapa em DCBD responsável pela seleção dos métodos a serem utilizados para localizar padrões nos dados, seguida da efetiva busca por padrões de interesse em uma forma particular de representação, juntamente com a busca pelo melhor ajuste dos parâmetros do algoritmo para a tarefa em questão. Mineração de dados em imagens utiliza técnicas de DCBD e de outras áreas, respeitando a complexidade e a amplitude semântica deste domínio (SILVA, 2006).

Segundo Han e Kamber (2000), a DCBD é um processo que emprega uma seqüência iterativa das etapas (Figura 2.8), listadas abaixo:

- limpeza dos dados (para remoção de ruídos e inconsistências);
- integração dos dados (em que múltiplas fontes de dados podem ser combinadas, produzindo um único repositório de dados);

- seleção dos dados (etapa na qual são selecionados os atributos que interessam ao usuário);
- transformação dos dados (etapa na qual os dados são transformados em um formato apropriado para a aplicação de algoritmos de mineração, como, por exemplo, através de operações de agregação);
- **mineração de dados** (etapa essencial do processo, consistindo na aplicação de técnicas inteligentes, a fim de se extrair os padrões de interesse);
- avaliação (etapa na qual são identificados os padrões de interesse, de acordo com algum critério estabelecido pelo usuário);
- representação do conhecimento (as técnicas de visualização e representação do conhecimento são utilizadas para apresentar o conhecimento extraído para o usuário).




Figura 2.8 - Etapas do processo de KDD ou DCBD.

Fonte: Adaptado de Fayyad et al. (1996).

Segundo Pacheco (2009), o processo KDD resume-se na interseção de áreas distintas, como a Inteligência Computacional (IC), estatística e visualização dos dados. Na área de IC, particularmente, existem alguns tipos de técnicas e algoritmos que são utilizados em larga escala na fase de mineração, tais como: as Redes Neurais, os Sistemas Especialistas, a Lógica Fuzzy, os Sistemas Híbridos e os Algoritmos Genéticos.

Em um processo de KDD ou DCBD, supondo-se que os dados já foram devidamente selecionados e transformados, integrados em um armazém de dados (*Data Warehouse*),

e deles se eliminaram ruídos que poderiam afetar o processo de descoberta de conhecimento, as tarefas e técnicas de mineração comumente empregadas são: Análise de Regras de Associação, Análise de Padrões Seqüenciais, Classificação e Predição, Análise de Clusters (Agrupamentos), Análise de *Outliers* (FAYYAD et al., 1996).

Na seqüência, é necessária a escolha da técnica a ser utilizada no processo de mineração. Esta pode variar de acordo com a tarefa proposta. O Quadro 2.9 ilustra as principais tarefas de KDD e as técnicas mais utilizadas para mineração de dados.

Quadro 2.9 - Tarefas de KDD e técnicas para mineração de dados.

Tarefas de KDD	Técnicas
Associação	Estatística e Teoria do Conjunto
Classificação	Algoritmos Genéticos, Redes Neurais e Árvores de Decisão
Clustering	Redes Neurais e Estatística
Séries Temporais	Redes Neurais, Lógica Fuzzy e Estatística

Fonte: Pacheco (2009).

Após a escolha do algoritmo a ser aplicado, deve-se implementá-lo e adequá-lo ao problema em questão.

Existem vários algoritmos para cumprir a tarefa de mineração de dados, porém o algoritmo C4.5 apresenta um desempenho superior aos demais classificadores devido aos seguintes fatores (SILVA, 2006): (a) o algoritmo suporta atributos (não-categóricos) contínuos nos nós da árvore; (b) o C4.5 é largamente utilizado, testado e validado, o que indica a sua qualidade enquanto método computacional; (c) o algoritmo tenta gerar a menor árvore possível, uma vez que árvores menores são mais facilmente compreendidas e têm bom desempenho preditivo.

O algoritmo C4.5 está implementado em várias plataformas, como, por exemplo, o GeoDMA (Geographical Data Mining Analyst) (KORTING et al., 2009), cujo funcionamento é acoplado ao sistema TerraView, disponível livremente no site <http://www.dpi.inpe.br/terraview/>. TerraView é um sistema computacional capaz de lidar com bancos de dados espaciais, imagens e regiões resultantes do processo de

segmentação, além de outros dados geográficos, como, por exemplo, mapas de estradas, dados cadastrais, etc.

2.3.5 Mapa de Incerteza e Coeficiente de Concordância Kappa

O mapa de incerteza expressa a estabilidade da classificação. Consiste na espacialização das diferenças entre o maior e o segundo maior grau de pertinência fuzzy para cada objeto. Quanto maior esta diferença, mais estável a classificação. Do contrário, ocorre confusão entre duas ou mais classes (BENZ et al., 2004). O mapa é gerado pelo aplicativo Definiens Developer.

Outro parâmetro muito utilizado e eficiente para quantificar a exatidão de classificação de cobertura da terra é o índice Kappa, que é obtido mediante a adoção de uma referência para comparação com as classificações e/ou mapeamentos produzidos. Neste caso, a análise da exatidão dos mapeamentos é obtida através de uma matriz de confusão ou matriz de erro, sendo posteriormente calculado o índice Kappa de concordância (COHEN, 1960).

A estatística Kappa é uma medida de concordância usada em escalas nominais, que fornece uma idéia do quanto as observações reais se afastam daquelas esperadas, fruto do acaso, indicando, assim, quão legítimas são as interpretações. Landis e Koch (1977) atribuem uma valoração qualitativa a intervalos de valores do índice Kappa, estimado para avaliar a acurácia da classificação, de acordo com a Tabela 2.1 abaixo.

Tabela 2.1 - Qualidade da classificação associada a intervalos de valores do índice Kappa.

Índice Kappa	Qualidade
<0,00	Péssima
0,00 - 0,20	Ruim
0,21 - 0,40	Razoável
0,41 - 0,60	Boa
0,61 - 0,80	Muito Boa
0,81 - 1,00	Excelente

Fonte: Landis e Koch (1977).

CAPÍTULO 3

Material e Métodos

3.1 Área de Estudo

A área de estudo localiza-se no município de Uberlândia – MG. O município está situado no oeste do estado de Minas Gerais, na zona geográfica denominada Triângulo Mineiro. Possui uma área de 4.116 km² e é limítrofe aos municípios de: Tupaciguara, Araguari, Indianópolis, Uberaba, Veríssimo, Prata e Monte Alegre de Minas. A sede municipal está a 550 km da capital Belo Horizonte e tem como coordenadas geográficas: 18° 55' 07" S e 48° 16' 38" O (IBGE, 2007). A Figura 3.1 ilustra a posição geográfica do município no país.




Figura 3.1 - Área de estudo.

Fonte: MTE (2009).

Será utilizada como área de estudo um recorte da imagem (Figura 3.2 (a)) da malha urbana do município obtida pelo satélite IKONOS. A área de estudo está contida nessa área mais verticalizada, abrangendo os bairros Centro e Fundinho, e parte dos bairros Tabajaras, Martins e Osvaldo Rezende (Figura 3.2 (b)).

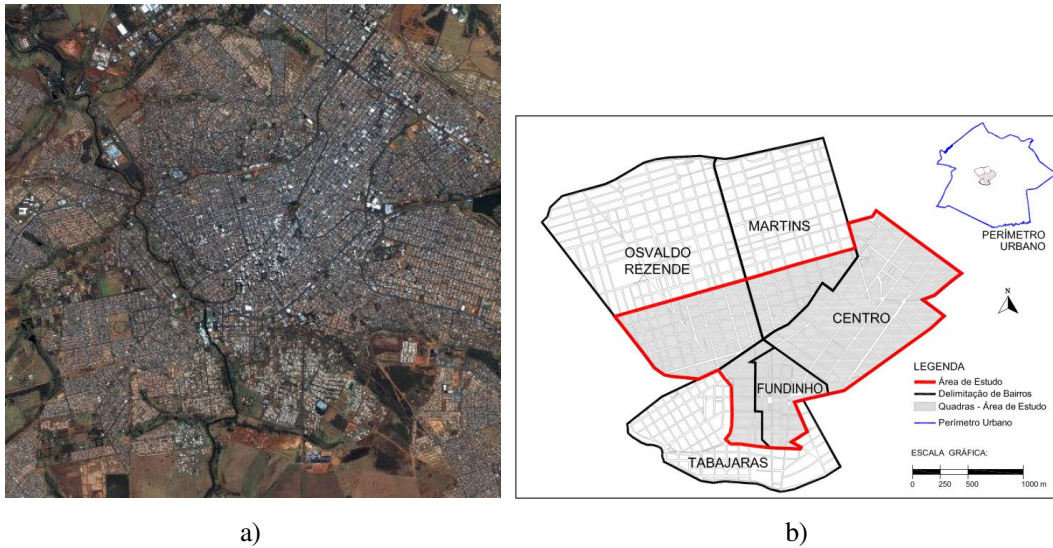


Figura 3.2 – a) Área de estudo retratada para uma imagem IKONOS e b) Delimitação da área de estudo.

Fonte: PMU/SEPLAMA (2007).

Segundo estimativa do IBGE (Instituto Brasileiro de Geografia e Estatística), a população de Uberlândia em 2007 era de 608.369 habitantes (IBGE, 2007).

O clima de Uberlândia é o tropical semi-úmido, com duas estações definidas, sendo o tipo climático Aw predominante, caracterizado por clima de cerrado, com inverno seco e chuvas de verão intensas, segundo a classificação de Pell et al. (2007). A pluviosidade anual varia em torno de 1.500 mm, e a temperatura média é de 22 °C (ROSA et al., 1991).

O município situa-se no domínio dos Planaltos e Chapas da Bacia Sedimentar do Paraná e se insere na subunidade do Planalto Meridional da Bacia do Paraná, caracterizando-se por apresentar relevo tabular, levemente ondulado, com altitude inferior a 1.000 m (CARRIJO; BACCARO, 2000).

Segundo Brito e Prudente (2005), o município de Uberlândia está inserido no bioma Cerrado, apresentando como principais tipos fisionômicos: vereda, campo limpo, campo sujo, cerrado, cerradão, mata de várzea, mata galeria ou ciliar e mata mesofítica. A hidrografia da região inclui o rio Paranaíba, tendo como afluentes os rios Araguari e

Tijucu. As fontes de abastecimento de água para a cidade são provenientes do rio Uberabinha, afluente do rio Araguari.

A forma de ocupação do centro de Uberlândia apresenta-se bem diversificada, com áreas verdes, construções baixas e assobradadas e edifícios residenciais e comerciais. Os materiais de cobertura do solo urbano encontrados na área são: vegetação arbórea e rasteira, solo exposto claro e escuro, piscina e asfalto. Quanto aos tipos de telhados, têm-se: coberturas metálicas, telhas de cerâmica claras e escuras, concreto e telhas de cimento amianto em tons claro, médio e escuro.

3.2 Dados de Entrada

Neste trabalho, serão utilizadas imagens orbitais de alta resolução espacial do sensor a bordo do satélite IKONOS-II obtidas em 27/06/2008. As Tabela 3.1 e 3.2 apresentam as características do satélite IKONOS-II e de sua carga útil, respectivamente.

Tabela 3.1 - Características do satélite IKONOS-II.

Missão	IKONOS-II
País/Região	Estados Unidos
Satélite	IKONOS-II
Lançamento	24/09/1999
Situação Atual	Ativo
Órbita	Heliossíncrona
Altitude	681 km
Inclinação	98,1°
Tempo de Duração da Órbita	98 min
Horário de Passagem	10:30 a.m.
Período de Revisita	3 dias
Instrumentos Sensores	PANCROMÁTICO E MULTIESPECTRAL

Fonte: Satimagingcorp (2009).

Tabela 3.2 - Características do sensor a bordo do satélite IKONOS.

Sensor	Bandas Espectrais	Resolução Espectral	Resolução Espacial	Resolução Temporal	Faixa Imageada
PANCROMÁTICO	PAN	0,45 - 0,90 μm	1 m	2,9 dias	
	AZUL	0,45 - 0,52 μm			
	VERDE	0,52 - 0,60 μm			
	VERMELHO	0,63 - 0,69 μm			
MULTIESPECTRAL	INFRAVERMELHO PRÓXIMO	0,76 - 0,90 μm	4 m	1,5 dias	13 X 13 km

Fonte: Satimagingcorp (2009).

Com resolução espacial de 1 m no modo pancromático e de 4 m nas bandas multiespectrais, há a possibilidade de geração de imagens coloridas fusionadas com 1m de resolução, permitindo a discriminação de objetos de 1 m² de área ou maiores. As imagens IKONOS II possuem uma elevada precisão cartográfica e uma resolução radiométrica de 11 bits (2.048 níveis de cinza), que aumenta o poder de contraste e de discriminação dos alvos presentes nas cenas. Além disso, o IKONOS tem capacidade de efetuar visadas no sentido de sua órbita e lateralmente, aumentando a frequência de revisita e possibilitando a aquisição de par estereoscópico, utilizado para trabalhos de restituição de altimetria.

Além dos dados IKONOS, serão utilizados dados laser aerotransportados, obtidos a partir de levantamento realizado pela empresa Esteio Engenharia e Aerolevantamentos S.A (2003/2004), recobrando parte da região central da cidade de Uberlândia – MG. Esses dados foram fornecidos pela Prefeitura Municipal de Uberlândia. O perfilamento a laser foi realizado com o aparelho ALTM 2025 da fabricante canadense Optech Inc., cuja precisão altimétrica é de 0,15 m (dados brutos). Na base de dados da Prefeitura Municipal de Uberlândia, as curvas de nível são fornecidas de m/m, e a precisão altimétrica determinada pelo PEC (Padrão de Exatidão Cartográfica) é de 1/2 equidistância, o que corresponde a 0,5 m.

3.3 Metodologia

O diagrama de blocos da Figura 3.3 apresenta a metodologia proposta neste trabalho. Detalhes das fases de processamento são apresentados a seguir.

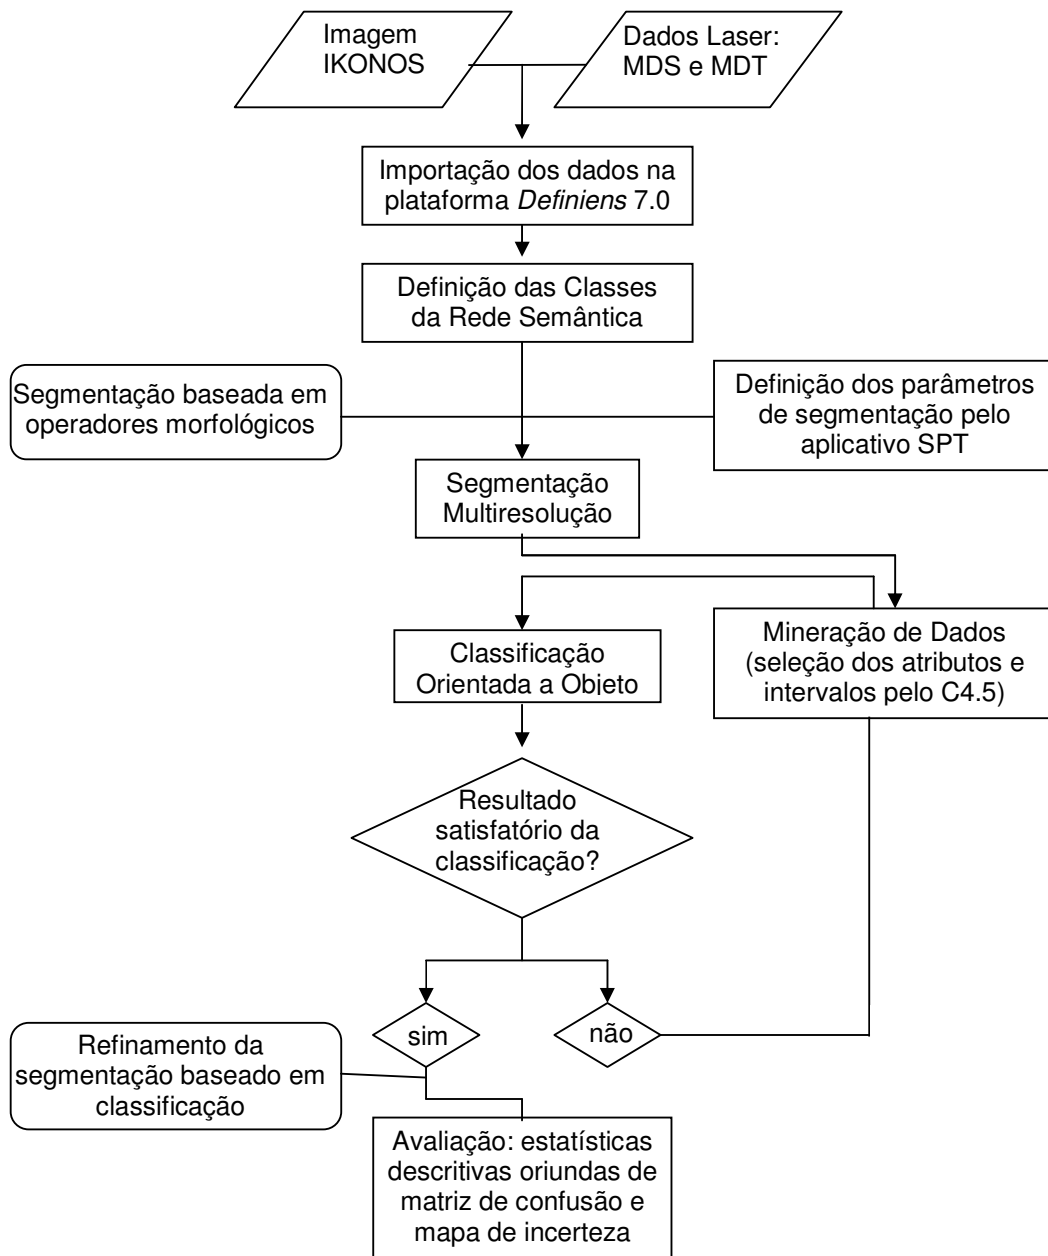


Figura 3.3 - Diagrama de blocos da metodologia proposta.

3.4 Estimativa dos Parâmetros de Segmentação no Aplicativo SPT

Nesta etapa do trabalho, será utilizado o aplicativo SPT (Segmentation Parameters Tuner), desenvolvido pelo Departamento de Engenharia Elétrica da PUC-RJ (Pontifícia Universidade Católica do Rio de Janeiro) e que opera em ambiente MATLAB.

O SPT usa um algoritmo genético (AG) para identificar valores ótimos para os parâmetros de segmentação (peso de bandas, fator de escala, cor, forma, compacidade, suavidade) dentro de um espaço de busca. O valor mais satisfatório é estabelecido por uma função objetiva, que mede o nível de concordância entre o resultado da segmentação e um conjunto de amostras de referência.

3.5 Importação dos Dados de Laser e Ópticos na Plataforma Definiens 7.0

Nesta fase do trabalho, será realizada a importação dos dados de laser e ópticos na plataforma Definiens 7.0. No que se refere aos dados ópticos, será feita a importação das quatro bandas multiespectrais e da banda pancromática de uma imagem IKONOS recobrimdo a área de estudo. Quanto aos dados de perfilamento a laser, será feita a importação do MDS e MDT em formato raster, bem como da banda de intensidade do sinal de retorno dos diferentes ecos.

No desenvolvimento do trabalho, o modelo digital de alturas (MDA), obtido pela diferença entre o MDS e o MDT, poderá ser utilizado.

3.5.1 Classificação

3.5.1.1 Segmentação Multiresolução e Definição da Rede Hierárquica

O sistema Definiens Developer, que será utilizado nesta pesquisa, necessita da definição dos objetos (segmentos) na imagem para o procedimento de classificação.

Pretende-se integrar as duas metodologias mencionadas na Seção 2.24, visando tornar o processo de segmentação de objetos regulares mais eficiente e automatizado.

Com este objetivo, a segmentação multiresolução através de um algoritmo de crescimento de regiões (BENZ et al., 2004) será empregada. Os parâmetros da segmentação são fator de escala, cor e forma, bem como compacidade e suavidade, conforme descrito na Seção 2.2.1.

Pretende-se estabelecer, ao menos, três níveis de segmentação: no primeiro, que corresponde ao nível mais “grosseiro” da segmentação, será introduzido um *layer* de arruamentos e quadras. No segundo nível, almeja-se segmentar a imagem para classificação intermediária, contendo classes como vegetação, áreas construídas, solo exposto e sombra, por exemplo. Por fim, no terceiro nível, que se refere ao de segmentação mais refinada, pretende-se segmentar as classes para classificação de cobertura do solo, tais como telha cerâmica (clara e escura), cobertura de concreto/amianto (clara, média e escura), asfalto, piscinas.

3.5.1.2 Seleção de Atributos e de Intervalos de Valores pelo Método C4.5

Existem diversos algoritmos de mineração que poderiam ser utilizados nesta etapa da pesquisa, tais como PART, OneR, Prism, Id3, C4.5, NaiveBayes, Decision Table e Redes Neurais. Porém, optou-se pela escolha do classificador C4.5 por árvore de decisão como a melhor alternativa, em função dos fatores apresentados na Seção 2.3.4.

Será utilizado o algoritmo C4.5 que está implementado no software GeoDMA, (Geographical Data Mining Analyst), cujo funcionamento é acoplado ao sistema TerraView.

3.5.1.3 Classificação de Cobertura do Solo Urbano

Almeja-se, neste trabalho, identificar os principais materiais aplicados nas vias pavimentadas, nas coberturas das construções, bem como os principais tipos de cobertura de feições naturais, como vegetação, por exemplo.

As classes serão definidas a partir da interpretação visual da imagem de satélite IKONOS. As chaves de interpretação poderão ser elaboradas a partir dos elementos de

cor, textura, forma, tamanho, sombra, altura, padrão e localização (FLORENZANO, 2002). As classes pré-definidas são apresentadas no Quadro 3.4.

Quadro 3.4 - Classes de cobertura do solo urbano selecionadas para o estudo.

Vegetação	Arbórea
	Rasteira
Telha Cerâmica	Clara
	Escura
Concreto/Amianto	Claro
	Médio
	Escuro
Solo Exposto	Claro
	Escuro
Piscina	
Asfalto	
Sombra	

3.5.1.4 Avaliação da Classificação

A classificação obtida será avaliada através de dois procedimentos: mapa de incerteza ou de instabilidade da classificação e matriz de confusão para determinação do coeficiente de concordância Kappa (K).

CAPÍTULO 4

RESULTADOS ESPERADOS E CRONOGRAMA

Ao final desta pesquisa, espera-se que a metodologia proposta mostre resultados melhores do que os métodos de classificação tradicionais para classificação de objetos urbanos. O uso de dados LIDAR em conjunto com os dados óticos pode, de certa maneira, fornecer informações complementares que podem melhorar a caracterização dos alvos urbanos e, assim, melhorar a classificação. Da mesma forma, o uso de técnicas mais avançadas de segmentação (abordagem multiresolução, AG, re-segmentação, morfologia matemática) certamente será um fator de contribuição para melhoria dos resultados da classificação.

Tabela 4.1 - Cronograma de atividades.

Atividades	2009										2010	
	M	A	M	J	J	A	S	O	N	D	J	F
Revisão bibliográfica	■	■	■	■	■	■	■	■				
Definição de parâmetros para segmentação pelo Aplicativo SPT	■	■										
Segmentação baseado em operadores morfológicos		■	■									
Mineração de Dados			■	■								
Segmentação multi-resolução			■	■	■							
Classificação orientada a objeto			■	■	■	■						
Refinamento da segmentação baseado em classificação						■	■					
Avaliação da classificação								■	■			
Redação da dissertação	■	■	■	■	■	■	■	■	■	■	■	■

REFERÊNCIAS BIBLIOGRÁFICAS

ANTUNES, A. F. B.; LINGNAU, C.; CENTENO, J. A. S. Object- Oriented Analysis and Semantic Network for High Resolution Image Classification. **Bol. Ciênc. Geod.** v. 9, no 2, p.233-242, jul-dez, 2003.

BAATZ, M.; SCHÄPE, A. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. **Proceedings...** STROBL, J., BLASCHKE, T. Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGITSymposium Salzburg 2000. Karlsruhe. Herbert Wichmann Verlag, 2000. p. 12 – 23.

BALTSAVIAS, E.P., **Airborne Laser Scanning: Basic Relations and Formulas**, Institute of Geodesy and Photogrammetry, Switzerland, 1999.

BARTELS, M; WEI, H. SEGMENTATION OF LIDAR DATA USING MEASURES OF DISTRIBUTION. **Proceedings...** "ISPRS Comm. III Symposium, Photogrammetric Computer Vision, Bonn : Germany (2006)".

BATISTA, M. A. F.; GUIMARÃES, L. N. F. Algoritmos Genéticos em Ambientes Paralelos. V WORCAP, INPE, **Anais...** São José dos Campos, 26 e 27 de outubro de 2005.

BENZ, U. C.; HOFMANN, P.; WILLHAUCK, G.; LINGENFELDER, I.; HEYNEN, M. Multi-resolution, object-oriented fuzzy analysis of remote sensing data for GIS-ready information. **ISPRS Journal of Photogrammetry & Remote Sensing**, n. 58, 239 - 258 p., 2004.

BRITO, J.L.S.; PRUDENTE, T. D. Análise Temporal do Uso do Solo e Cobertura Vegetal do Município de Uberlândia-MG, Utilizando Imagens ETM+/Landsat 7. **Rev. Sociedade & Natureza**, Uberlândia, v.17 , n.32, p.37-46, jun. 2005.

BURROUGH, P. A. **Principles of Geographical Information System for Land Resources Assessment**. New York: Oxford University Press, 1986.

CARRIJO, B. R.; BACCARO, C.A.D. Análise sobre a erosão hídrica na área urbana de Uberlândia (MG). Ver. **Caminhos de Geografia**, Uberlândia, Edufu, V.1, n2, p.70-80, 2000. Disponível em: <<http://www.caminhosdegeografia.ig.ufu.br/viewissue.php?id=41>>. Acesso em 22 de janeiro de 2009.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and psychological measurement**, v.20, n.1, p.37-46, 1960.

- DEFINIENS IMAGING. **eCognition**: user guide. 2000, 468 p. Disponível em: <http://www.definiens.com/definiens-developer_7_7_8.html>. Acesso em: 8 de fevereiro de 2008.
- DESCLÉE, B.; BOGAERT, P.; DEFOURNY, P. Forest change detection by statistical object-based method. **Remote Sensing of Environment**. v. 102, p. 1–11, 2006.
- FAYYAD, U. M.; PIATESKY-SHAPIO, G.; SMYTH, P.. “From Data Mining to Knowledge Discovery: An Overview”. **Advances in Knowledge Discovery and Data Mining**, AAAI Press, 1996.
- FEITOSA, R. Q.; COSTA, G. A. O. P.; CAZES, T. B.; FEIJÓ, B.. A genetic approach for the automatic adaptation of segmentation parameters. In: *1st International Conference on Object Based Image Analysis*, Salzburg. **Proceedings...** 2006.
- FLANDERS, D.; HALL-BEYER, M.; PEREVERZOFF, J. Preliminary evaluation of eCognition object-based software for cut block delineation and feature extraction. **Canadian Journal of Remote Sensing**, v. 29, n. 4, p. 441–452, 2003.
- FLORENZANO, T. G.. **Imagens de satélite para estudos ambientais**. São Paulo, SP: Oficina de Textos, 2002. 97 p.
- FLORES, C. D. Fundamentos dos Sistemas Especialistas. In: BARONE, D. A. C. (Ed.). **Sociedades Artificiais**: a nova fronteira da inteligência nas máquinas. Porto Alegre: Bookman, 2003. p.332.
- FREDRICH, C. M. B.; FEITOSA, R. Q.. AUTOMATIC ADAPTATION OF SEGMENTATION PARAMETERS APPLIED TO INHOMOGENEOUS OBJECTS DETECTION. In: GEOBIA 2008. **Proceedings...** University of Calgary Calgary, Alberta, Canadá. August 5 - 8, 2008.
- HAALA, N. Combining Multiple data source for urban data acquisition. In: **Photogrammetric week**, 1999. Wichmann Verlag, Heidelberg, Germany.
- HAN, J.; KAMBER, M. **Data Mining**: Concepts and techniques. 550 p. Morgan Kaufmann Publishers 2000. Simon Fraser University, CA.
- HOFFMANN, A; VEGT, J.W.V. New sensor systems and new classification methods: laser-and digital camera-data meet object-oriented strategies. **Journal for Spatial Information and Decision Making**, n. 6/01, p. 18-23, June 2001.
- IBGE, Instituto Brasileiro de Geografia e Estatística. **Cidades**. Disponível em: <<http://www.ibge.gov.br/cidadesat/default.php>> Acesso em 22 de janeiro de 2009.
- JENSEN, J. R. **Remote sensing of the environment an Earth perspective**. New Jersey: Prentice Hall Upper Saddle River, 2000. 544 p.

KORTING, T. S.; FONSECA, L. M.; ESCADA, M. I. S.; SILVA, F. C.; SILVA, M. P. S. GeoDMA - A novel system for spatial data mining. Data Mining Workshops, 2008. ICDMW '08. **Proceeding...** IEEE International Conference on. Pisa, Italy. 2008.

KORTING, T. S.; FONSECA, L. M. G.; ESCADA, M. I. S.; CÂMARA, G. GeoDMA – Um sistema para mineração de dados de sensoriamento remoto. In: Simpósio Brasileiro de Sensoriamento Remoto, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. CD-ROM.

KORTING, T. S. **Um paradigma para re-segmentação de imagens de alta resolução.** 2007. 67p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007.

LANDIS, J. R.; KOCH, G. G.. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174. 1977.

MCBRATNEY, A. B.; ODEH, I. O. A. Application of fuzzy sets in soil science: fuzzy logic, fuzzy measurements and fuzzy decisions. **Geoderma**, n. 77, 85 – 113 p., 1997.

MARTINS, M. A. R.; FELIX, D.; KERSTING, A. P. B. Análise do Padrão de Exatidão Cartográfica (PEC) para dados provenientes do sistema laser - ALTM 2050. In: Congresso Brasileiro de Cadastro Multifinalitário, 6., 2004, Florianópolis, **Anais...**(CD-ROM), UFSC, 2004.

MTE. Disponível em: <<http://perfildomunicipio.caged.gov.br/brasil.asp>>. Acesso em: 26 Fev. 2009.

NEGRON, R.A.R; NUNES, J.L.; BRITO, S. A Tecnologia “Laser Scanning”: Uma Alternativa para o Mapeamento Topográfico. In: XXI Congresso Brasileiro de Cartografia. 2003. Belo Horizonte, MG. **Anais...** 227/SR25. Disponível em: <http://www.cartografia.org.br/xxi_cbc/227-SR25.pdf>. Acesso em: 25 jan. 2009.

PACHECO, M. A. **Notas de Aula em Computação Evolucionária.** Disponível em: <<http://www.ica.ele.puc-rio.br/home/index.rails>>. Acesso em: 7 fev. 2009.

PINHO, C. M. D. **Análise Orientada a Objetos de Imagens de Satélite de Alta Resolução Espacial Aplicada à Classificação de Cobertura do Solo no Espaço Intra-Urbano: O Caso de São José dos Campos - SP.** 2005. 182 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.

PREFEITURA MUNICIPAL DE UBERLÂNDIA. **Banco de Dados Integrados Resumido de Uberlândia.** Uberlândia: SEPLAMA (Secretaria Municipal de Planejamento Urbano e Meio Ambiente), 2009. Disponível em: <<http://www.uberlandia.mg.gov.br>>. Acesso em: 24 de Janeiro de 2009.

- PY, M. X. **Sistemas Especialistas: uma introdução**. Instituto de Informática Universidade Federal do Rio Grande do Sul. Porto Alegre, RS. Disponível em: <<http://www.inf.ufrgs.br/procpar/disc/cmp135/trabs/mpy/sistemasespecialistas.pdf>>. Acesso em: 17 Jan. 2009.
- ROSA, R., LIMA, S. C.; ASSUNÇÃO, W. L.. Abordagem preliminar das condições climáticas de Uberlândia (MG). **Rev. Sociedade & natureza**. Uberlândia: EDUFU, v.3, n.5 e 6, p.91-108, dez. 1991.
- SATELLITE IMAGING CORPORATION. **IKONOS Satellite Imagery and Satellite System Specifications**. Disponível em: <<http://www.satimagingcorp.com/satellite-sensors/IKONOS.html>>. Acesso em: 16 de Janeiro de 2009.
- SBGMAPS. Disponível em: <www.sbgmaps.com/lidar.htm>. Acesso em: 15 Fev. 2009.
- SCHIMALESKY, V. **Avaliação da Qualidade da Informação Altimétrica Derivada da Varredura a Laser em uma Região Coberta por Vegetação: Um Estudo de Caso**. 2007. 93 p. Dissertação (Mestrado em Ciências Geodésicas). Universidade Federal do Paraná. Curitiba/PR, 2007.
- SCHWARZ, M; STEINMEIER, C.; WASER, L. **Detection of storm losses in alpine forest areas by different methodic approaches using high-resolution satellite data**. 2002. Disponível em: <http://www.definiens.com/case-studies_20_15_16.html>. Acesso em: 25 jan. 2009.
- SILVA, M. P. S. **Mineração de Padrões de Mudança em Imagens de Sensoriamento Remoto**. 2006. 83 p. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.
- SOILLE, P.: **Morphological Image Analysis: Principles and applications**. Springer-Verlag, Berlin (1999).
- TARSHA-KURDI, F.; LANDES, T.; GRUSSENMEYER, P.; SMIGIEL, E. New Approach for Automatic Detection of Buildings in Airborne Laser Scanner Data Using First Echo Only. **In: "ISPRS Comm. III Symposium, Photogrammetric Computer Vision, Bonn: Germany (2006)**.
- UBA, D. M. **Detecção de Objetos Regulares em Imagens de Alta Resolução Utilizando Casamento de Modelos**. 2008. 41 p. Proposta de Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2008.
- ZADEH, L. A. Is there a need for fuzzy logic? Department of EECS, University of California, Berkeley, CA 94720-1776, United States. **Science Direct**. Information Sciences 178 (2008) 2751–2779.