

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE PESQUISAS HIDRÁULICAS

ESTIMATIVA DE PARÂMETROS FÍSICOS DE BACIAS
UTILIZANDO TÉCNICAS DE SENSORIAMENTO REMOTO
E O SISTEMA DE INFORMAÇÕES GEOGRÁFICAS.

NÉSTOR ALDO CAMPANA

*Dissertação submetida ao Programa de Pós-Graduação em
Engenharia de Recursos Hídricos e Planejamento Ambiental
da Universidade Federal do Rio Grande do Sul como
requisito parcial para a obtenção do título de Mestre em
Engenharia.*

Porto Alegre, fevereiro de 1992

APRESENTAÇÃO

Este trabalho foi desenvolvido no Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental do Instituto de Pesquisas Hidráulicas da Universidade Federal do Rio Grande do Sul, sob a orientação do Prof. Vitor Haertel da Universidade Federal do Rio Grande do Sul e co-orientado pelo Prof. Carlos Tucci da Universidade Federal do Rio Grande do Sul.

A realização deste trabalho só foi possível com o auxílio de muitas pessoas, às quais expresso agora minha profunda gratidão:

Aos professores Vitor Haertel e Carlos Tucci, pelas críticas, sugestões, incentivo e dedicação durante todas as etapas. Com eles divido os méritos que possam existir neste trabalho.

À Universidade Federal de Rio Grande do Sul através do Instituto de Pesquisas Hidráulicas, e aos professores pela contribuição dos ensinamentos ministrados.

Ao Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, que permitiu a utilização de seus equipamentos, e aos operadores José Carlos e Laurindo pelo constante apoio técnico durante a realização deste trabalho.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pelo apoio financeiro.

Ao Instituto Nacional de Pesquisas Espaciais-INPE e SPOT IMAGE pelo fornecimento das imagens digitais, que tornaram possível

a realização deste trabalho.

A meus colegas do curso pela amizade e pelas críticas e sugestões ao projeto de pesquisa.

Meus pais, Shirley e Aldo, tiveram a participação maior. Foram eles que deram o estímulo para começar e, mesmo longe, conseguiram se fazer sempre presentes.

E, finalmente, agradeço a Luciene, minha esposa, que conseguiu trazer nos momentos mais difíceis apoio, carinho e muita força para chegar até aqui.

RESUMO

Neste trabalho foi desenvolvida uma metodologia para estimar a fração de áreas impermeáveis de uma bacia hidrográfica, a partir da classificação supervisionada de imagens digitais. O algoritmo usado é baseado na representação Fuzzy, que apresenta maior precisão global na classificação e na identificação dos tipos e proporções das classes presentes nos pixels mistura. Os resultados da classificação de uma imagem SPOT são apresentados e analisada sua precisão.

Também, foi desenvolvido um software para a extração das características topográficas e delimitação de bacias e da rede de drenagem, a partir de modelos numéricos do terreno. Os algoritmos foram implementados em programas interrelacionados em linguagem C.

ABSTRACT

In this work have been developed a methodology to estimate the impermeable rate of a watersheds, from remote sensing image supervised classification. The algorithm used is based on the Fuzzy representation, wich presents the major achievements including higher overall classification accuracy and identification of types and proportions of component cover class in mixed pixels. Results of classifying a SPOT image are presented and their accuracy is analyzed.

Also, software tools have been developed to extract topographic characteristics and to delineate watersheds and overland flow paths from digital elevation medels. The tools are purpose C programs interfaced.

SUMÁRIO

	Página
1 - INTRODUÇÃO.....	01
2 - REVISÃO BIBLIOGRÁFICA.....	04
2.1 - Princípios de sensoriamento remoto.....	04
2.2 - Satélite SPOT.....	06
2.3 - Sistema de informações geográficas.....	10
2.4 - Mapa de cobertura do solo e fração de áreas impermeáveis.....	15
2.5 - Modelo numérico do terreno (MNT).....	21
2.6 - Rede de drenagem superficial e dos divisores de água.....	23
3 - CLASSIFICAÇÃO DE IMAGENS DIGITAIS.....	27
3.1 - Processo de classificação e o problema do pixel mistura.....	27
3.2 - Algoritmos de classificação de imagens di- gitais.....	30
3.2.1 - Algoritmo de classificação por Má- xima Verossimilhança.....	31
3.2.2 - Algoritmo de classificação K-Mé- dias.....	35
3.3 - Interpretação geométrica do problema de estimação de proporções.....	37
3.4 - Significado da distância de Mahalanobis...	38
3.5 - Algoritmo de classificação baseado na re- presentação Fuzzy.....	39
3.5.1 - Representação Fuzzy de informação	

geográfica.....	40
3.5.2 - Partição Fuzzy do espaço multiespectral.....	41
3.5.3 - Parâmetros Fuzzy.....	43
3.5.4 - Análise das assinaturas espectrais dos componentes da mistura.....	45
3.5.5 - Função pertinência Fuzzy.....	49
4 - CARACTERÍSTICAS TOPOGRÁFICAS DA BACIA.....	52
4.1 - Divisor de águas e rede de drenagem superficial.....	52
4.2 - Outras características topográficas.....	56
5 - EXPERIMENTOS.....	58
5.1 - Área de estudo.....	58
5.2 - Materiais.....	59
5.3 - Procedimento metodológico.....	60
5.3.1 - Fase I.....	61
5.3.2 - Fase II.....	76
6 - CONCLUSÕES E LIMITAÇÕES.....	81
7 - BIBLIOGRAFIA.....	84

LISTA DE TABELAS

	Página
2.1 - Principais aplicações potenciais das bandas SPOT.....	09
2.2 - Valores de impermeabilidade recomendados pelo SCS.....	16
2.3 - Valores de impermeabilidade recomendados pelo UDFCD.....	16
2.4 - Exemplo de classificação multi-nível.....	17
2.5 - Materiais necessários para cada nível da classificação multi-nível.....	17
2.6 - Tamanho mínimo das áreas a serem mapeadas.....	18
2.7 - Percentagens da área da bacia ocupada com os diferentes tipos de uso-cobertura.....	19
2.8 - Resultados da classificação de cobertura do solo por técnicas convencionais e LANDSAT.....	20
4.1 - Exemplo das quatro condições possíveis na determinação de orientação de cada célula.....	55
5.1 - Coeficiente de correlação linear entre as bandas multiespectrais SPOT.....	65
5.2 - Distância Euclidiana ponderada máxima, mínima e média para as diferentes combinações.....	65
5.3 - Matrizes pertinência obtidas com a função pertinência linear e a função pertinência exponencial.....	70
5.4 - Avaliação dos resultados da classificação.....	75
5.5 - Distribuição da área da bacia do arroio do Meio em função da altitude.....	80

LISTA DE FIGURAS

	Página
2.1 - Diagrama esquemático de um típico SIG.....	11
2.2.a - Representação de uma área no formato raster...	13
2.2.b - Representação de uma área no formato vetoreal.	13
2.3 - Interpolação de pontos irregularmente espaçados e geração da matriz de altitude.....	22
2.4 - Exemplo da estrutura do modelo de triangulação TIN.....	23
2.5 - Estimativa das classes de orientação e janela de determinação a montante relativos ao centro, ponto "in".....	26
3.1.a - Pixel mistura causado por objetos menores do que o elemento da cena.....	29
3.1.b - Pixel mistura causado por limites de objetos maiores dentro do elemento da cena.....	29
3.2 - Interpretação geométrica do problema de estimação de proporções para três componentes e duas bandas espectrais.....	38
3.3 - Partição "hard" do espaço espectral e superfícies de decisão.....	41
3.4 - Matriz pertinência de um pixel e partição Fuzzy do espaço multiespectral.....	42
3.5 - Comportamentos espectrais de alguns alvos característicos de áreas urbanas.....	46
3.6 - Simlex de sinais para três componentes e duas bandas espectrais.....	47
3.7.a - Simplex de sinais bem-condicionado.....	48
3.7.b - Simplex de sinais mal-condicionado.....	48
4.1.a - Matriz de altitudes com depressão e esquema da	

	janela utilizada para detectar depressões.....	54
4.1.b	- Matriz de altitudes com as depressões preenchidas.....	54
5.1	- Bacia do arroio Dilúvio, Porto Alegre - RS....	59
5.2	- Relação de bandas SPOT para cinco classes.....	62
5.3	- Relação de bandas SPOT para as classes que apresentam maior confusão.....	63
5.4	- Simplex de sinais mal-condicionado.....	68
5.5	- Simplex de sinais bem-condicionado.....	69
5.6	- Matriz pertinência para a classe área construída.....	71
5.7	- Matriz pertinência para a classe vegetação....	72
5.8	- Matriz pertinência para a classe solo exposto.....	73
5.9	- Posição dos pontos classificados no simplex de sinais.....	74
5.10	- Distribuição espacial das áreas impermeáveis..	75
5.11	- MNT da área sob estudo.....	77
5.12	- MNT da bacia do arroio do Meio.....	78
5.13	- Representação volumétrica da rede de drenagem da bacia do arroio do Meio.....	79
5.14	- Curva hipsométrica.....	80

LISTA DE SÍMBOLOS

ϕ_r	Fluxo refletido;
ϕ_i	Fluxo incidente;
ϕ_t	Fluxo transmitido;
ϕ_a	Fluxo absorvido;
ρ	Reflectância;
α	Absortância;
τ	Transmitância;
L_{ij}	Área do mapa correspondente à classe i e representada como classe j;
A	Área mal representada;
M_i	Classes de mapa;
n	Número de classes;
$L_x(w_i)$	Perda esperada;
$\lambda(w_i/w_j)$	Função de perda;
$p(w_j/x)$	Probabilidade condicional de que dado o pixel x, ocorra a classe w_j ;
$p(x/w_j)$	Função densidade de probabilidade associada à classe w_j ;
$p(x)$	Função densidade de probabilidade associada a x;
$p(w_j)$	Probabilidade "a priori" da classe w_j ;
w_j	Classes de coberturas;
$g_i(x)$	Função discriminante;
μ_i	Média da classe w_i ;
Σ_i	Matriz de variância e covariância da classe w_i ;
$S_j(k)$	Agrupamento k na iteração j;
J_i	Índice de desempenho na iteração i;
f_{F_i}	Função pertinência da classe F_i ;
$P(A)$	Probabilidade do evento A;
μ_j^*	Média Fuzzy da classe j;
σ_j^*	Variância Fuzzy da classe j;

Σ_j^*	Matriz de variância e covariância Fuzzy da classe j;
r	Função estritamente de crescente da distância $d(x, \mu_i)$;
$d(x, \mu_i)$	Distância do pixel x ao elemento ideal da classe i;
$P_i^*(x)$	Função densidade de probabilidade Normal Multivariada para um evento Fuzzy;
D	Declividade;
Z_c	Altitude da célula central;
Z_v	Altitude da célula vizinha;
dx	Resolução horizontal da grade;
dy	Resolução vertical da grade;
d	Distância Euclidiana ponderada;
A_i	Número digital médio da classe A na banda i;
B_i	Número digital médio da classe B na banda i;
S_p^2	Variância ponderada para as classes A e B;
N_A	Número de amostras para a classe A;
N_B	Número de amostras para a classe B.

1 - INTRODUÇÃO

A modelação matemática é um instrumento muito difundido para o conhecimento da dinâmica dos sistemas hidrológicos. Esta, entretanto, requer uma certa quantidade de dados referentes a determinadas características físicas e hidrológicas da bacia, algumas das quais, são de difícil obtenção através de técnicas convencionais.

Na modelação matemática dos processos hidrológicos é preciso conhecer algumas características da bacia tais como: área da bacia, declividade, cobertura do solo, fração de áreas impermeáveis, canais de drenagem e relevo da bacia. Deve-se conhecer, ainda, os dados hidrológicos tais como vazão, precipitação e evapotranspiração. Em bacias localizadas em áreas urbanas, um parâmetro importante é o que diz respeito às áreas impermeáveis. Nas regiões metropolitanas, hoje em rápido processo de crescimento, o conhecimento atualizado desse parâmetro reveste-se de importância. Neste particular um aspecto a ser considerado é o que diz respeito à dificuldade na quantificação de áreas impermeáveis por meio de métodos convencionais.

A determinação de tais parâmetros por métodos tradicionais requer, normalmente, trabalhos de campo que demandam muito tempo para serem executados, além de seu elevado custo. As técnicas de sensoriamento remoto, que fazem uso de imagens digitais multiespectrais e pancromáticas fornecidas por satélites de sensoriamento remoto, como por exemplo o sistema SPOT (Systeme Probatoire d'Observation de la Terra), em combinação com a técnica do sistema de informações geográficas (SIG), tornam possível a obtenção de modo rápido, preciso e com baixo custo de alguns

parâmetros e características físicas de uma bacia tais como cobertura do solo, rede de drenagem, declividade, etc. O sistema de informações geográficas possibilita a manipulação e cruzamento dessas informações de modo eficiente e rápido. Uma vantagem adicional dessas técnicas é o conhecimento da distribuição espacial dos parâmetros estimados, o qual é imprescindível na modelação de sistemas hidrológicos usando modelos de tipo "distribuído". As vantagens das técnicas de sensoriamento remoto são maiores quando se trabalha com sistemas hidrológicos extensos e/ou situados em regiões de difícil acesso, situação muito frequente no Brasil e em diversos outros países.

Nesta dissertação foi desenvolvida uma metodologia para o mapeamento de uma bacia hidrográfica urbana em termos de cobertura do solo com o propósito final de estimar a fração de áreas impermeáveis.

Como consequência da composição altamente complexa das áreas urbanas, formadas por edifícios de apartamentos e lojas comerciais, residências unifamiliares, sistema viário, parques, estacionamentos, shopping centers e outros, que além de estarem constituídos por materiais diferentes apresentam pequenas dimensões e espaçamento, exige que o levantamento detalhado do uso e cobertura do solo a partir da classificação de imagens digitais seja realizado utilizando-se produtos que apresentam alta resolução espacial e preferivelmente, também, alta resolução espectral. Neste trabalho foi privilegiada a resolução espacial. Decidiu-se portanto trabalhar com imagens multiespectrais SPOT, que apresentam melhor resolução espacial em relação aos sistemas LANDSAT TM e LANDSAT MSS.

Além dos dados obtidos por sensoriamento remoto, isto é, fração de áreas impermeáveis, nesta dissertação foi implementada um algoritmo para a extração automática de algumas características topográficas da bacia, tais como: divisor de águas, rede de

drenagem, área de drenagem e curva hipsométrica. Isso foi feito utilizando o sistema de informações geográficas.

Supõe-se que os parâmetros descritos anteriormente, normalmente estimados por métodos convencionais podem ser obtidos com a precisão suficiente requerida pelos modelos matemáticos de simulação através de técnicas de sensoriamento remoto e SIG, com maior rapidez e eficiência econômica, ou seja, com custos menores.

2 - REVISÃO BIBLIOGRÁFICA

2.1 - PRINCÍPIOS DE SENSORIAMENTO REMOTO

Pode-se definir sensoriamento remoto como a ciência e a técnica que visa obter informações a respeito de objetos (alvos) a partir de medições feitas à distância, sem entrar em contato direto com o objeto. A metodologia mais utilizada é aquela baseada na análise da energia ou radiação eletromagnética refletida e/ou emitida pelos alvos. Como exemplos de alvos naturais, podem-se citar: corpos de água, vegetação, solo exposto.

A radiação eletromagnética (REM) é definida como toda forma de energia que se move à velocidade da luz. A REM possui uma natureza física peculiar, apresentando simultaneamente aspectos de caráter ondulatório e corpuscular. Ela não necessita de um meio material para se propagar e possui duas componentes uma elétrica e outra magnética orientadas perpendicularmente na direção de propagação (HUNT, 1980). A radiação solar é um dos exemplos mais comuns de REM e é uma das mais utilizadas em sensoriamento remoto.

O espectro eletromagnético é conceituado como uma representação contínua da REM em termos de comprimento de onda ou o equivalente da frequência. Embora seus limites não sejam bem definidos, pode-se subdividi-lo em várias faixas: raios gama, raios X, ultravioleta, visível, infravermelho, além de bandas compreendidas em comprimentos de onda maiores como as utilizadas em radar (sensoriamento remoto ativo) e telecomunicações.

Quando o fluxo de REM incide sobre um alvo, podem ocorrer três fenômenos: uma parcela da radiação incidente é refletida pelo alvo, outra é absorvida pelo alvo e finalmente uma terceira parcela é transmitida isto é, atravessa o alvo. Neste contexto três variáveis são definidas:

a) Reflectância (ρ): é a relação entre o fluxo refletido (ϕ_r) e o fluxo incidente (ϕ_i).

$$\rho = \phi_r / \phi_i \quad (2.1)$$

b) Absortância (α): é a relação entre o fluxo absorvido (ϕ_a) e o fluxo incidente (ϕ_i).

$$\alpha = \phi_a / \phi_i \quad (2.2)$$

c) Transmittância (τ): é a relação do fluxo transmitido (ϕ_t) e o fluxo incidente (ϕ_i).

$$\tau = \phi_t / \phi_i \quad (2.3)$$

Pela lei da Conservação da Energia, tem-se que:

$$\phi_r + \phi_a + \phi_t = \phi_i \quad (2.4)$$

Dividindo os dois membros da equação anterior por ϕ_i , obtém-se a seguinte relação:

$$\rho + \alpha + \tau = 1 \quad (2.5)$$

A energia refletida e/ou emitida pelos alvos em diversas regiões do espectro eletromagnético é medida por sensores, montados em aeronaves ou satélites de sensoriamento remoto (LANDSAT, SPOT, etc). Quando a fonte de energia utilizada é natural (energia

solar) o sensor é dito ser do tipo "passivo", caso a fonte de energia seja artificial (por exemplo radar) o sensor é chamado de "ativo".

Os dados assim obtidos são fornecidos ao usuário na forma de imagens digitais, adequadas à análise com o auxílio de computadores. Essas imagens são formadas por um arranjo regular de células elementares, denominadas de pixel (picture element) organizadas em formato raster (matricial) e gravadas em fitas magnéticas, denominadas de CCT (computer compatible tape). Uma imagem multiespectral é formada por um conjunto de imagens obtidas simultaneamente da mesma região ou cena, e em bandas distintas do espectro eletromagnético. Nessas imagens, a cada célula ou pixel está associado um valor numérico (número digital), que representa a radiância refletida ou emitida pela correspondente parcela da superfície da terra na correspondente banda espectral.

Através de imagens digitais obtidas simultaneamente em várias bandas espectrais, é possível identificar as características físicas dos alvos, sua distribuição espacial e, quando se dispõe de imagens obtidas em datas distintas, as variações que ocorrem ao longo do tempo.

2.2 - SATELITE SPOT

O sistema SPOT (Systeme Probatoire d' Observation de la Terra) foi projetado pelo Centre National d' Etudes Epaciales (CNES) da França em colaboração com outros países europeus. Da mesma forma que o sistema LANDSAT, o sistema SPOT consiste de uma sequência de 4 satélites para fins de sensoriamento remoto da superfície da Terra. O primeiro satélite foi lançado em 22 de fevereiro de 1986 em associação com a Bélgica e Suécia e o segundo em 22 de janeiro de

1990.

Os satélites SPOT 1, 2 e 3 são idênticos nas suas especificações. O SPOT 4 terá características técnicas melhoradas, e um banda espectral suplementar no infra-vermelho médio (1,5 a 1,7 μm) com baixa resolução (1 km) e largo campo de visada (2000 km), para estimação da safras agrícolas e observações da vegetação em escala pequena (grandes áreas).

O instrumento HVR (Haute Resolution Visible) dos satélites SPOT observa a superfície da terra em 3 faixas do espectro electromagnético, organizados em dois modos espectrais de funcionamento: Pancromático (P - 10 m de resolução) e Multiespectral (XS1, XS2 e XS3, - 20 m de resolução). As características desses modos são:

a) Modo multiespectral: a imagem multiespectral é obtida em três bandas espectrais - cada pixel mede 20 x 20 m, ou uma área de 0.04 ha. O modelo de representação dessa imagem pode ser considerada como um conjunto de três bandas espectrais. Uma imagem cobre 60 x 60 km, são portanto 3000 linhas x 3000 pixels, codificados em 8 bits no formato digital, totalizando 28 Mbytes de informação. As três bandas são: banda 1 (0,5 a 0,59 μm), banda 2 (0,61 a 0,68 μm) e banda 3 (0,79 a 0,89 μm).

b) Modo pancromático: a imagem pancromática é feita de uma só banda no visível (0,51 a 0,73 μm); cada pixel mede 10 x 10 m, ou 0,01 ha. Uma imagem cobre 60 x 60 km, são portanto, 6000 linhas x 6000 pixels, codificados em 8 bits no formato digital, completando 36 Mbytes de informação.

É frequente dizer que os detalhes discriminados pelo satélite nos modos Pancromático e multiespectral são respectivamente de 10 e 20 m. Isso depende também do contexto do objeto no terreno.

Pode acontecer que um objeto menor que a resolução nominal possa ser visto ou sobressair visualmente bem. Como exemplo, pode-se citar uma pequena embarcação no mar.

Cada imagem SPOT é referenciada por um par de coordenadas K/J segundo a grade de referência SPOT (GRS) do mapa de cobertura SPOT do Brasil. Duas imagens vizinhas (verticalmente ou horizontalmente) têm um recobrimento de 3 km aproximadamente, variando em função da latitude. O satélite SPOT apresenta característica de repetitividade, isto é, observa a mesma área a cada 26 dias em visada vertical. Com a utilização das possibilidades de visada lateral, (27° para o leste ou para o oeste), é possível reduzir este período para 3 dias (9 vezes a cada ciclo orbital, no Equador). O recurso de visada lateral possibilita ainda a visão estereoscópica.

Uma imagem inteira do satélite SPOT representa no solo uma área de abrangência de 60 x 60 km com visada vertical. No caso de visada lateral máxima (27°) essa área chega de 60 a 80 km, a imagem sendo deformada no sentido leste-oeste.

O satélite SPOT é um sensor passivo pois utiliza apenas a energia electromagnética solar refletida pelos alvos. Na tabela 2.1 são apresentadas as principais aplicações potenciais das bandas do satélite SPOT, nos modos Pancromático e Multiespectral.

Tabela 2.1 - Principais aplicações potenciais das bandas SPOT.

Fonte: INPE (1991)

Banda	Intervalo espectral (μm)	Principais características e aplicações das bandas 1-2-3 e 4 em modo pancromático dos satélites SPOT
P	0,51-0,73	Este modo espectral produz imagens com uma única banda espectral que é restituída sempre em preto e branco. Ela privilegia a fidelidade geométrica da imagem e permite discriminar detalhes finos, do tamanho do pixel que é de 10 x 10 m. É o modo mais aconselhável para trabalhar em estereoscopia para topografia, pois assim consegue-se maior precisão altimétrica.
XS1	0,50-0,59	Apresenta sensibilidade à presença de sedimentos em suspensão, possibilitando sua análise em termos de quantidade e qualidade. Boa penetração em corpos de água.
XS2	0,61-0,68	A vegetação verde, densa e uniforme, apresenta grande absorção, ficando escura, permitindo bom contraste entre as áreas ocupadas com vegetação e aquelas sem vegetação, ex.: solo exposto, estradas, áreas urbanas. Permite a análise da variação litológica em regiões com pouca cobertura vegetal. Permite o mapeamento da drenagem através da visualização da mata galeria dos cursos dos rios em regiões com pouca cobertura vegetal. É a banda mais utilizada para delimitar a mancha urbana, incluindo identificação de novos loteamentos. Permite a identificação de áreas agrícolas.
XS3	0,79-0,89	Os corpos de água absorvem muita energia nesta banda e ficam escuros, permitindo o mapeamento da rede de drenagem e delimitamento de corpos de água. A vegetação verde densa e uniforme reflete muita energia nesta banda, aparecendo bem clara nas imagens. Apresenta sensibilidade à rugosidade da copa da floresta (dossel florestal). Apresenta sensibilidade à morfologia do terreno, permitindo a obtenção de informação sobre geomorfologia, solos e geologia. Serve para análise e mapeamento de feições geológicas e estruturais. Serve para separar e mapear áreas ocupadas com pinus e eucalipto.

Continuação tabela 2.1

Banda	Intervalo espectral (μm)	Principais características e aplicações das bandas 1-2-3 e 4 em modo pancromático dos satélites SPOT)
XS3	0,79-0,89	Serve para mapear áreas ocupadas com vegetação que foram queimadas. Permite a visualização de áreas ocupadas com macrófitas aquáticas (ex.: aguaporé) Permite a identificação de áreas agrícolas

2.3 - SISTEMA DE INFORMAÇÕES GEOGRÁFICAS

Um sistema de informações geográficas (SIG) é um conjunto de ferramentas para a obtenção, armazenamento, recuperação, transformação e edição de dados espacialmente distribuídos (BURROUGH, 1986). COWEN (1987a, 1987b e 1988) define, também, o SIG como um sistema de ajuda na tomada de decisões que envolvem a integração de dados referenciados espacialmente na solução de problemas ambientais.

Segundo SHORT (1982) o SIG é basicamente um sistema de armazenamento computadorizado, onde os dados (obtidos de tabelas, gráficos ou por sensoriamento remoto) são lidos, armazenados, processados e apresentados, todos em um formato apropriado para as necessidades do usuário. A figura 2.1 mostra um diagrama esquemático de um típico SIG.

A definição de sistema de informações geográficas não implica que alguma das funções não possam ser realizadas separadamente por software diferenciado, pois a tecnologia do SIG não se limita a um bem definido sistema de software.

É importante destacar que a principal característica de um SIG é a possibilidade de combinar (cruzar) informações (dados) de natureza diversa e distribuídos espacialmente, seguindo um modelo definido pelo usuário.

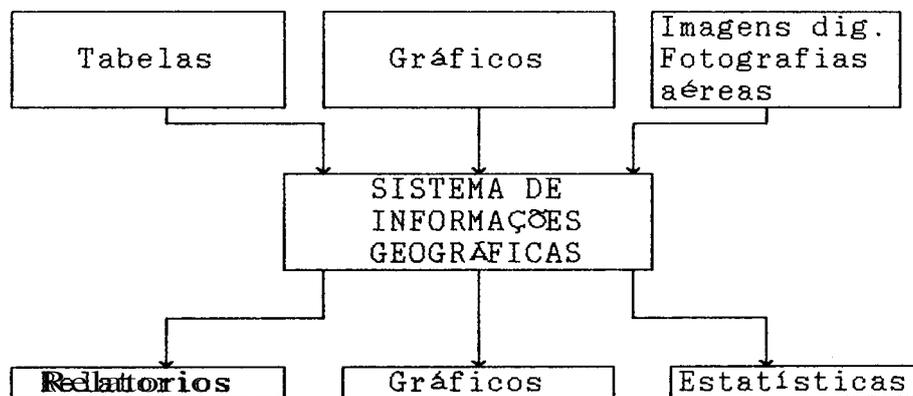


Figura 2.1 - Diagrama esquemático de um SIG.
Adaptado de SHORT (1981)

O SIG tem a capacidade de integrar informações provenientes de diversas fontes e a capacidade de tratar informações (ou dados) espacialmente distribuídos e não apenas pontuais (como tradicionalmente é feito).

Segundo LINDGREN (1985) um SIG deveria ser capaz de: a) incorporar um banco de dados geo-codificados; b) consultar, transformar, manipular ou combinar todas as informações armazenadas; c) armazenar os novos dados criados para uma análise num arquivo de dados; d) fazer análises estatísticas, como regressões multivariada, correlações, etc.; e) efetuar a superposição de um arquivo com outro, por exemplo tipo de solo e uso do solo; f) ser capaz de modelar e simular, isto é, desenvolver cenários (geralmente na forma de mapas) para prever um evento futuro.

Existem dois tipos de formatos usados para a codificação e

armazenamento de dados: a representação raster e a representação vetorial.

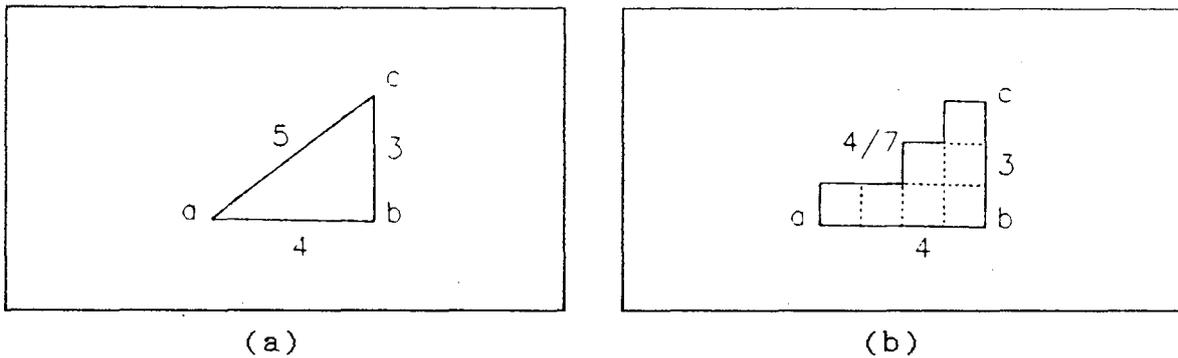
A representação raster (ou varredura) consiste de um conjunto de células localizadas em coordenadas contíguas implementadas como uma matriz bi-dimensional. Cada célula, também denominada pixel, é referenciada por índices de linha e coluna e contém um número representando o valor do atributo mapeado. Este formato é utilizado nas operações de superposição e comparação de vários conjuntos de dados ou informações.

A representação vetorial é, em geral, o resultado da digitalização manual de mapas. Consiste, normalmente, de listas de coordenadas bi-dimensionais, isto é, pares (x,y) , que delimitam regiões temáticas ou representam redes. A representação vetorial de um objeto é uma tentativa de representá-lo tão fielmente quanto possível, procurando definir precisamente todas as posições, comprimentos e dimensões das entidades geográficas. Este tipo de representação de dados faz uso dos seguintes elementos básicos:

- Ponto : entidade geométrica localizável por um único par de coordenadas (x,y) . Os pontos são similares às células da representação raster, mas não cobrem uma área.
- Arco : conjunto de coordenadas (x,y) que descrevem uma linha contínua no espaço.
- Nó : pontos inicial e final de cada arco. A estes nós está associado a informação de topologia.
- Polígono : compreende uma região limitada por arcos.

A representação vetorial é muitas vezes utilizada em pequenas áreas, onde a precisão cartográfica dos dados é o mais importante, e para a medição de áreas. A figura 2.2 ilustra o caso

de uma área representada nos formatos raster e vetorial. A figura 2.2.a mostra que a distância (Euclidiana) entre o ponto "a" e o ponto "c" é igual a cinco unidades, enquanto a distância de "a" a "c", segundo a figura 2.2.b, pode ser 7 ou 4 unidades dependendo se são computados os lados das células ou as células que deve ser atravessadas. A área da figura 2.2.a é igual a seis (unidades)²; a área da figura 2.2.b é de 7 (unidades)².



(a) (b)
 Figura 2.2 - Representação de uma área no formato:
 a) vetorial; b) raster.

As diferenças mais significativas entre as duas representações são: a) a representação vetorial requer menos números, isto implica em um menor espaço de armazenamento na memória do computador; b) a representação vetorial é esteticamente melhor do que a representação raster; c) se a forma ou tamanho do objeto representado precisam ser modificados, isso pode ser feito mais depressa e com maior facilidade numa representação raster do que numa representação vetorial. Na representação raster a atualização de dados, frequentemente implica em apagar certos valores, substituindo-os pelos novos valores. Na representação vetorial, não só as coordenadas dos pontos deverão ser atualizados como também as conexões deverão ser reconstruídas.

Em muitas aplicações práticas, é necessária a superposição

de vários mapas temáticos contendo diferentes tipos de informações (topografia, tipo do solo, rede de drenagem, etc.). A forma mais eficiente de fazer essa superposição é trabalhar com uma base de dados em formato raster. Portanto, se a informação original está no formato vetorial, será preciso uma conversão para o formato raster. Neste processo de conversão o tamanho da célula da representação raster é um fator crítico, ele deve ser pequeno em relação à resolução espacial dos temas dos mapas, especialmente em áreas pequenas.

Uma estimativa da precisão do mapa raster, obtido a partir de um mapa no formato vetorial, pode ser computada usando a seguinte expressão:

$$L_{ij} = A(M_i \cap M_j) \quad , \quad i=1, 2, \dots, n \quad (2.6)$$

$$i <> j$$

onde L_{ij} : é a área do mapa que realmente corresponde à classe M_i , mas que foi representada como classe M_j ;

A : é a área do mapa mal representada;

M_i : representa as unidades ou classes do mapa, e

n : é o número total de classes presentes no mapa.

A área total incorretamente mapeada como classe M_i é dada por:

$$L_i = \sum_{\substack{j=1 \\ j <> i}}^n L_{ij} \quad (2.7)$$

Denotando com $A(M)$ a área total do mapa, o erro (em percentagem) gerado na conversão de formatos será:

$$L = 100 \frac{\sum_{i=1}^n L_i}{A(M)} \quad (2.8)$$

Uma explicação mais detalhada do processo de estimação da precisão de um mapa raster encontra-se em SWITZER (1975).

2.4 - MAPA DE COBERTURA DO SOLO E FRAÇÃO DE ÁREAS IMPERMEÁVEIS

Os métodos matemáticos para simulação do comportamento hidrológico de uma bacia urbana diferem na sua estrutura e complexidade. Entretanto todos estes métodos requerem informações da cobertura do solo da bacia, que pode ser considerado através de parâmetros. A percentagem de impermeabilidade ou fração de áreas impermeáveis da bacia é talvez o mais importante desses parâmetros.

Um procedimento comum para a estimação da fração de áreas impermeáveis é definir vários tipos de uso e cobertura do solo a partir de um mapa, fotografia aérea ou imagem obtida por satélite e atribuir um valor de impermeabilidade média para cada um com base em algum critério como o de STANKOWSKI (1972) e o de TUCCI et alii (1989), onde os autores relacionaram taxa de áreas impermeáveis com densidade populacional. O SOIL CONSERVATION SERVICE - SCS (1975) apresenta alguns valores recomendáveis de impermeabilidade para diferentes classes de uso-cobertura do solo, como mostra a tabela 2.2. Outros valores de impermeabilidade são sugeridos por o URBAN DRAINAGE AND FLOOD CONTROL DISTRICT - UDFCD (1985) e apresentados na tabela 2.3.

O termo cobertura do solo refere-se à natureza das feições presentes na superfície da terra. Como exemplos de tipo de cobertura de solo, podem ser citados: Área construída, vegetação, pavimento, solo exposto, etc. O termo uso do solo refere-se à atividade humana associada com uma parcela específica do solo. Assim, a área construída pode estar associada a área residencial ou industrial;

vegetação pode estar associada a uma área de preservação, a uma área agrícola ou a uma área de lazer. Uma mesma classe de cobertura do solo pode estar associada a distintos tipos de uso do solo.

Tabela 2.2 - Valores de impermeabilidade recomendados pelo SCS.

Classes de uso-cobertura	% Impermeabilidade
Área comercial e lojas	85
Distritos ind.	72
Área residenc.:	
< 500 m ²	65
1000 m ²	38
1350 m ²	30
2000 m ²	25
4050 m ²	20

Fonte : SCS (1975)

Tabela 2.3 - Valores de impermeabilidade recomendados pelo UDFCD.

Classes de uso-cobertura	% Impermeabilidade
Área comercial	90
Residencial de alta densidade	70
Residencial de baixa densidade	50
Espaços abertos	02

Fonte: UDFCD (1985)

Segundo ANDERSON et alii (1976), idealmente, as informações de uso e cobertura do solo deveriam ser apresentadas separadamente e não misturadas. Informações da cobertura do solo podem ser diretamente interpretadas de uma imagem digital. Informações sobre a atividade humana no solo nem sempre podem ser inferidas a partir da cobertura do solo. Por essa razão, informações

adicionais são necessárias como complemento aos dados de cobertura solo. O autor cita, também, que um bom sistema de classificação de uso-cobertura do solo seria um do tipo multi-nível, que ele fixa em quatro níveis. A razão de um sistema multi-nível reside nos diferentes graus de detalhamento que podem ser obtidos por diferentes produtos de sensoriamento remoto, dependendo das características do sistema sensor, particularmente de sua resolução espacial. O sistema multi-nível proposto por ANDERSON mantém fixas as classes nos dois primeiros níveis enquanto que os níveis III e IV podem ser ajustados para cada caso particular. A tabela 2.4 ilustra um exemplo de classificação nos três primeiros níveis, enquanto a tabela 2.5 apresenta quais seriam os possíveis produtos a serem utilizados nos diferentes níveis.

Tabela 2.4 - Exemplo de classificação multi-nível.

Nível I	Nível II	Nível III
Urbana	Residencial	Familiar simples
		Multi-familiar
		Residenciais, hotéis
		Grupos de condomínios
		Parques p/casas móveis
		Outros
	Comercial	
	Industrial	
	Comunicação	
	Outros	

Fonte: ANDERSON et alii (1976)

Tabela 2.5 - Materiais necessários em cada nível da classificação multi-nível.

Nível de classif.	Materiais ou produtos necessários
I	LANDSAT MSS
II	LANDSAT TM, SPOT, fotografias aéreas em pequena escala, ex.: 1:50.000 - 1:100.000
III	Fotografia aérea em escala média ex.: 1:25.000
IV	Fotografias aéreas em grande escala, ex.: 1:5.000 - 1:10.000

Fonte : ANDERSON et alii (1976)

O tamanho da menor área que pode ser mapeada em qualquer classe de uso-cobertura depende da escala e resolução da imagem ou fotografia aérea e da escala de compilação dos dados e da escala final do mapa de uso-cobertura do solo. LILLESAND et alii (1987) aponta, quando os dados de uso-cobertura do solo são apresentados na forma de mapa, é difícil a representação de uma área menor de 2,5 mm de lado. No entanto, pequenas áreas geram problemas de legibilidade ao usuário do mapa. A tabela 2.6 lista o tamanho mínimo das áreas do solo que podem ser mapeadas nos diferentes níveis.

Tabela 2.6 - Tamanho mínimo das áreas a serem mapeadas.

Nível	Escala de compilação do mapa	Valor mínimo aproximado de uma área mapeada (*) (ha)
I	1:500.000	150
II	1:62.500	2.5
III	1:24.000	0.35

(*) Baseado na mínima unidade do mapa de 2,5 x 2,5 mm
 Fonte: LILLESAND et alii (1987)

RAGAN R. e JACKSON T.J. (1975) apresentaram um trabalho de determinação da taxa de áreas impermeáveis na bacia do rio Anacostia a partir do processamento de imagens digitais obtidas pelo satélite LANDSAT-MSS por meio de técnicas de sensoriamento remoto. Os autores estabeleceram sete categorias de uso-cobertura de solo que correspondiam a classes espectrais bem definidas e fizeram uma classificação supervisionada das imagens digitais LANDSAT-MSS obtendo resultados satisfatórios. Trabalharam com imagens digitais em escala 1:100.000 e as áreas teste foram ampliadas para 1:24.000. A tabela 2.7 apresenta uma comparação dos resultados obtidos por técnicas convencionais (análise de fotografias aéreas) e dos resultados obtidos usando técnicas de sensoriamento remoto.

Os autores afirmam que o trabalho feito a partir da

análise de fotografias aéreas pancromáticas na escala 1:4.800 demandou 94 dias/homem para sua realização, enquanto que por meio de técnicas de sensoriamento remoto orbital só foram necessários 4 dias/homem para fazer o mesmo trabalho. Desta comparação torna-se fácil perceber a conveniência da aplicação das técnicas de sensoriamento remoto.

Tabela 2.7 - Percentagens da área da bacia ocupado por os diferentes tipos de uso-cobertura do solo.

Uso do solo	Fotografia aerea	LANDSAT MSS
Área com floresta	30.7	27.0
Área altamente impermeável (*)	4.9	6.5
Área com grama	8.5	10.4
Área residencial	44.9	43.5
Ruas e estradas	9.9	5.5
Solo exposto	não classif.	0.4
Rio, arroio	1.0	não classif.
Represas ou corpos de água	0.1	não classif.
Píxeis não classificados	-	6.7

(*) Área comercial, industrial e grandes estacionamentos.

Fonte: RAGAN e JACKSON (1975)

RAGAN R. e JACKSON T.J. (1980) num estudo posterior, visando a determinação da capacidade de geração de escoamento superficial em uma bacia urbana utilizando o método da "curva número" do Soil Conservation Service (SCS) em combinação com técnicas de sensoriamento remoto, realizaram um mapeamento da bacia em termos de uso-ocupação por meio de uma classificação de imagens digitais LANDSAT-MSS. A área de estudo foi a bacia do rio Anacostia. Os resultados foram satisfatórios apesar da dificuldade em se obter uma classificação bem detalhada do tipo de solo, fato esse causado pela resolução espacial insuficiente do sistema LANDSAT-MSS (80 x80 m).

BONDELID T. R., JACKSON T. J. E e Mc. CUEN R. H. (1981) em seu trabalho de determinação de escoamento superficial pelo método da "curva número" do SCS usando dados adquiridos via sensoriamento

remoto realizaram uma classificação supervisionada do uso e cobertura do solo em duas bacias obtendo resultados aceitáveis, confirmando a confiabilidade das técnicas de sensoriamento remoto no mapeamento de uma bacia segundo o uso-ocupação do solo. A tabela 2.8 apresenta resultados obtidos da classificação das imagens digitais e os resultados obtidos por técnicas convencionais (planimetrando as diferentes categorias de solo de um mapa).

JOHNSON (1989) partindo da digitalização de um mapa base da bacia urbana de Lena Gulch e utilizando técnicas SIG fez uma classificação da bacia em termos de uso-ocupação com o propósito de determinar a taxa de áreas impermeáveis, fator importante na estimação do escoamento superficial. No trabalho, foram consideradas quatro classes: área comercial, residencial de alta densidade, residencial de baixa densidade e espaços abertos. O autor estabeleceu o nível de impermeabilidade para cada classe levando em conta o critério de URBAN DRAINAGE AND FLOOD CONTROL DISTRICT (1985).

Tabela 2.8 - Resultados da classificação de cobertura de solo por técnicas convencionais e por imagens digitais LANDSAT MSS.

Bacia	Floresta (%)		Agricultura (%)		Urbana(%)	
	Conven- cional	LANDSAT MSS	Conven- cional	LANDSAT MSS	Conven- cional	LANDSAT MSS
Little Mahanoy	76.0	80.8	6.9	0.1	16.0	16.1
Chickies Creek	29.0	29.8	57.0	63.4	14.0	6.8

Fonte: BONDELID et alii (1981)

Da análise dos trabalhos apresentados, pode-se concluir que a utilização das técnicas de sensoriamento remoto e imagens multiespectrais na determinação das características do solo, em termos de uso e cobertura, de uma bacia, é uma alternativa válida que permite obter resultados de forma rápida e com precisão aceitável.

2.5 - MODELO NUMÉRICO DO TERRENO

O modelo numérico do terreno (MNT) consiste em uma representação numérica das variações do relevo ao longo de uma área, ou seja, o MNT descreve as variações de altitudes sobre uma superfície bi-dimensional. Existem dois métodos de representação que podem ser usados num MNT: modelos matemáticos e modelos de imagem que envolvem os modelos de pontos e os modelos de linha.

A representação matemática do MNT refere-se a funções tridimensionais contínuas capazes de descrever adequadamente as complexas formas da superfície do terreno. Basicamente o método consiste em dividir a área de interesse em células quadradas ou parcelas irregulares que apresentem relevo uniforme e então, funções matemáticas são ajustadas, a partir de observações pontuais em cada célula ou parcela, sob a restrição que as diferentes parcelas das superfícies coincidam nas bordas das células (SCHUT, 1976).

A segunda alternativa de representação de um MNT é o modelo de linha que utiliza um conjunto de linhas denominadas de curvas de nível. Curva de nível é o lugar geométrico dos pontos com a mesma altitude. Perfis, ou cortes verticais, são produtos usualmente derivados usados para a análise de declividade. As curvas de nível são obtidas a partir da digitalização de mapas já existentes. Infelizmente as linhas ou contornos assim digitalizados não são computacionalmente apropriados para o cálculo da declividade ou a geração de modelos sombreados. Por essa razão, são usualmente convertidos para modelo de ponto como uma matriz (discreta) de altitudes. CERUTI (1980) e YOELI (1984) descrevem alguns algoritmos de interpolação para obter a matriz de altitudes a partir de um modelo de linha.

O terceiro método de representação usado num MNT é o

modelo de ponto, que consiste numa matriz de altitude ou malha retangular regular que é obtida através de medições por estereoscopia em fotografias aéreas ou, alternativamente a matriz de altitude pode ser produzida por interpolação de dados pontuais regular ou irregularmente espaçados. As desvantagens mais importantes deste método consistem na grande quantidade de dados redundantes em áreas de relevo plano, e na impossibilidade de modificar o tamanho da malha em áreas com relevo mais acidentado.

Os pontos irregularmente espaçados podem ser usados de duas maneiras diferentes na geração de um MNT. A primeira consiste em superpor aos pontos uma malha regular e por alguma técnica de interpolação obter a matriz de altitudes (figura 2.3). Uma ampla revisão das técnicas de interpolação e suas aplicações é feita pelos autores RIPLEY (1981), AGTEBERG (1982), LAM (1983) e WEBSTER (1984).

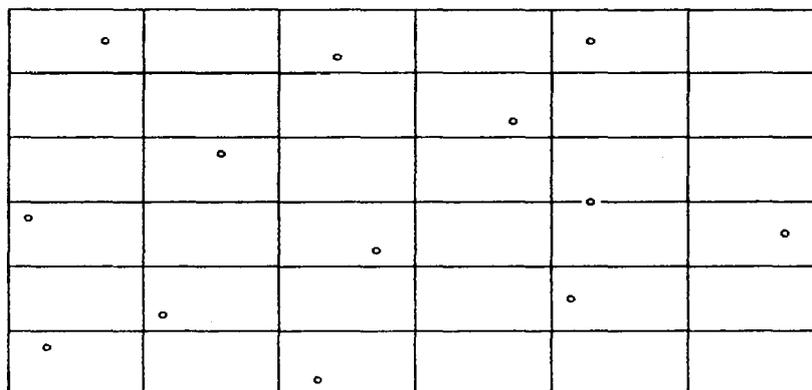


Figura 2.3 - Interpolação de pontos irregularmente espaçados e geração da matriz de altitude.

A segunda forma consiste em usar pontos irregularmente espaçados como a base de um sistema de triangulação. A maior vantagem deste método, denominado de TRIANGULATED IRREGULAR NETWORK (TIN), que foi desenvolvido por PEUKER et alii (1978) é que evita a

redundância de dados em áreas de relevo uniforme, além de permitir um melhor detalhamento em áreas com relevo mais complexo.

O TIN é um modelo numérico do terreno formado por uma série de superfícies ou segmentos triangulares irregulares ajustados à superfície topográfica a partir dos pontos irregulamente distribuídos ao longo dessa superfície. O ajuste das superfícies triangulares baseia-se no princípio de que uma superfície plana pode ajustar-se a três pontos quaisquer não colineares, ou seja, não orientados segundo uma reta no espaço. A figura 2.4 ilustra um exemplo do modelo TIN.

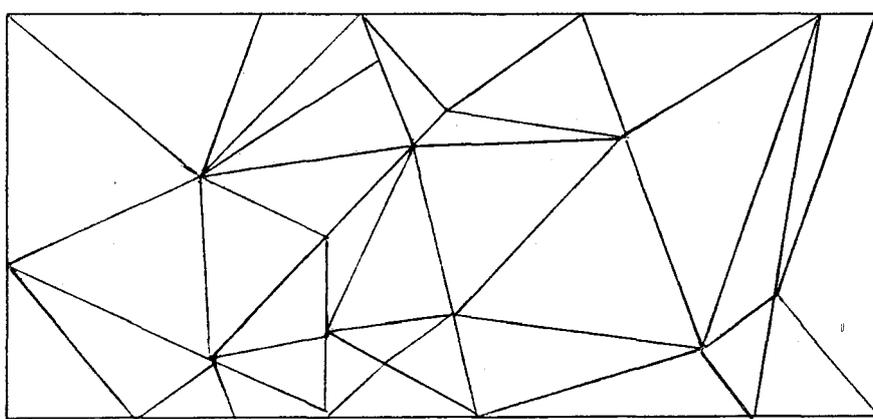


Figura 2.4 - Exemplo da estrutura do modelo de triangulação TIN.

2.6 - REDE DE DRENAGEM SUPERFICIAL E DIVISORES DE ÁGUA

A seguir serão definidos alguns conceitos, como bacia hidrográfica, rede de drenagem e divisor de águas, a serem utilizados nesta seção.

A bacia hidrográfica é uma área definida topograficamente, drenada por um curso de água ou um sistema conectado de cursos de água tal que toda a vazão efluente seja descarregada através de uma simples saída. Esse curso de água ou sistema conectado de cursos de água constitui a rede de drenagem superficial.

A bacia hidrográfica é, necessariamente, contornada por um divisor, que é a linha que divide as precipitações que caem em bacias vizinhas e que encaminham o escoamento superficial resultante para um outro sistema fluvial. O divisor segue uma linha rígida em torno da bacia, atravessando o curso de água somente no ponto de saída. O divisor de águas une os pontos de máxima cota entre as bacias, o que não impede que no interior de uma bacia existam picos isolados com altitude superior a qualquer ponto do divisor de água. Existem dois tipos de divisores de água: um divisor topográfico ou superficial e um divisor freático ou subterrâneo. O divisor topográfico é condicionado pela topografia e ele fixa a área da qual provém o escoamento superficial da bacia. O divisor de água freático é, em geral, determinado pela estrutura geológica dos terrenos, sendo muitas vezes influenciado também pela topografia. Este divisor estabelece os limites dos reservatórios de água subterrânea. Neste trabalho, qualquer referência a divisor de águas deve ser entendida como divisor topográfico ou superficial.

A partir da matriz de altitude do MNT é possível derivar a rede de drenagem superficial e os divisores de água, por meio de técnicas SIG. PEUKER e DOUGLAS (1975) elaboraram um algoritmo simples, que trabalha com uma janela de quatro células. Esta janela é movida sobre a matriz de altitude, cobrindo quatro células por vez. Para estimar a rede de drenagem, a célula de maior elevação é marcada. Para estimar os cumes, a célula de menor elevação é marcada. Ao final do processo de marcação, as células que permaneceram sem serem marcadas, representam a rede de drenagem ou o padrão de cumes, respectivamente. O passo seguinte do processo é

juntar os pontos não marcados de forma de construir uma linha continua.

Dado que este algoritmo não se fundamenta em nenhum conhecimento de processos fluviais, MARK (1984), decidiu pesquisar se por estudos geomorfológicos, não seria possível obter um melhor algoritmo para simular o escoamento das águas sobre um MNT. O algoritmo desenvolvido assemelha-se com a definição do teorema de Cauchy que estabelece que a menor distância entre dois pontos quaisquer sobre uma superfície, é a linha de descenso mais íngreme.

O algoritmo proposto por MARK (1984) requer a posição de saída da rede de drenagem e a locação de uma célula de partida. Para cada célula exceto a de saída, sua altitude é comparada com a dos oito vizinhos mais próximos dentro de uma janela de 3 x 3 células. O vizinho mais baixo é marcado e o acúmulo de água, expresso como uma função do número de células atravessadas e a área de cada uma, é atribuído à célula. A janela então é movida para o vizinho mais baixo e o processo é repetido. As linhas de drenagem podem ser codificadas numa escala de níveis de cinza de acordo ao volume de água que passe sobre elas.

MARK et alii (1984) também apresentaram um algoritmo para determinar os divisores de água de uma bacia. Os autores partem do cálculo de gradiente local e da orientação de cada célula. O procedimento é: a saída da bacia é identificada iterativamente; o computador procura todas as células que estão a montante da saída da bacia e dentro da mesma, usando o seguinte algoritmo: empregando uma janela de 3 x 3 células e partindo da saída da bacia, uma célula é definida como a montante da célula central da janela, segundo figura 2.5, se a sua orientação for para o centro da janela. A orientação é quantificada usualmente em oito níveis (N, S, E, W, NE, NW, SE e SW).

O algoritmo opera sobre a base de dados de uma forma recursiva, partindo da saída da bacia. Para cada ponto "in" atual serão conferidos os oitos vizinhos sequencialmente, levando em conta as bordas e os cantos da grade. Se um vizinho já foi marcado como ponto "in", é ignorado, por outro lado se um vizinho que for considerado a montante ou no mesmo nível horizontal, será escolhido como novo centro da janela. O algoritmo desloca-se sobre o MNT até encontrar um cume ou os dados externos (pontos não pertencentes à área de estudo). Esse processo repete-se até que toda a bacia seja marcada. O método visita cada célula uma vez e ignora as células que estão fora da bacia de drenagem.

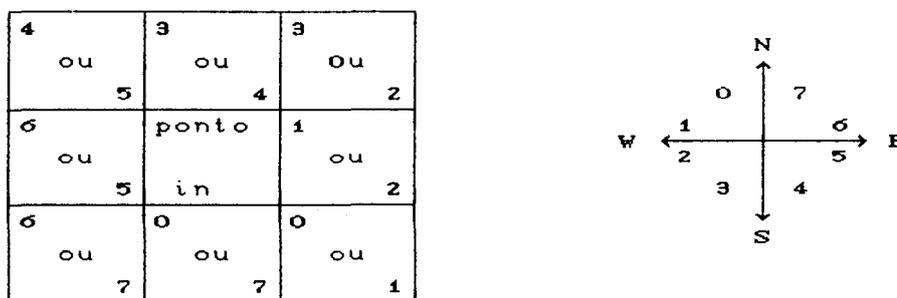


Figura 2.5 - Estimativa das classes de orientação e janela de determinação dos pontos a montante relativos ao centro, ponto "in".
 Fonte: BURROUGH (1986)

No capítulo 4, é apresentado em detalhes o algoritmo usado para a determinação do divisor de águas e da rede de drenagem.

3 - CLASSIFICAÇÃO DE IMAGENS DIGITAIS

Neste capítulo são apresentados os algoritmos de classificação de imagens multiespectrais mais comumente utilizados, dando especial atenção ao procedimento que utiliza o conceito de matemática Fuzzy, pois é a abordagem utilizada neste trabalho.

3.1 - PROCESSOS DE CLASSIFICAÇÃO E O PROBLEMA DO PIXEL MISTURA

A classificação de uma imagem multiespectral consiste em identificar nelas, os diferentes alvos, fenômenos ou feições que apresentam padrões espectrais similares. Em outras palavras, é a associação de pontos de uma imagem a uma classe ou grupo: água, cultura, área urbana, etc..

Um padrão espectral é qualquer ente com características bem definidas num espaço multiespectral, e representado por um conjunto de medidas igual à dimensão do espaço espectral.

O desenvolvimento de algoritmos para fins de classificação de imagens digitais com o auxílio de computadores tem merecido a atenção de um grande número de pesquisadores. A literatura especializada vem registrando diferentes tipos de abordagem desse problema como TOU e GONZALES (1974), DUDA e HART (1973), entre outros. Presentemente, entre os métodos mais utilizados para a

classificação de imagens digitais multiespectrais em sensoriamento remoto, pode ser citada a da Máxima Verossimilhança Gaussiana (MVG). Na seção 3.2 será apresentada uma discussão sobre os diferentes métodos.

Todos esses processos buscam atribuir cada pixel da imagem à uma das classes presente na cena. Nos processos de classificação supervisionada como o da MVG o analista fornece ao computador amostras de cada classe. A partir dessas amostras são então estimados os parâmetros que definem cada classe e que serão utilizados nas funções discriminantes que realizam a classificação da cena.

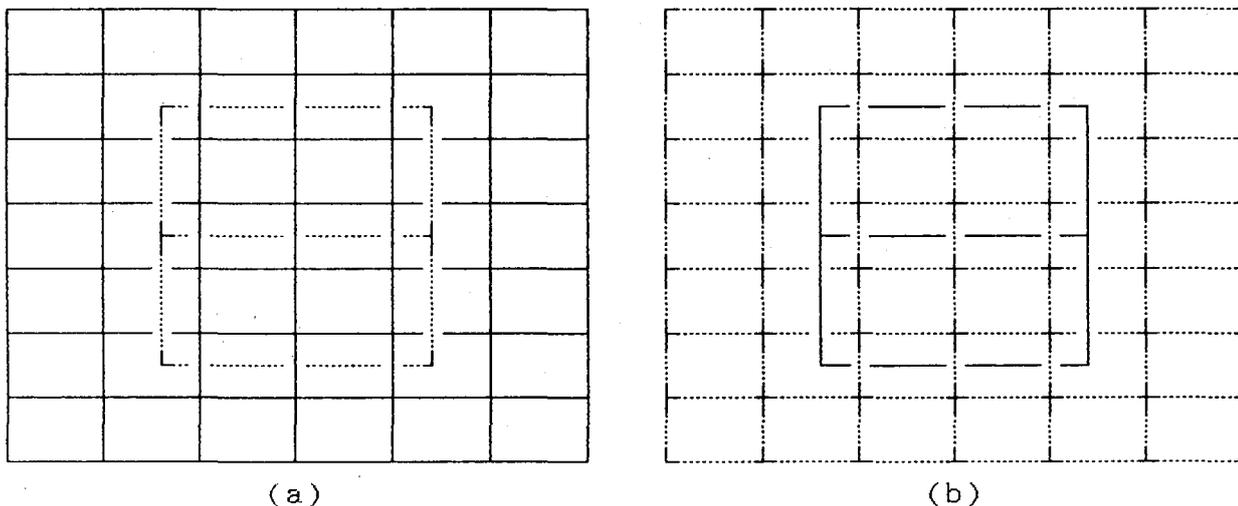
Nesse processo, cada amostra, e portanto, cada função discriminante refere-se a uma classe conhecida e presente na cena. Isto significa que, durante o processo de classificação, cada pixel é ou atribuído inteiramente a uma das classes ou colocado na categoria de "não classificado", quando suas características diferem muito daquelas estimadas para as classes conhecidas.

Essa abordagem é normalmente aceitável nas cenas naturais analisadas por técnicas de sensoriamento remoto. Existem entretanto casos em que essa metodologia pode tornar-se pouco satisfatória. Em áreas urbanas, por exemplo, as diversas classes presentes na cena (vegetação, solo exposto, pavimento, área construída) ocorrem intercaladas em áreas pequenas. Como resultado, a maior parte dos pixels presentes na imagem são "pixels mistura", o que significa que mais de uma classe está presente naqueles elementos de resolução.

Os pixels mistura acontecem quando o tamanho dos objetos (alvos) no terreno é menor do que o elemento da cena (pixel), ou quando os limites (fronteiras) de objetos maiores estão dentro do elemento da cena, como ilustra a figura 3.1. Um pixel dessa natureza, apresenta uma resposta espectral distinta daquela das

classes conhecidas. A radiação detetada é a integração da radiação de todas as classes presentes no elemento da cena.

A presença de pixels mistura é um fator limitante ao processo de classificação automática, uma vez que os métodos convencionais de classificação, como a Máxima Verossimilhança Gaussiana, baseiam-se nas características espectrais dos pixels, onde uma classe corresponde a um único tipo de cobertura do terreno. Portanto, a radiação resultante da combinação de mais de uma classe de cobertura do terreno não será representativa de nenhuma delas, acarretando uma classificação incorreta e, conseqüentemente, uma estimativa imprecisa da área ocupada por cada classe no terreno.



□ Elemento da cena □ Objeto

Figura 3.1 - Pixel mistura causado por: a) objetos menores do que o elemento da cena; b) limites de objetos maiores dentro do elemento da cena. Adaptado de SHIMABUKURO (1987).

O problema de estimar essas frações nos pixels que compõem a imagem é conhecido como o "problema da mistura". Soluções diversas tem sido propostas. Uma solução bastante aceita é a que implementa o "modelo linear de mistura". Uma descrição detalhada desse modelo

pode ser encontrada em SHIMABUKURO (1987). Neste trabalho é implementado um modelo distinto, proposto por WANG (1990) e que faz uso de conceitos de matemática "Fuzzy". A abordagem fuzzy é baseada no princípio de que a transição de uma classe para outra é gradual e não abrupta. Portanto, a pertinência de um pixel da cena a uma classe não pode ser descrita simplesmente por um valor: um ou zero se pertence ou não a essa classe, respectivamente. Mas se por um conjunto de valores que indicariam os diferentes graus de associação do pixel com cada classe.

3.2 - ALGORITMOS DE CLASSIFICAÇÃO DE IMAGENS DIGITAIS

O processo de classificação de imagens digitais consiste no particionamento do espaço espectral de maneira que, idealmente, os pontos pertencentes a uma determinada classe caiam sempre na partição correspondente. Em sensoriamento remoto, métodos estatísticos de reconhecimento de padrões são particularmente apropriados, devido à incerteza inerente à categorização das classes, e também devido a variações provenientes de perturbações estatísticas (ruído) nos sensores. O instrumento básico empregado nestes métodos é a teoria de decisão estatística. Neste caso a partição do espaço espectral é estabelecida minimizando a probabilidade de erro. Esta metodologia é explicada detalhadamente na seção 3.2.1.

Os métodos de classificação mais utilizados são os supervisionados, que utilizam amostras de treinamento para estimar as características espectrais das classes. A classificação supervisionada é utilizada quando se tem algum conhecimento sobre as classes na imagem, quanto a seu número e aos pontos representativos destas classes. Entre esses métodos, o mais comumente utilizado é o método de classificação por máxima verossimilhança, sob a hipóteses

gaussiana, na qual cada classe é descrita por uma função densidade de probabilidade multivariada normal. O vetor que descreve cada pixel é então substituído na função densidade de probabilidade associada a cada classe. O pixel é então atribuído à classe correspondente ao maior valor assim gerado.

Outra alternativa para dividir o espaço multiespectral, é, a classificação não-supervisionada. Ela é útil quando não se tem informações sobre a área imageada. Frequentemente a classificação não-supervisionada é efetuada utilizando métodos de agrupamento de dados ("clustering"). As técnicas desenvolvidas se baseiam na minimização de algum critério derivado de uma medida de similaridade entre amostras. Algoritmos diversos de agrupamentos são descritos em detalhe na literatura (TOU e GONZALES 1974). Um algoritmo muito utilizado na prática é o denominado "K-média".

3.2.1 - Algoritmo de classificação por Máxima Verossimilhança

Um pixel genérico será representado pelo vetor $x = \{x_1, x_2, \dots, x_n\}$, sendo x_i o contador digital na banda i , e por w_i ($i=1, 2, \dots, m$) as classes ou tipos de cobertura presentes na cena. A ideia básica deste algoritmo é classificar a imagem pixel a pixel de modo de minimizar o erro, isto é, a perda esperada resultante da classificação do pixel x na classe w_j quando a verdadeira classe é w_k . Esse critério é conhecido como o método de BAYES e, pode ser formulado como segue:

$$\text{minimizar } L_x(w_i) = \sum_{\substack{j=1 \\ j \neq i}}^m \lambda(w_i/w_j) \cdot p(w_j/x) \quad (3.1)$$

onde: $L_x(w_i)$: perda esperada resultante de classificar x
como **pertencente** à classe w_i ,

$\lambda(w_i \setminus w_j)$: função de perda. Representa o custo de tomar
decisão por uma classe w_i quando a verdadeira é w_j ;
 $i, j = 1, 2, 3, \dots, m$,

$p(w_j/x)$: probabilidade condicional de que dado o pixel x ,
ocorra a classe w_j . Esta probabilidade é conhecida
como probabilidade "a posteriori",

n : dimensão do espaço espectral (número de bandas
espectrais), e

m : número de classes.

A escolha mais frequente para a função de perda $\lambda(w_i \setminus w_j)$
é:

$$\lambda(w_i \setminus w_j) = \begin{cases} 0 & \text{para } i=j \\ 1 & \text{para } i \neq j \end{cases} \quad (3.2)$$

isto é, o custo de uma classificação correta é zero, e unitario no
caso contrário.

A estratégia de BAYES na classificação é tomar aquela
decisão que minimize a perda (3.1). Mas, levando em conta que
minimizar um conjunto de funções ($L_x(w_i)$, $i=1,2, \dots, m$) é a mesma
operação que maximizar o negativo do mesmo conjunto de funções, a
função discriminante pode ser escrita como:

$$g_i(x) = -L_x(w_i) \quad , \quad \text{para } i=1,2, \dots, m \quad (3.3)$$

e a **estratégia de classificação** é classificar x na classe w_i para a
qual $g_i(x)$ seja máxima.

Pelo teorema de BAYES:

$$p(w_j/x) = \frac{p(x/w_j) \cdot p(w_j)}{p(x)} \quad (3.4)$$

onde: $p(w_j/x)$: probabilidade condicional de dado x , a classe w_j ocorrer.

$p(x/w_j)$: função densidade de probabilidade associada à classe w_j ,

$p(w_j)$: probabilidade "a priori" da classe w_j , e

$p(x)$: função densidade de probabilidade associada com x .

Substituindo as equações 3.2 e 3.4 em 3.3 tem-se:

$$g_i(x) = - \sum_{\substack{j=1 \\ j <> i}}^m \frac{p(x/w_j) \cdot p(w_j)}{p(x)} \quad (3.5)$$

$$g_i(x) = - \frac{1}{p(x)} \sum_{\substack{j=1 \\ j <> i}}^m p(x/w_j) \cdot p(w_j) \quad (3.6)$$

O termo $1/p(x)$ modifica o valor absoluto da função discriminante $g_i(x)$ mas não o valor relativo que nos interessa, pois a distribuição $p(x)$ é independente da classe. Conseqüentemente, para fins da classificação esse termo pode ser negligenciado, então:

$$g_i(x) = - \sum_{\substack{j=1 \\ j <> i}}^m p(x/w_j) \cdot p(w_j) \quad (3.7)$$

Da estatística elementar tem-se que:

$$p(x) = \sum_{j=1}^m p(x/w_j) \cdot p(w_j) \quad (3.8)$$

$$\text{ou } p(\mathbf{x}) = p(\mathbf{x}/w_i) \cdot p(w_i) + \sum_{\substack{j=1 \\ j \neq i}}^m p(\mathbf{x}/w_j) \cdot p(w_j) \quad (3.9)$$

As equações (3.8) e (3.9) são válidas sempre que as classes w_j formarem um conjunto exaustivo.

Substituindo a equação 3.9 na equação 3.7:

$$g_i(\mathbf{x}) = -p(\mathbf{x}) + p(\mathbf{x}/w_i) \cdot p(w_i) \quad (3.10)$$

Como $p(\mathbf{x})$ é independente da classe, pode ser negligenciada, então a função discriminante no método de Máxima Verossimilhança é:

$$g_i(\mathbf{x}) = p(\mathbf{x}/w_i) \cdot p(w_i) \quad (3.11)$$

~~Assume-se~~ geralmente que para uma classe, o valor associado a cada pixel (número digital) segue uma distribuição normal, isto é, a função densidade de probabilidades $p(\mathbf{x}/w_i)$ tem a forma da distribuição gaussiana multivariada. Assim pode-se reescrever a função discriminante como:

$$g_i(\mathbf{x}) = \frac{p(w_i)}{(2\pi)^{n/2} |\Sigma_i|^{0.5}} \exp [-0.5 (\mathbf{x} - \mu_i)^T \cdot \Sigma_i^{-1} \cdot (\mathbf{x} - \mu_i)] \quad (3.12)$$

onde: $g_i(\mathbf{x})$: função discriminante,
 $p(w_i)$: probabilidade a priori da classe w_i ,
 $|\Sigma_i|$: determinante da matriz de variância e covariância,
 Σ_i^{-1} : inversa da matriz de variância e covariância, e
 μ_i : vetor de médias da classe w_i .

Tomando-se qualquer função monotonicamente não decrescente da função discriminante $g_i(\mathbf{x})$, a partição resultante não é alterada. Então, utilizando a função logaritmo neperiano e desprezando os

termos constantes, a função discriminante será:

$$g_i(\mathbf{x}) = \ln[p(w_i)] - 0.5 \ln|\Sigma_i| - 0.5 (\mathbf{x} - \mu_i)^T \cdot \Sigma_i^{-1} \cdot (\mathbf{x} - \mu_i) \quad (3.13)$$

A razão dessa transformação é que computacionalmente fica mais rápida de ser avaliada a função discriminante.

Na generalidade dos casos a probabilidade a priori para cada classe ($p(w_i)$, $i=1, 2, \dots, m$) é desconhecida, portanto assume-se igual probabilidade para todas as classes. Consequentemente a função discriminante resume-se a:

$$g_i(\mathbf{x}) = p(\mathbf{x}/w_i) \quad (3.14)$$

Intrinsicamente, essa estratégia é equivalente a considerar a seguinte função de perda:

$$\lambda(w_j/w_i) = \begin{cases} 0 & \text{para } i=j \\ 1/p(w_j) & \text{para } i \neq j \end{cases} \quad (3.15)$$

3.2.2 - Algoritmo de classificação "K-MEDIAS"

Este algoritmo de agrupamento de dados é baseado na minimização de um índice de "desempenho" que é definido como a soma do quadrado da distância dos pontos ao centro do agrupamento, isto é, a soma do quadrado da distância euclidiana. O procedimento de agrupamento de dados consiste dos seguintes passos:

Passo 1: Define-se o número ,k , de agrupamentos ("clusters") e os centros iniciais $\mu_1(1), \mu_2(1), \dots, \mu_k(1)$ desses agrupamento. Usualmente os centros iniciais são selecionados arbitrariamente como as primeiras k amostras do conjunto de elementos a classificar.

Passo 2: Por meio de um processo iterativo, são distribuídos todos os elementos entre os k agrupamentos definidos, usando a relação:

$$x \in S_j(k) \quad \text{se } [x - \mu_j(k)] < [x - \mu_i(k)] \quad (3.16)$$

$$i=1, 2, \dots, k$$

$$i \neq j$$

onde $S_j(k)$ denota o conjunto de amostras cujo centro é $\mu_j(k)$. Se um elemento apresentar a mesma distância com relação a mais de um agrupamento, a situação é resolvida arbitrariamente.

Passo 3: A partir dos resultados do passo anterior, são computados os novos centros $\mu_j(k+1)$, $j=1, 2, \dots, k$, de modo que a soma do quadrado da distância de todos os pontos pertencentes a $S_j(k)$ ao novo centro seja minimizada. Em outras palavras, o novo centro $\mu_j(k+1)$ é computado de modo que o índice de desempenho:

$$J_j = \sum_{x \in S_j(k)} [x - \mu_j(k+1)]^2, \quad j=1, 2, \dots, k \quad (3.17)$$

seja mínimo. O novo centro $\mu_j(k+1)$ que minimiza o índice de desempenho é simplesmente a média de $S_j(k)$. Então o novo centro do agrupamento é dado por:

$$\mu_j(k+1) = \frac{1}{n_j} \sum_{x \in S_j(k)} x, \quad j=1, 2, \dots, k \quad (3.18)$$

sendo n_j o número de elementos de $S_j(k)$.

Passo 4: Se $\mu_j(k+1) = \mu_j(k)$, $j=1, 2, \dots, k$, o algoritmo tem sido convergente e o processo é finalizado, caso contrário volta-se ao passo 2.

3.3 - Interpretação geométrica do problema de estimação de proporções

O problema de estimação de proporções do pixel mistura pode ser interpretado geometricamente como o de minimizar a distância entre o vetor observado e o "simplex" de sinais, segundo CORREIA (1983) apud AGUIAR (1991). Entende-se por "simplex" de sinais à figura geométrica formada quando são ligados os pontos determinados pelos vetores médias dos componentes envolvidos no pixel.

A figura 3.2 ilustra o significado do problema de estimação de proporções no caso particular em que o pixel é representado pela mistura de três componentes. Verifica-se que as extremidades A_1 , A_2 e A_3 dos vetores μ_1 , μ_2 e μ_3 , respectivamente, determinam o triângulo que define o plano π . Se o ponto extremo, M , do vetor observado, x , estiver acima ou abaixo do plano π a restrição de que $p(x/w_1) + p(x/w_2) + p(x/w_3) = 1$ não será satisfeita, onde $p(x/w_i)$ tem o mesmo significado que no método de Máxima Verossimilhança. Por outro lado, se o ponto M estiver no plano π , mas não se localizar no interior ou fronteira do triângulo, as restrições $p(x/w_i) \geq 0$ ($i=1, 2, \dots, m$) serão violadas.

Portanto, o problema de estimação de proporções resume-se a minimizar a distância do vetor observado x ao "simplex" de sinais, sujeito às restrições:

$$\sum_{i=1}^m p(x/w_i) = 1 \quad (3.19)$$

$$p(x/w_i) \geq 0 \quad , \text{ para } i=1, 2, \dots, m \quad (3.20)$$

sendo m o número de componentes (classes "puras"). No caso que o ponto M está no plano π e localizado dentro ou na fronteira do

triângulo, esta distância é zero, logo o erro de estimação é zero e o ponto M é realmente composto pela mistura dos componentes.

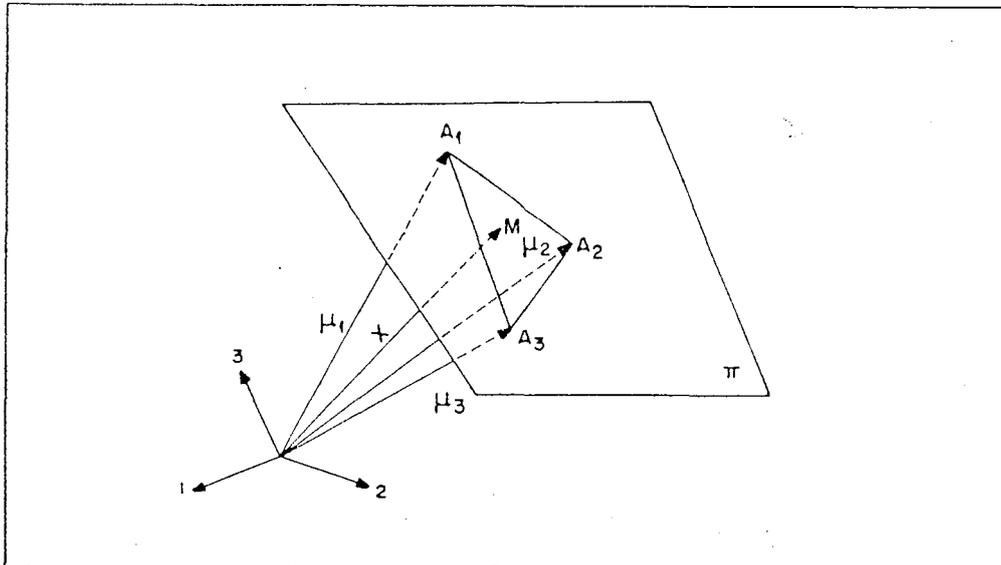


Figura 3.2 - Interpretação geométrica do problema de estimação de proporções para três componentes e três bandas espectrais. Adaptado de AGUIAR (1991).

3.4 - Significado da distância de Mahalanobis

Considerando a função discriminante $g_i(x)$ do método de Máxima verossimilhança dada pela equação 3.12 e assumindo que: a) as matrizes de covariâncias são iguais para todas as classes, e b) a probabilidade a priori para todas as classes é a mesma, a regra de decisão é simplificada para atribuir o vetor x à classe w_i , minimizando o valor da expressão:

$$(x - \mu_i)^T \cdot \Sigma^{-1} \cdot (x - \mu_i) \quad (3.21)$$

Essa expresssão é conhecida como a distância de Mahalanobis entre x e μ_c . A distância de Mahalanobis pode ser entendida de uma maneira simples como sendo a distância Euclidiana ponderada pelos valores da variância e covariância de x . Quanto menor distância de Mahalanobis, maior similaridade entre o pixel e a classe predefinida, em termos de características espectrais. De acordo com WANG (1990.b), a análise dos valores da distância de Mahalanobis associando um pixel às classes existentes, pode fornecer informação adicional a respeito do pixel. Em outras palavras, no processo de classificação o método MVG não faz uso completo das informações contidas nos valores da distância de Mahalanobis. Primeiro, a distância de Mahalanobis pode fornecer informação para diferenciação entre pixels puros e pixels mistura: o vetor de um pixel puro deve estar mais próximo à média da classe que o vetor do pixel mistura. Segundo, comparando as distâncias de Mahalanobis, é possível identificar as classes componentes de um pixel mistura e estimar suas proporções.

Assim, a informação contida na distância de Mahalanobis não é totalmente aproveitada no classificador convencional, Máxima Verossimilhança, representando perda de informação.

3.5 - Algoritmo de classificação baseado na representação Fuzzy

O algoritmo Fuzzy de classificação supervisionada é baseado na representação Fuzzy da informação. Esse algoritmo consiste de duas grandes partes: estimação dos parâmetros Fuzzy a partir de amostras e partição do espaço multiespectral.

3.5.1 - Representação Fuzzy da informação geográfica

Seja X o universo de valores, onde um elemento genérico é denotado com x . Então $X = \{x\}$. A pertinência de um elemento x a um conjunto A de X muitas vezes é considerada em relação a uma função μ_A que pode tomar valores $\{0;1\}$, sendo $\mu_A = 1 \iff x \in A$. O conjunto Fuzzy B de X é caracterizado por uma função pertinência ("membership function") f_B que associa cada x com um número real no intervalo $[0,1]$. A função f_B representa o "grau de pertinência" de x em B . A função f_B toma o valor 1 para os elementos mais próximos de B . O conjunto B não tem limites com uma forma definida e cada elemento pode pertencer parcialmente a mais de um conjunto.

No método convencional de representação da informação geográfica, cada pixel é associado a uma única classe. Na representação Fuzzy as classes são definidas como conjuntos Fuzzy, e os pixels como elementos do conjunto. Na representação Fuzzy cada classe é representada por uma matriz (matriz associação). Os elementos dessa matriz representam os pixels da imagem e o valor numérico respectivo descreve o grau de associação do pixel com a classe.

Num processo de classificação Fuzzy, deve existir um número de matrizes associação igual ao número de classes "puras" existentes na cena. Os valores numéricos associados a uma mesma posição nas diversas matrizes associação descrevem o grau de associação do pixel correspondentes com cada uma das classes.

Essa abordagem é aqui utilizada para descrever os pixels mistura: os graus de associação representando a pertinência do pixel a cada classe é interpretado como a fração da área do pixel ocupada pelas classes componentes.

3.5.2 - Partição Fuzzy do espaço multiespectral

Tradicionalmente, a partição do espaço espectral é baseada nos princípios de teoria clássica de conjuntos. Superfícies de decisão são precisamente definidas por alguma regra de decisão, por exemplo a regra de decisão da máxima verossimilhança, para separar as regiões. Um pixel situado em uma determinada região é classificado como correspondente a essa única classe. Esta partição é conhecida como "hard-partition", e se mostra na figura 3.3.

Na representação Fuzzy o espaço espectral não é particionado por superfícies bem definidas. Neste caso, um pixel pode pertencer a mais de uma classe, obviamente com diferente grau de associação. Esta partição é chamada "partição Fuzzy" do espaço espectral. A figura 3.4 mostra as matrizes pertinência de um pixel numa partição Fuzzy.

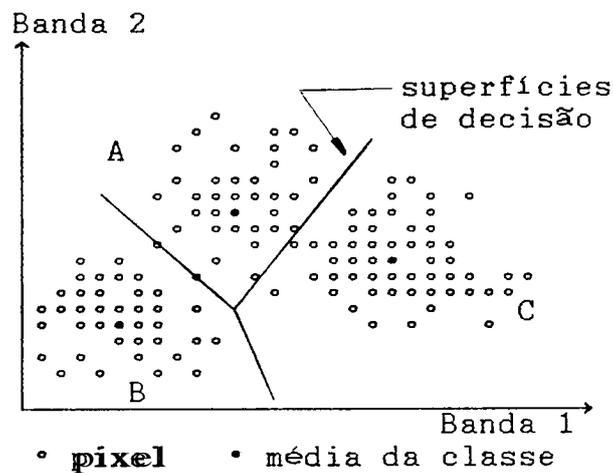


Figura 3.3 - Partição hard do espaço multiespectral e superfícies de decisão.

Fonte: WANG (1990.a)

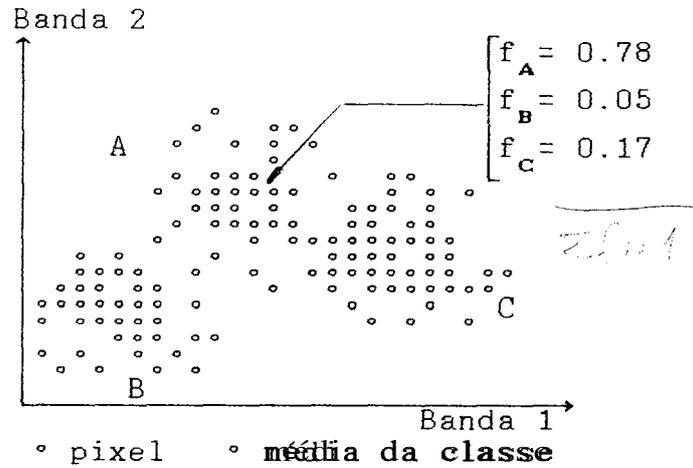


Figura 3.4 - Matriz pertinência de um pixel e partição Fuzzy do espaço multispectral.
 Fonte: WANG (1990.a)

Formalmente, segundo aponta WANG (1990.a), a partição Fuzzy do espaço espectral é uma familia de conjuntos F_1, F_2, \dots, F_m no universo X tal que:

para todo $x \in X$:

$$0 \leq f_{F_i}(x) \leq 1 \tag{3.22}$$

$$\sum_{x \in X} f_{F_i}(x) > 0 \tag{3.23}$$

$$\sum_{i=1}^m f_{F_i}(x) = 1 \tag{3.24}$$

onde F_1, F_2, \dots, F_m representam as classes espectrais, X é o total de pixels, m é o número de classes predefinidas, x é um pixel e f_{F_i} é a função pertinência ao conjunto Fuzzy F_i ($1 \leq i \leq m$).

A partição Fuzzy pode ser expressada na forma de uma matriz de partição Fuzzy:

$$\begin{bmatrix} f_{F_1}(x_1) & f_{F_1}(x_2) & \dots & f_{F_1}(x_n) \\ f_{F_2}(x_1) & f_{F_2}(x_2) & & f_{F_2}(x_n) \\ \dots & \dots & \dots & \dots \\ f_{F_m}(x_1) & f_{F_m}(x_2) & & f_{F_m}(x_n) \end{bmatrix} \quad (3.25)$$

A matriz de partição "hard" pode ser derivada da matriz de partição Fuzzy trocando o maior valor de cada coluna por um e as outras por zero.

Segundo WANG (1990.b), a partição Fuzzy do espaço espectral pode representar melhor a situação real que a partição "hard" e permite obter mais informação espectral para ser utilizada em análises subsequentes. As matrizes pertinência podem ser usadas para descrever classes misturas ou condições intermediárias. Outra vantagem da partição Fuzzy na análise de aglomeração ("cluster") é que pixels perdidos ou isolados entre classes podem ser classificados deste modo.

3.5.3 - Parâmetros Fuzzy

Os parâmetros dos algoritmos de classificação supervisionada são gerados por aplicação de métodos estatísticos a um conjunto de dados. Os parâmetros são uma parte crítica na estimação da pertinência de um pixel a uma determinada classe. Perdas de precisão na classificação são muitas vezes devidas às variações entre os parâmetros gerados estatisticamente e os "reais". A representação Fuzzy torna possível a estimação dos parâmetros

estatísticos com mais precisão. WANG (1990.b) cita que segundo ZADEH (1968), isso pode-se conseguir por meio das medidas de probabilidades dos eventos Fuzzy.

Na teoria de probabilidades, quando um evento A é precisamente definido por um grupo de pontos no espaço amostral Ω , a probabilidade de A pode ser expressa pela integral de LEBESGUE & STIELTJES como:

$$P(A) = \int_A dp \quad (3.26)$$

ou equivalentemente

$$P(A) = \int_{\Omega} \chi_A(x).dp \quad (3.27)$$

onde x denota um ponto de Ω e $\chi_A(x)$ é a função característica de A . ($\chi_A(x)=0$ ou 1). Quando A é um evento Fuzzy, a medida da probabilidade de A pode ser definida como:

$$P(A) = \int_{\Omega} f_A(x).dp \quad (3.28)$$

onde $f_A(x)$ é a função pertinência de A ($0 \leq f_A(x) \leq 1$). Essa definição é uma generalização de 3.27. Agora a pertinência parcial de um ponto x em A pode ser levada em conta em $P(A)$.

Similarmente, a média e variância de um evento Fuzzy A pode ser expressada como:

$$\mu_A^* = \frac{1}{P(A)} \int_{\Omega} x.f_A(x).dp \quad (3.29)$$

$$\sigma_A^{*2} = \frac{1}{P(A)} \int_{\Omega} (x - \mu_A^*)^2.f_A(x).dp \quad (3.30)$$

A média e variância calculadas deste modo são chamadas média Fuzzy e variância Fuzzy, que no caso discreto são calculadas

pelas seguintes expressões:

$$\mu_j^* = \frac{\sum_{i=1}^n f_j(x_i) \cdot x_i}{\sum_{i=1}^n f_j(x_i)} \quad (3.31)$$

$$\Sigma_j^* = \frac{\sum_{i=1}^n f_j(x_i) \cdot (x_i - \mu_j^*) \cdot (x_i - \mu_j^*)^T}{\sum_{i=1}^n f_j(x_i)} \quad (3.32)$$

onde n é o número total de pixels amostrados, $f_j(x_i)$ é a função pertinência da classe j , e x_i é o pixel (vetor) amostrado.

3.5.4 - Análise dos comportamentos espectrais dos componentes da mistura

O comportamento espectral dos elementos utilizados como componentes primários (classes puras) é crítico para o bom desempenho dos modelos de mistura. Entende-se por comportamento espectral a forma com que o objeto (alvo) modifica o espectro de energia que incide sobre ele. A figura 3.5 ilustra exemplos de comportamentos espectrais para alguns materiais característicos de áreas urbanas.

Segundo HORWITZ et al. (1971) apud AGUIAR (1991), as assinaturas espectrais das classes puras podem ser obtidas como nos métodos convencionais de classificação supervisionada, isto é, dado um certo número de amostras pertencentes a uma classe, são estimados o vetor média e a matriz de variância e covariância para esta

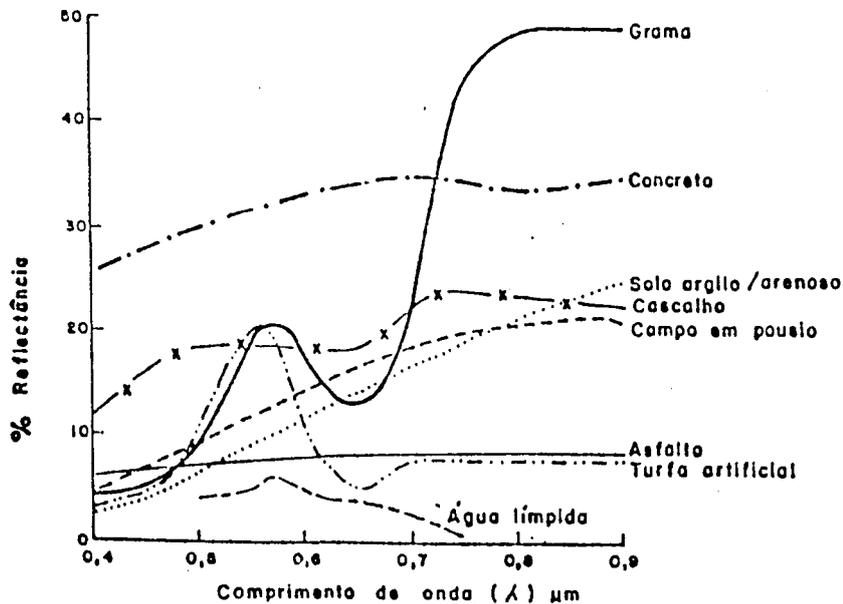


Figura 3.5 - Comportamentos espectrais de alguns alvos característicos de áreas urbanas.

Fonte: JENSEN (1983)

classe. Uma maneira alternativa, utilizada por HORWITZ et al. (1975), consiste em empregar uma técnica de agrupamento de dados, que evita o problema causado pela dificuldade de localizar amostras em número suficiente para o cálculo das estatísticas.

A qualidade esperada das estimativas de proporção pode ser determinada examinando o conjunto de assinaturas das classes puras. Sabe-se que as amostras retiradas de uma população normalmente distribuída agrupam-se em uma nuvem de pontos cujo centro é o vetor de média e cuja forma é determinada pela matriz de covariância. A figura 3.6 ilustra o "simplex" de sinais para três componentes (classes puras) e duas bandas espectrais.

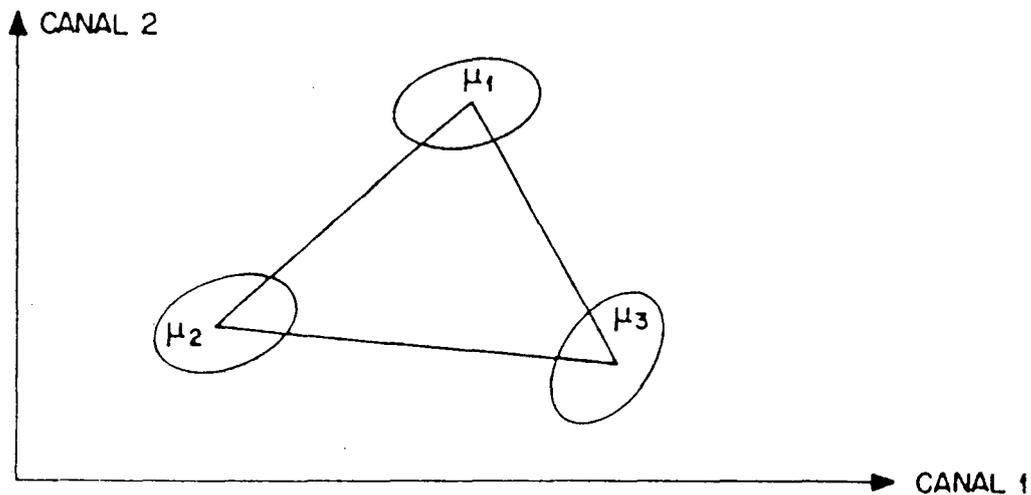
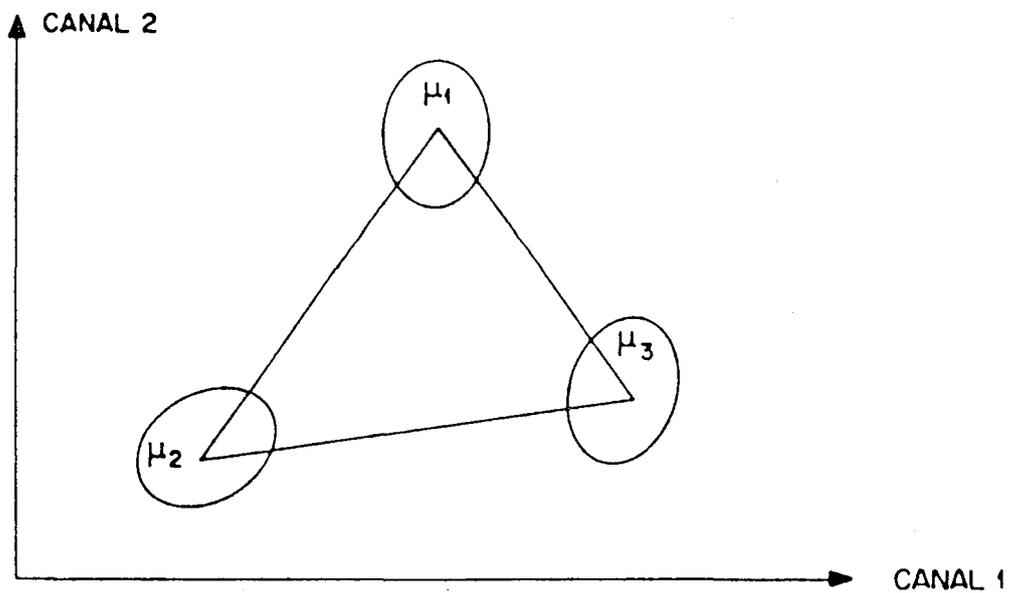
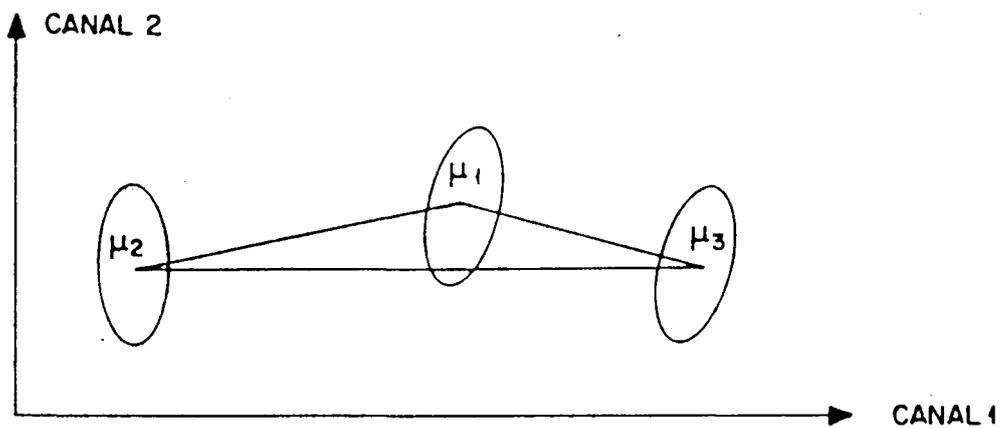


Figura 3.6 - Simplex de sinais para três componentes e duas bandas espectrais. Fonte: AGUIAR (1991).

A condição necessária para uma boa estimativa é que nenhuma assinatura seja próxima, em sentido probabilístico, a qualquer assinatura de uma mistura de outras classes, pois pontos pertencentes ao elipsoide centrado em μ_i podem ser confundidos com pontos representativos da amostra de outras classes; neste caso, diz-se que o "simplex" de sinais é mal-condicionado. A figura 3.7.a ilustra um caso no qual o simplex é bem-condicionado e a figura 3.7.b um no qual é mal-condicionado.



(a)



(b)

Figura 3.7 - Simplex de sinais: a) bem-condicionado;
b) mal-condicionado.

Fonte: AGUIAR (1991).

3.5.5 - Função pertinência Fuzzy

Uma das maiores dificuldades da aplicação da abordagem da matemática Fuzzy é a estimação da função pertinência. Embora a função pertinência Fuzzy seja formalmente similar à função densidade de probabilidade, conceitualmente, são diferentes. Probabilidade é quão frequentemente uma amostra acontece numa população, enquanto o valor da função pertinência Fuzzy significa quão corretamente uma amostra se assemelha a um elemento ideal de uma população. No caso de classificação de imagens multiespectrais, esse elemento "ideal" define uma classe "pura" (componente primário da mistura).

O algoritmo utilizado para a estimação da função pertinência Fuzzy é baseado no conceito de que existe um protótipo ou um elemento ideal para uma classe, e o grau de associação de cada elemento a essa classe está diretamente relacionado à similaridade do elemento com o ideal, ou, em outras palavras, inversamente relacionado à distância do elemento ideal (protótipo).

Seja $d(x, \mu)$ a distância de um elemento genérico, representado pelo vetor $x = \{x_1, x_2, \dots, x_n\}$, ao protótipo $\mu = \{\mu_1, \mu_2, \dots, \mu_n\}$ de uma certa classe, verificando-se que $d(x, \mu) \geq 0$. O valor da função pertinência Fuzzy do elemento x para essa classe será:

$$f_i(x) = r\{d(x, \mu_i)\} \quad (3.33)$$

onde : $f_i(x)$: função pertinência para a classe i ,
 r : função estritamente decrescente com a distância
 $d(x, \mu_i)$, e
 μ_i : elemento ideal ou protótipo para a classe i .

Dois exemplos de tipos de funções pertinência são:

$$f_i(x) = [1 + d(x, \mu_i)]^{-1} \quad (3.34)$$

$$f_i(x) = \exp[-d(x, \mu_i)] \quad (3.35)$$

WANG (1990.b), propõe que as funções pertinência para cada classe sejam calculadas com base na função densidade de probabilidade normal multivariada, substituindo a média e a variância convencional pela média e variância Fuzzy, respectivamente. Para cada classe a função pertinência fica definida assim:

$$f_j(x) = \frac{P_j^*(x)}{\sum_{i=1}^m P_i^*(x)} \quad (3.36)$$

onde:

$$P_i^*(x) = \frac{1}{(2\pi)^{n/2} \cdot |\Sigma_i^*|^{1/2}} \cdot e^{-\frac{1}{2} \cdot (x - \mu_i^*)^T \cdot \Sigma_i^{*-1} \cdot (x - \mu_i^*)} \quad (3.37)$$

n é a dimensão do vetor x , m é o número de classes predefinidas, e $1 \leq i \leq m$.

As matrizes pertinência de um pixel x dependem da posição dos demais pixels. A função $f_j(x)$ cresce exponencialmente com o decrescimento da distância entre x e μ_j , isto é:

$$(x - \mu_j^*)^T \cdot \Sigma_j^{*-1} \cdot (x - \mu_j^*) \quad (3.38)$$

O termo $\sum_{i=1}^m P_i^*(x)$ serve como fator normalizador.

WANG (1990.b) aponta, que foi verificado que a matriz pertinência calculada a partir da equação 3.36 é proporcional à percentagem com que cada classe esta presente no pixel. Consequentemente, este algoritmo foi utilizado neste trabalho para a identificação das componentes dos pixels mistura.

4 - CARACTERÍSTICAS TOPOGRÁFICAS DA BACIA

Neste capítulo é apresentada a metodologia utilizada no desenvolvimento de um software para a extração automática de informação topográfica de uma bacia hidrográfica, a partir do modelo numérico de terreno. Essas informações referem-se à rede de drenagem superficial, divisor de águas, área da bacia e curva hipsométrica.

4.1 - DIVISOR DE ÁGUAS E REDE DE DRENAGEM SUPERFICIAL

O divisor de águas e a rede de drenagem foram derivados a partir da matriz de altitudes do MNT, segundo um esquema estruturado nas seguintes etapas: 1) preenchimento das depressões do MNT, 2) determinação das declividades e das direções do escoamento, e 3) determinação do divisor de águas e da rede de drenagem superficial.

a) - Preenchimento de depressões:

A matriz de altitude foi obtida a partir da digitalização das curvas de níveis em cartas topográficas em escala 1:10.000. Portanto, foi preciso uma transformação do modelo de linha (curvas de nível) para um modelo de ponto (matriz de altitude), conforme foi explicado na seção 1.3. A matriz de altitudes assim obtida pode apresentar depressões, geradas no processo de interpolação. Faz-se

necessário então, numa primeira etapa, preencher essas depressões. Uma depressão ocorre quando uma simples célula da matriz de altitudes apresenta uma elevação menor que a de seus vizinhos, definidos em uma janela de três células por três células, como ilustra a figura 4.1.

b) - Determinação de declividades e orientações:

Uma vez preenchidas as depressões existentes no MNT determina-se a declividade de cada célula da matriz de altitudes. Para cada célula é determinada a declividade em relação aos oito vizinhos mais próximos definidos por uma janela de três por três células centralizada na célula analisada.

A declividade é calculada com a seguinte expressão:

$$D = \begin{cases} \frac{Z_c - Z_v}{dx} & \text{para as células vizinhas localizadas} \\ & \text{na horizontal em relação à célula} \\ & \text{central.} \\ \frac{Z_c - Z_v}{dy} & \text{para as células vizinhas localizadas} \\ & \text{na vertical em relação à célula} \\ & \text{central.} \\ \frac{Z_c - Z_v}{(dx^2 + dy^2)^{1/2}} & \text{para as células vizinhas localizadas} \\ & \text{na diagonal em relação à célula} \\ & \text{central.} \end{cases} \quad (4.1)$$

onde:

- D : declividade,
- Z_c : cota da célula central,
- Z_v : cota da célula vizinha,
- dx : resolução horizontal da grade, e
- dy : resolução vertical da grade.

136	135	143	146	146
137	129	139	141	144
141	130	132	136	134
128	133	131	134	135

(a)

136	135	143	146	146
137	130	139	141	144
141	130	132	136	134
128	133	131	134	135

(b)

Figura 4.1 - a) Matriz de altitudes com depressão e esquema da janela utilizada para detectar depressões; b) matriz de altitudes com as depressões preenchidas.

Logo, é atribuída à célula a maior das oito declividades calculadas, ou zero caso seja uma área plana.

A seguir, com base nas declividades determinou-se a orientação de cada célula, ou seja a direção do escoamento em cada célula. As orientações foram discretizadas em oito classes: NE, E, SE, S, SW, W, NW e N, e codificadas com: 1, 2, 3, 4, 5, 6, 7 e 8, respectivamente.

Foram identificadas quatro condições possíveis de acontecerem no processo de determinação da orientação de cada célula, como se ilustra na tabela 4.1

A condição 1 corresponde ao caso de uma depressão, onde as declividades em relação às células vizinhas são negativas. Esta situação é resolvida preenchendo-se as depressões existentes no MNT, como foi explicado acima. A condição 2 é a mais simples, somente numa direção a declividade é positiva, portanto essa será a orientação da célula. A condição 3 ocorre quando a célula apresenta a mesma declividade em mais de uma direção. Neste caso a orientação é decidida de forma arbitrária. O critério adotado consiste em procurar, conforme o sentido em que as direções são analisadas, qual das possíveis orientações ocorre primeiro e atribuir essa orientação

à célula . Neste trabalho adotou-se o sentido horário, partindo da direção norte-leste (NE). Portanto para o exemplo da tabela 4.1 a orientação da célula será E, ou seja código 2. A condição 4 é a mais difícil de ser resolvida e representa a situação de uma área plana.

Tabela 4.1 - Exemplos das quatro condições possíveis na determinação da orientação de cada célula.

Condição	Cota	Declividade	Orientação
1	100 102 100	-7.0 -12.0 -7.0	-
	99 90 92	-9.0 -2.0	
	98 94 92	-5.6 -4.0 -1.4	
2	92 91 90	-1.4 -1.0 0.0	2
	92 90 89	-2.0 1.0	
	94 93 90	-2.8 -3.0 0.0	
3	90 91 90	0.0 -1.0 0.0	2
	89 90 89	1.0 1.0	
	90 93 90	0.0 -3.0 0.0	
4	92 91 90	-1.4 -1.0 0.0	Aplica-se processo iterativo
	93 90 90	-3.0 0.0	
	94 93 90	-2.8 -3.0 0.0	

No processo de determinação das orientações primeiro são resolvidas as condições 1, 2 e 3, deixando para o final a condição 4, que é resolvida por um processo iterativo. Nesse procedimento iterativo se atribui à célula uma das orientações possíveis e se verifica que a célula vizinha localizada na direção escolhida não tenha uma orientação oposta à atribuída à célula analisada, se isso não acontecer se repete o procedimento com uma outra orientação. Este procedimento é repetido até atribuir à célula uma orientação compatível com a orientação das células vizinhas.

c) - Determinação do divisor de águas e da rede de drenagem:

A delimitação da bacia hidrográfica e a determinação da rede de drenagem superficial foi feita a partir da matriz de

orientações. O processo se inicia definindo a saída da bacia. Uma janela de três células por três células é centralizada na célula que representa a saída da bacia e procura-se entre as oito células vizinhas qual está a montante da célula central da janela. A célula a montante é encontrada pela análise das orientações, conforme descrito no item anterior. A célula que tiver uma orientação tal que aponte à célula central da janela será a célula escolhida. A seguir, a célula central da janela é posicionada na célula identificada como "a montante", e repete-se o procedimento até encontrar uma célula para a qual não exista outra a montante, então esta célula é marcada como pertencente à bacia. A célula central da janela posiciona-se novamente na saída da bacia e se repete todo o processo, descartando-se da análise as células já definidas como pertencentes à bacia. Este processo finaliza quando a célula definida como saída da bacia seja marcada como pertencente à bacia. Nesta situação a bacia hidrográfica foi totalmente delimitada.

A rede de drenagem superficial é determinada simultaneamente à delimitação da bacia. Considerando-se que cada célula da bacia contribui com um volume unitário de água, então a rede de drenagem em cada ponto da bacia é determinada pelo volume de água acumulado que passa sobre esse ponto, que será proporcional à quantidade de células atravessadas desde o divisor da bacia até o ponto (ou célula) analisada.

4.2 - OUTRAS CARTERÍSTICAS TOPOGRÁFICAS

a) Área:

A área da bacia, ou seja, a área plana (projeção horizontal) compreendida entre seus divisores topográficos, foi

determinada com a seguinte expressão:

$$A = NC \cdot dx \cdot dy \quad (4.2)$$

onde: A : área da bacia,
NC: número de células pertencentes à bacia;
dx: resolução horizontal da grade, e
dy: resolução vertical da grade.

b) Curva hipsométrica:

A maior parte dos fatores meteorológicos e hidrológicos (precipitações, temperaturas, vazões específicas, etc.) apresentam-se em função da altitude. Portanto é interessante determinar a distribuição da superfície da bacia segundo a altitude. Essa distribuição é calculada assim: divide-se o intervalo de altitudes definido pelas cotas máximas e mínima da bacia num certo número de sub-intervalos e se computa a área da bacia compreendida em cada sub-intervalo. A seguir, acumulam-se os valores de área determinados para cada sub-intervalo, começando pelo intervalo de maior altitude. Representando em um gráfico, em ordenadas os valores acumulados das áreas anteriormente computadas e em abscisas os sub-intervalos definidos, obtem-se a curva hipsométrica da bacia.

5 - EXPERIMENTOS

Neste capítulo descreve-se os experimentos realizados e apresentam-se os resultados obtidos no desenvolvimento da proposta previamente descrita, isto é, obtenção da fração de áreas impermeáveis através do mapeamento da bacia em termos de uso-cobertura do solo e obtenção da estrutura topográfica da bacia.

5.1 - AREA DE ESTUDO

Para o desenvolvimento deste trabalho foi escolhida a bacia urbana do arroio do Meio, que por sua vez constitui uma sub-bacia da bacia do arroio Dilúvio, situada na região metropolitana de Porto Alegre, no Estado de Rio Grande do Sul, localizada entre as latitudes S-30°00'00" e S-30°07'00" e as longitudes O-51°05'00" e O-51°15'00", como aparece na figura 5.1. O fator decisivo na escolha da área de trabalho foi a cobertura de nuvens na imagem multiespectral SPOT disponível.

A imagem disponível para o desenvolvimento deste trabalho (18/12/88), apresenta uma cobertura de nuvens de 20 %, percentagem relativamente baixa, mas infelizmente distribuída em grande parte sobre a área metropolitana de Porto Alegre. Isso impediu trabalhar com uma área maior, por exemplo, toda a bacia do arroio Dilúvio.

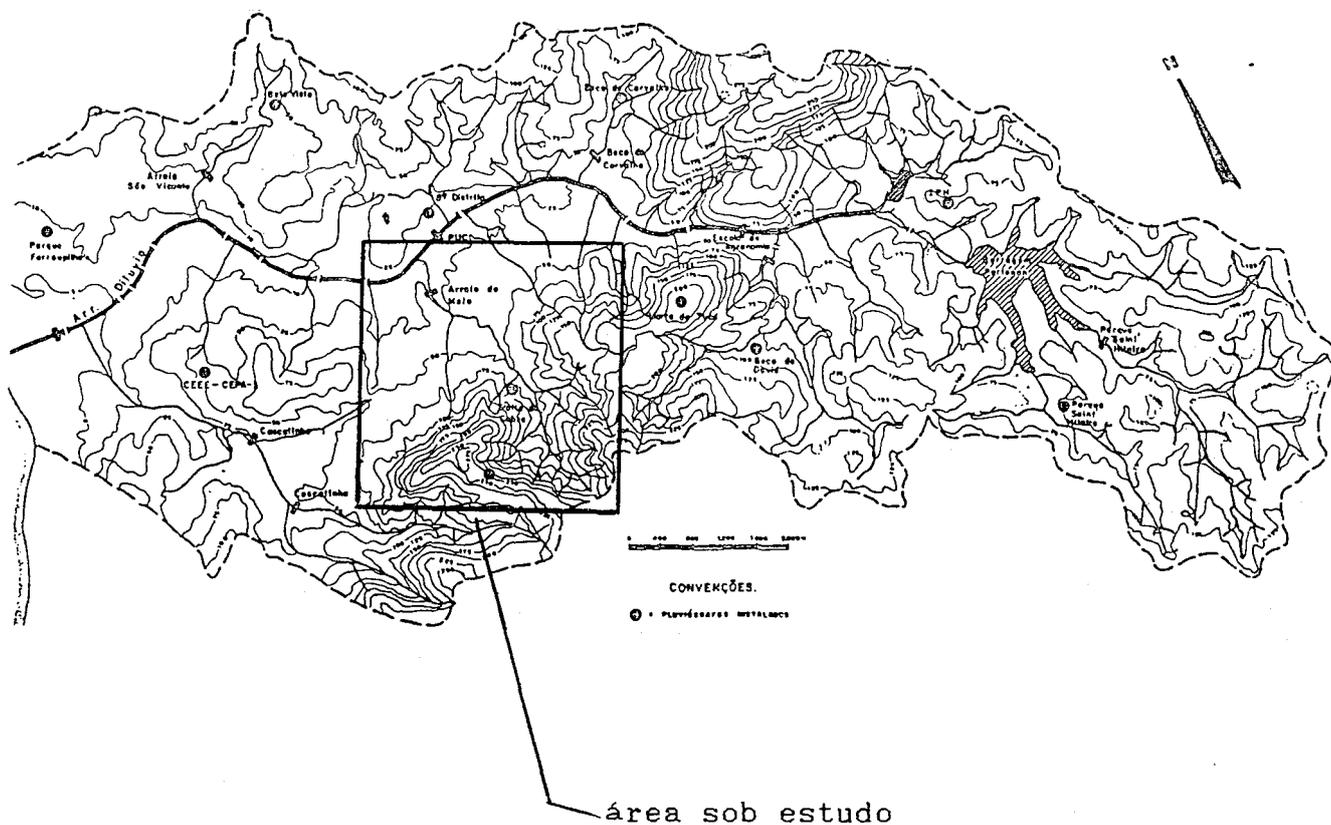


Figura 5.1 - Bacia do arroio Dilúvio. Porto Alegre - RS
Adaptada de SANCHEZ et al. (1983).

5.2 - MATERIAIS

Foram usados os equipamentos disponíveis no Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia (CEPSRM), fundamentalmente o sistema de tratamento de imagens SITIM-150 e o sistema de informações geográficas SIG.

Em relação às imagens digitais, foram utilizadas imagens do satélite SPOT do 18 de dezembro de 1988, cujas coordenadas são: K-711 e J-410. As imagens correspondem aos seguintes canais espectrais:

Canal 1:	0,50 a 0,59 μm
Canal 2:	0,61 a 0,68 μm
Canal 3:	0,79 a 0,89 μm
Canal pancromático:	0,51 a 0,73 μm

Também usou-se fotografias aéreas em escala 1:5.000 (maio de 1980) e as cartas topográficas: 2987.2-A, B, F, G, H (Esc. 1:10.000) e 2987-NO, NE, SE (Esc. 1:25.000).

5.3 - PROCEDIMENTO METODOLOGICO

O trabalho experimental foi dividido em duas fases principais:

- Fase I : classificação das imagens multiespectrais SPOT, com o propósito de obter a fração de áreas impermeáveis. Esta etapa foi desenvolvida no ambiente do sistema SITIM, disponível no Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia - CEPSRM.
- Fase II : obtenção da estrutura topográfica da bacia: rede de drenagem, divisor de água, área de drenagem e curva hipsométrica, a partir do modelo numérico do terreno. Esta etapa foi desenvolvida no SIG disponível no mesmo Centro.

5.3.1 - Fase I

O primeiro passo foi a escolha das bandas de trabalho. Para determinar quais são os melhores bandas ou combinação de bandas para usar no processo de classificação das imagens digitais, foram tomadas amostras das classes mais representativas da imagem e graficada a relação de bandas (números digitais), como mostram as figuras 5.2.a, 5.2.b e 5.2.c. Nesta etapa foram consideradas seis classes diferentes chamadas:

- 1) residencial de alta densidade (70% ou mais de área construída),
- 2) residencial de baixa densidade (30 % ou menos de área construída),
- 3) vegetação de pequeno porte (gramíneas),
- 4) vegetação de grande porte (arbustos e arbores),
- 5) solo exposto, e
- 6) corpos de água.

É fácil perceber que a banda 1 (0.50 - 0.59 μm) e a banda 2 (0.61 - 0.68 μm) apresentam alta correlação; a tabela 5.1 mostra os coeficientes de correlação entre as diferentes bandas. Além disso, da interpretação visual das figuras 5.3.a e 5.3.b correspondentes às classes que evidenciam maior confusão percebe-se que as bandas 2 e 3 (0.79 - 0.89 μm) apresentam maior poder de discriminação. Este fato também foi comprovado estatisticamente conforme a metodologia que segue.

Uma metodologia para a escolha das melhores bandas para o mapeamento de uma bacia urbana foi proposto por ROOT et al (1972). O processo baseia-se no algoritmo da distância Euclidiana que matematicamente descreve a distância entre duas curvas em determinadas bandas espectrais.

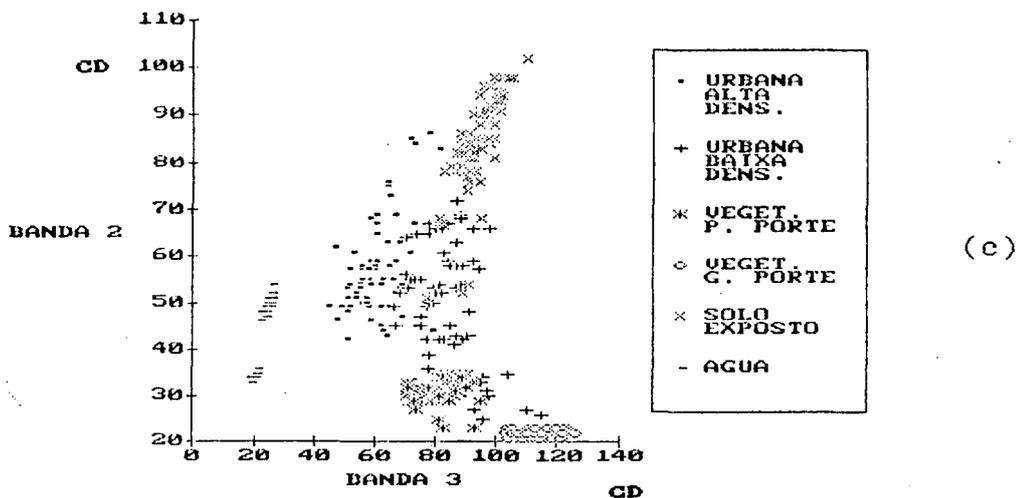
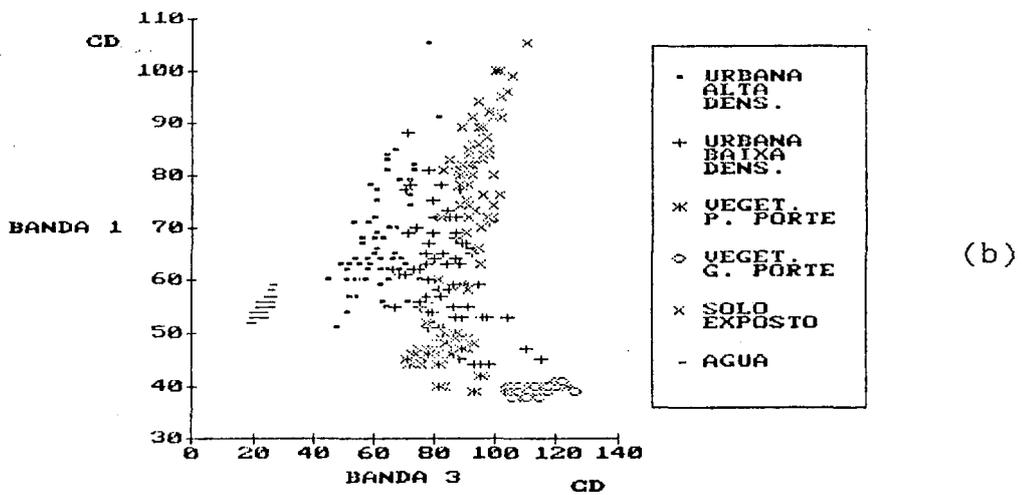
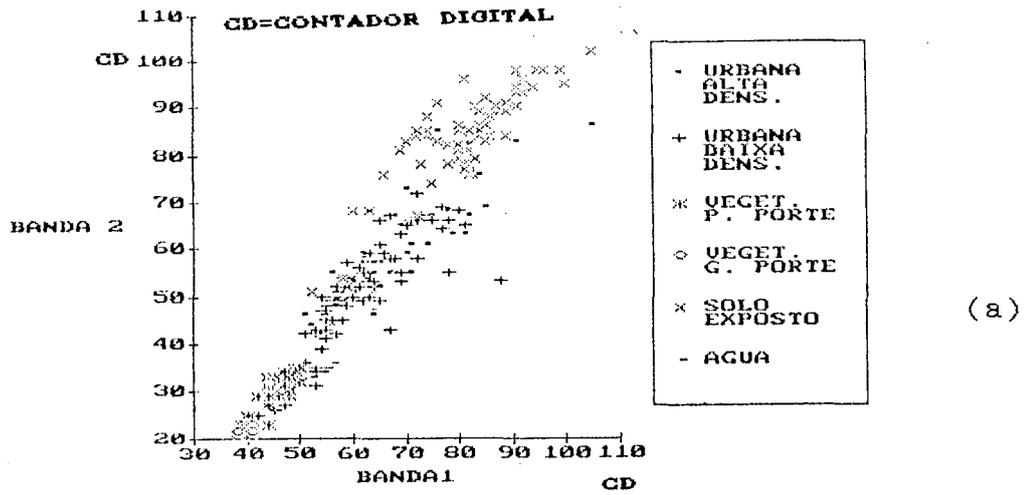


Figura 5.2 - Relação de bandas SPOT para cinco classes.

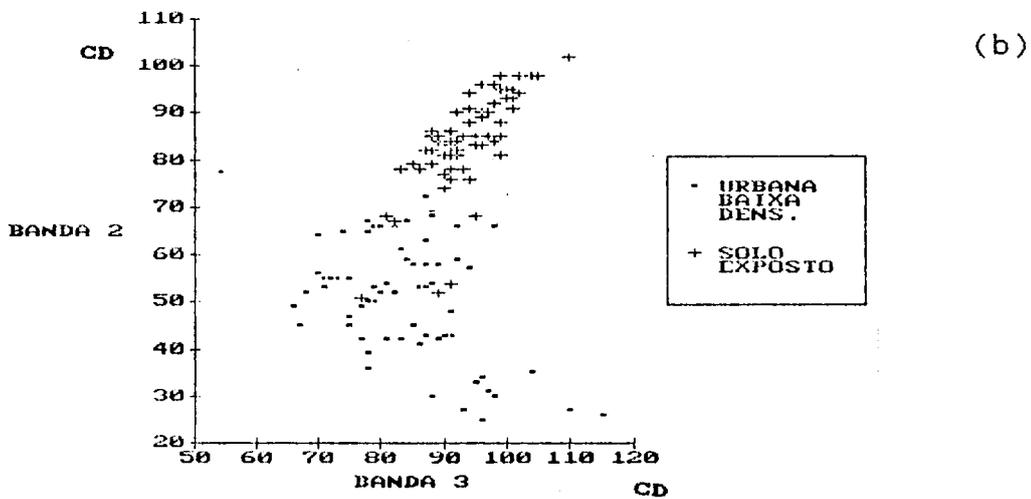
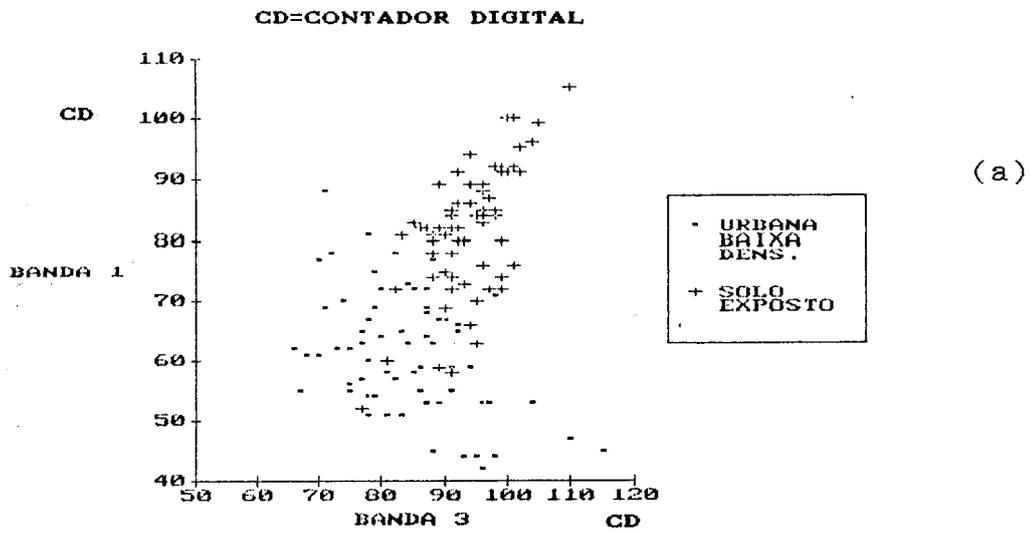


Figura 5.3 - Relação de bandas SPOT para as classes que apresentam maior confusão.

Essa distância é definida por:

$$d = \sum_{i=1}^n \frac{(B_i - A_i)^2}{S_p^2} \quad (5.1)$$

onde d : distância Euclidiana ponderada;

A_i : número digital médio da classe A na banda i ;

B_i : número digital médio da classe B na banda i ;

n : número ótimo de bandas multiespectrais;

S_p^2 : variância ponderada de N amostras para as classes A e B na banda i ; onde:

$$S_p^2 = \frac{N_A \cdot S_A^2 + N_B \cdot S_B^2}{N_A + N_B} \quad (5.2)$$

onde N_A : número de amostras da classe A;

N_B : número de amostras da classe B;

S_A^2 : variância da classe A;

S_B^2 : variância da classe B.

Como o número de amostras N é constante para todas as classes ($N_A = N_B$) então a expressão da variância ponderada fica simplificada (nesta aplicação $N=75$):

$$S_p^2 = (S_A^2 + S_B^2)/2 \quad (5.3)$$

A metodologia estabelece o cálculo da distância Euclidiana ponderada para cada banda e combinações de bandas, escolhendo para cada caso os valores: máximo, mínimo e médio. Posteriormente esses três valores são comparados para selecionar a melhor combinação de bandas, que apresente maior distância Euclidiana ponderada máxima,

maior distância Euclidiana ponderada mínima e maior distância Euclidiana ponderada média, com maior ênfase na distância Euclidiana ponderada média.

A tabela 5.2 apresenta as distâncias Euclidianas ponderadas calculadas para as possíveis combinações de bandas, verificando-se, como seria óbvio, que a combinação das bandas 1, 2 e 3 é a melhor. Contudo, o ganho em relação à combinação das bandas 2 e 3 é muito pequeno. Conseqüentemente, optou-se por trabalhar com as bandas 2 e 3 somente. Na mesma tabela, verifica-se que os valores das distâncias Euclidianas ponderadas para a combinação das bandas 1 e 2 são muito pequenos, confirmando a análise feita anteriormente e mostrada na figura 5.2.a.

Tabela 5.1 - Coeficientes de correlação linear entre as bandas SPOT.

Bandas	Coef. correlação linear
1-2	0.9586
1-3	-6.1853E-02
2-3	-5.8267E-02

Tabela 5.2 - Distância Euclidiana ponderada máxima, mínima e média para as diferentes combinações de bandas multiespectrais SPOT.

Combinação de bandas	Dist. Euclidiana pond.		
	máxima	mínima	média
1	11.642	0.439	3.578
2	8.852	0.575	3.726
3	21.052	0.389	6.522
1-2	12.404	0.724	5.306
1-3	24.056	2.172	7.814
2-3	21.483	2.389	8.194
1-2-3	24.434	2.690	9.057

Definidas as bandas de trabalho, o passo seguinte foi a classificação das imagens multiespectrais SPOT, visando obter a fração de áreas impermeáveis. A maioria dos algoritmos de classificação de imagens digitais se baseiam, como apontam ANDRADE & PEREIRA (1989), nas características espectrais da imagem, partindo da suposição de que os pixels em uma mesma classe possuem características espectrais semelhantes, o que nem sempre é verificado, principalmente tratando-se de áreas urbanas. As áreas urbanas por serem bastante heterogêneas, apresentam pixels com grande variabilidade espectral, fazendo com que as classes ocupem maiores áreas no espaço espectral aumentando assim a superposição entre elas. Essa superposição aumenta a probabilidade de erro na classificação. Além disso, a reflectância dos materiais que cobrem o solo dentro da região compreendida por um pixel são integrados e produzem um valor único de reflectância para este pixel. Esse valor como diz JENSEN (1983), nem sempre é relacionado à cobertura de solo dominante na área, podendo apresentar características semelhantes às de uma cobertura totalmente diferente. Daí a importância, também, da resolução espacial alta nos estudos de cobertura do solo urbano, já que reduz a proporção de pixels mistura.

No método convencional de classificação supervisionada - máxima verosimilhança são levadas em conta exclusivamente as classes "puras", ou seja, cada pixel pode estar associado a uma única classe de uso-cobertura do solo. Este método não tem a capacidade de representar misturas de classes e condições intermediárias que acontecem na maioria das imagens digitais. Particularmente em áreas urbanas, como a área sob estudo, a mistura de classes é muito significativa, conseqüentemente o nível de precisão da classificação usando o método convencional é limitado.

Uma alternativa, usada neste trabalho, é o novo algoritmo de classificação supervisionada baseado na representação Fuzzy, explicado em detalhes no capítulo 3. Para a implementação deste

algoritmo foi elaborado um programa em linguagem C, desenvolvido dentro do ambiente do sistema SITIM-150 disponível no CEPSRM.

O primeiro passo no processo de classificação foi a definição das classes "puras" ou componentes primários da cena. Para a definição das classes foram levados em consideração os seguintes critérios: a) cada classe devia representar uma determinada condição de impermeabilidade do solo; b) a precisão na interpretação para as diferentes classes devia ser aproximadamente a mesma; c) a categorização devia permitir que o uso do solo pudesse ser inferido a partir dos tipos de cobertura do solo; d) tendo em vista que o somatório das probabilidades associadas a cada classe ($\sum P_i(x)$) é utilizado na estimação dos elementos da matriz pertinência é necessário que seja utilizado um valor realista para o número de classes com o objetivo de diminuir o erro na classificação e, e) o simplex de sinais deve ser bem-condicionado. Assim, foram definidas as seguintes classes "puras" ou componentes primários da cena:

- Área construída
- Vegetação de grande porte.
- Vegetação de pequeno porte.
- Solo exposto

A figura 5.4 ilustra o "simplex" de sinais para as duas bandas de trabalho e as quatro classes consideradas. Pode-se perceber que o simplex de sinais resultante é mal-condicionado, conforme foi explicado no capítulo 3. A classe "vegetação de pequeno porte" confunde-se com uma possível classe mistura, cujos componentes primários seriam área construída e vegetação de grande porte.

Essa situação conduziria a erros no processo de classificação, provocados pela confusão da classe "pura" vegetação de pequeno porte e a possível classe mistura. Consequentemente,

eliminou-se a classe vegetação de pequeno porte, resumindo-se a três os componentes primários da cena. Deste modo foi obtido um simplex de sinais bem-condicionado, como ilustra a figura 5.5.

Definidas as classes puras presentes na cena, foi feita uma classificação supervisionada da imagem multiespectral SPOT, utilizando o algoritmo Fuzzy. Foram testados os dois tipos de funções pertinência citados na seção 3.5.5, isto é, a função linear dada pela equação 3.34 onde $d(x, \mu)$ representa a distância de Mahalanobis, e a função exponencial do tipo da equação 3.35. A expressão particular da função pertinência exponencial é dada pelas equações 3.36 e 3.37.

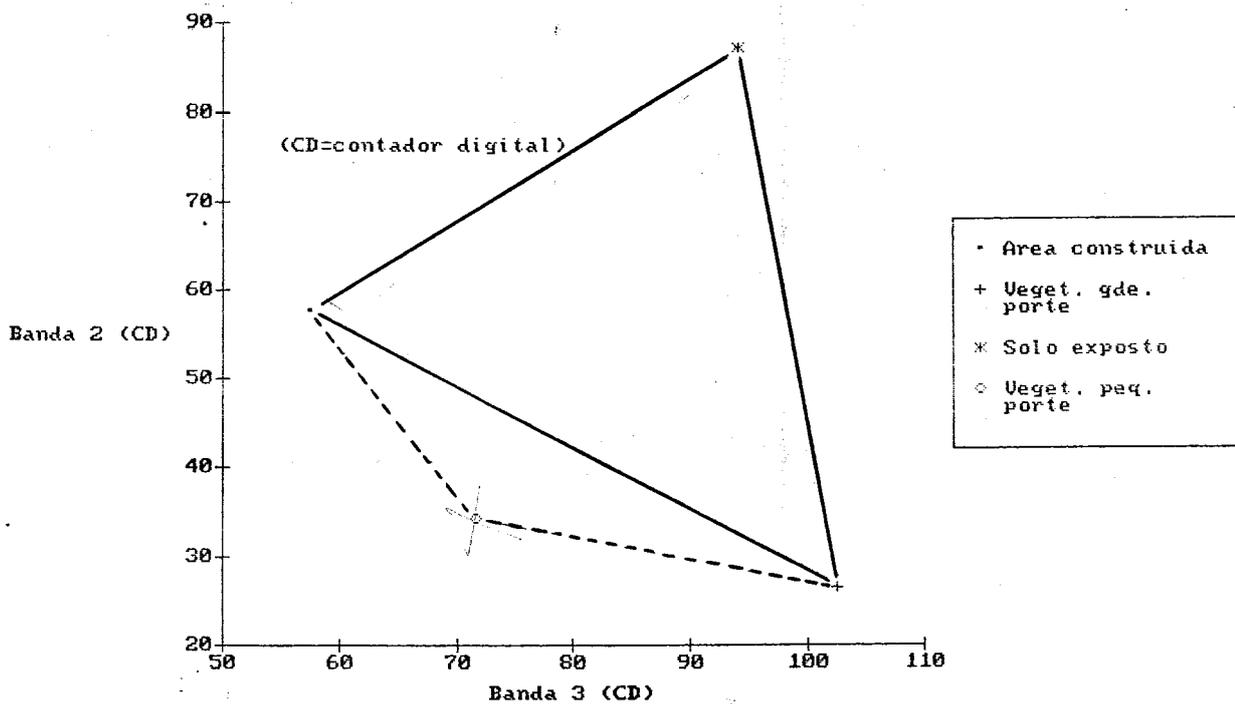


Figura 5.4 - Simplex de sinais mal-condicionado.

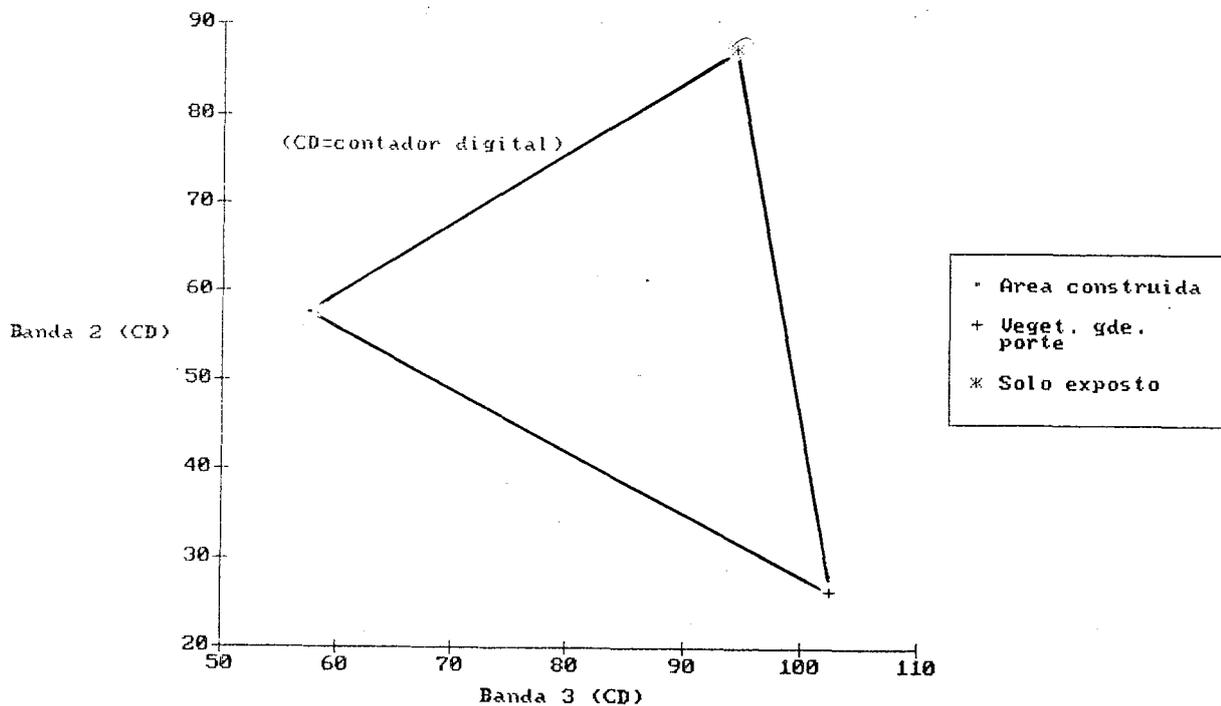


Figura 5.5 - Simplex de sinais bem-condicionado.

Para a estimação dos parâmetros da função pertinência, isto é, média e variância para cada classe pura, foram amostrados pixels representativos de cada classe.

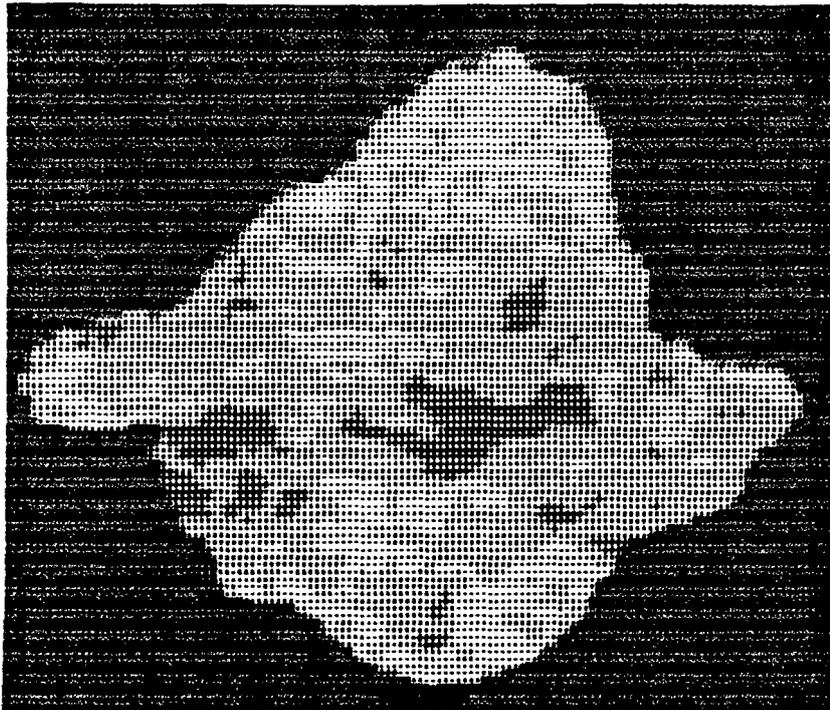
Como resultado dessa classificação obteve-se três matrizes pertinência (uma para cada classe) na forma de imagens digitais, como ilustram as figuras 5.6, 5.7 e 5.8. O valor associado a cada pixel em cada uma dessas imagens é o grau de associação ou pertinência do pixel a cada classe que, segundo WANG (1990.a), é proporcional à área do pixel ocupada por cada classe. Nesta dissertação assume-se como válida a hipótese de WANG, isto é, que o grau de pertinência do pixel às diferentes classes indica a proporção das classes puras na composição do pixel mistura.

A tabela 5.3 ilustra os resultados obtidos no processo de classificação da imagem digital para os dois tipos de funções pertinência testados. Os pontos dessa tabela foram escolhidos arbitrariamente. Percebe-se que o algoritmo que utiliza a função pertinência de tipo linear descreve melhor os pixels mistura do que o algoritmo que utiliza a função pertinência de tipo exponencial. Esse fato fica evidente, também, na figura 5.9, particularmente para os pontos 3, 6, 7 e 10, cujas posições relativamente afastadas dos centros das classes puras indicariam que são pixels mistura.

Tabela 5.3 - Matrizes de pertinência obtidas com a função de pertinência linear e a função pertinência exponencial.

Pto.	Nro. digital Banda 2	Nro. digital Banda 3	Função pert. exponenc.			Função pert. linear		
			Construção	Vegetação	Solo exposto	Construção	Vegetação	Solo exposto
01	35	77	0.423	0.574	0.003	0.415	0.410	0.175
02	56	70	0.415	0.001	0.584	0.753	0.064	0.183
03	44	67	1.000	0.000	0.000	0.714	0.124	0.162
04	60	105	0.000	0.618	0.382	0.235	0.391	0.374
05	22	122	0.000	1.000	0.000	0.089	0.823	0.088
06	55	83	0.867	0.003	0.130	0.491	0.188	0.321
07	62	71	0.945	0.000	0.055	0.727	0.050	0.223
08	40	101	0.000	1.000	0.000	0.103	0.809	0.088
09	67	108	0.002	0.031	0.967	0.223	0.285	0.492
10	40	89	0.004	0.995	0.001	0.251	0.587	0.162
11	106	107	0.000	0.000	1.000	0.151	0.057	0.792
12	58	70	0.978	0.000	0.022	0.756	0.056	0.188
13	82	88	0.019	0.000	0.981	0.145	0.024	0.831

Além desta avaliação qualitativa dos resultados, também, foi feita uma avaliação quantitativa, comparando a fração de áreas impermeáveis obtida no processo de classificação da imagem multiespectral com a fração de áreas impermeáveis obtidas por medição direta na imagem pancromática, com 10 metros de resolução espacial (considerada como o valor correto). Somente a classe área construída foi considerada como impermeável. O método tradicional para a determinação da fração de áreas impermeáveis é a medição



Valor função Padrão
pertinência

< 0.078	1
0.078-0.196	4
0.196-0.588	7
0.588-0.940	10
> 0.940	12

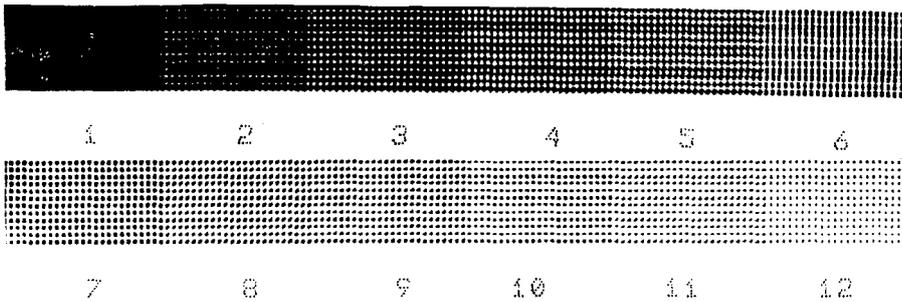
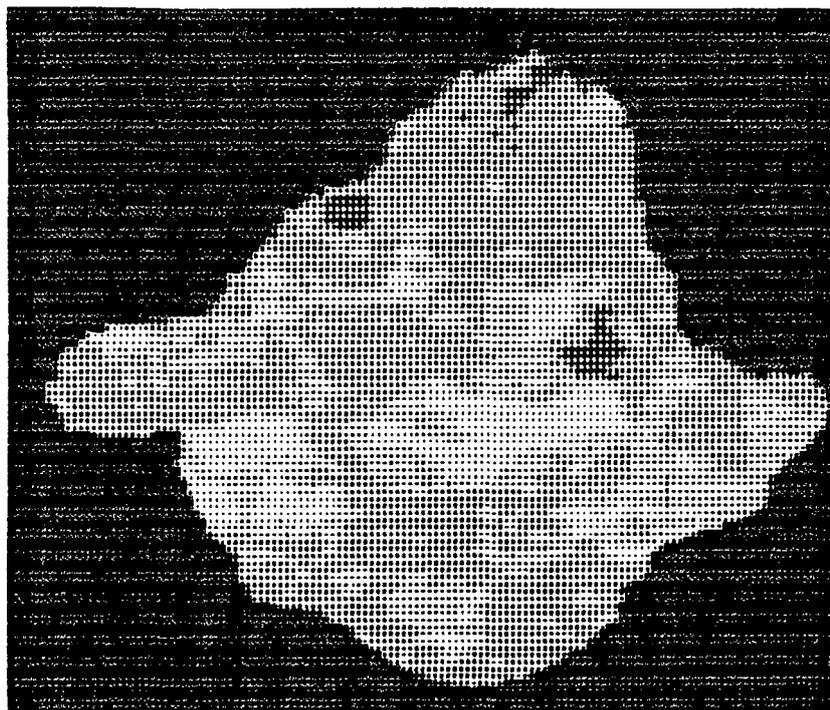


Figura 5.6 - Matriz pertinência para a classe
área construída.



Valor função Padrão
pertinência

< 0.078	1
0.078-0.196	4
0.196-0.588	7
0.588-0.940	10
> 0.940	12

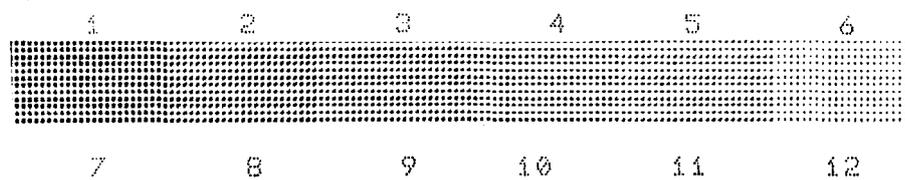
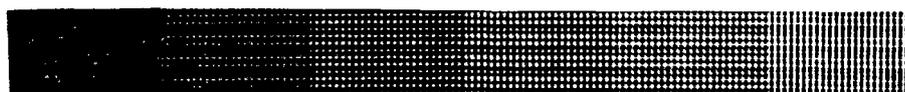


Figura 5.7 - Matriz pertinência para a classe vegetação.



Valor função Padrão
pertinência

< 0.078	1
0.078-0.196	4
0.196-0.588	7
0.588-0.940	10
> 0.940	12



1 2 3 4 5 6



7 8 9 10 11 12

Figura 5.8 - Matriz pertinência para a classe
solo exposto.

Tabela 5.4 - Avaliação dos resultados da classificação.

	Imagem pancromática SPOT	Função pertinên. linear	Função pertinên. exponenc.	Erro função linear (%)	Erro função expon. (%)
Área impermeável (km ²)	0.758	0.822	0.869	8.44	14.70
Área permeável (km ²)	3.327	3.263	3.216	1.92	3.34
Área total (km ²)	4.085	4.085	4.085		

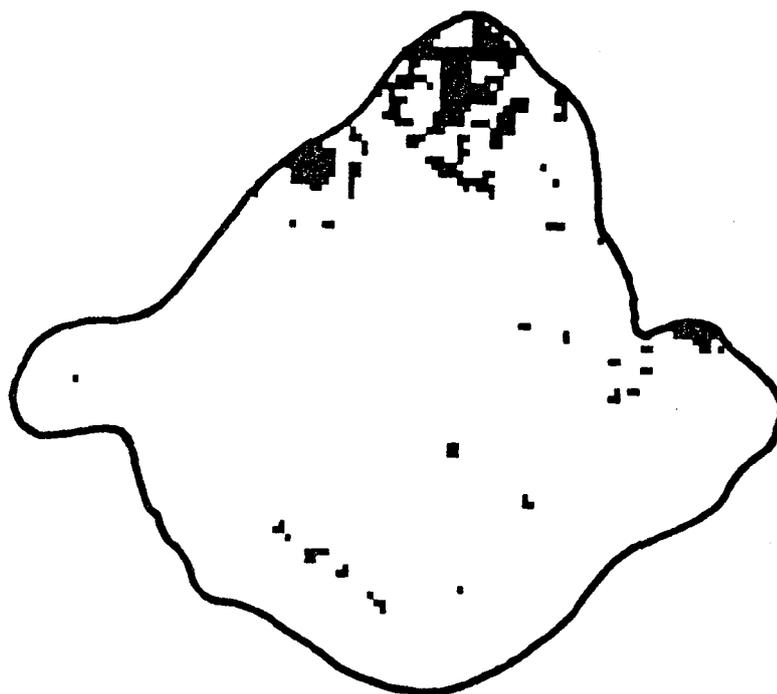


Figura 5.10 - Distribuição espacial das áreas impermeáveis.

5.3.2 - Fase II

As informações sobre as características topográficas da bacia, isto é, divisor de águas, rede de drenagem, área da bacia e curva hipsométrica foram obtidas por aplicação de um software especialmente desenvolvido para essa finalidade, conforme o procedimento apresentado no capítulo 4. Os dados requeridos pelo modelo são: a matriz de altitudes (MNT) e as coordenadas da saída da bacia de interesse.

O modelo numérico do terreno foi obtido a partir da digitalização manual de cartas topográficas em escala 1:10.000 com equidistância de 5 m entre curvas de nível. Esta representação do MNT (modelo de linha) não é computacionalmente apropriada, tendo sido por essa razão convertida para um modelo de ponto (matriz de altitudes) utilizando o SIG disponível no CEPSRM. O produto final é uma matriz de altitudes com uma resolução espacial de 100 m x 100 m, como ilustra a figura 5.11.

O algoritmo utilizado para a delimitação automática da bacia exige, além das coordenadas de saída da bacia de interesse, que a área coberta pelo MNT seja tal que a bacia a ser delimitada esteja totalmente contida nele. Conseqüentemente, a extensão do MNT é decidida com base em estudos existentes ou em forma aproximada, a partir da observação das curvas de nível na área de interesse, como foi feito neste trabalho. As coordenadas envolventes do MNT escolhidas são: $X_1=480712.33$, $Y_1=670068.53$ e $X_2=485550.15$, $Y_2=675000.00$. Essas coordenadas correspondem à projeção UTM (Universal Transverse Mercator). A figura 5.12 corresponde ao MNT após a delimitação da bacia do arroio do Meio e a figura 5.13 é uma representação da rede de drenagem. A área da bacia delimitada automaticamente é de 4.085 km^2 , enquanto a área da bacia determinada pelos métodos convencionais é de 4.343 km^2 (SANCHEZ et al., 1983).

Isso representa um erro na estimaco da rea da bacia de 5.94 %, que  considerado aceitvel.

A tabela 5.5 corresponde  distribuo da superfcie total da bacia do arroio do Meio em funo da altitude. Com esses dados constri-se a curva hipsomtrica mostrada na figura 5.14. Na mesma figura  mostrada a curva hipsomtrica existente, obtida de SANCHEZ et alii (1983).

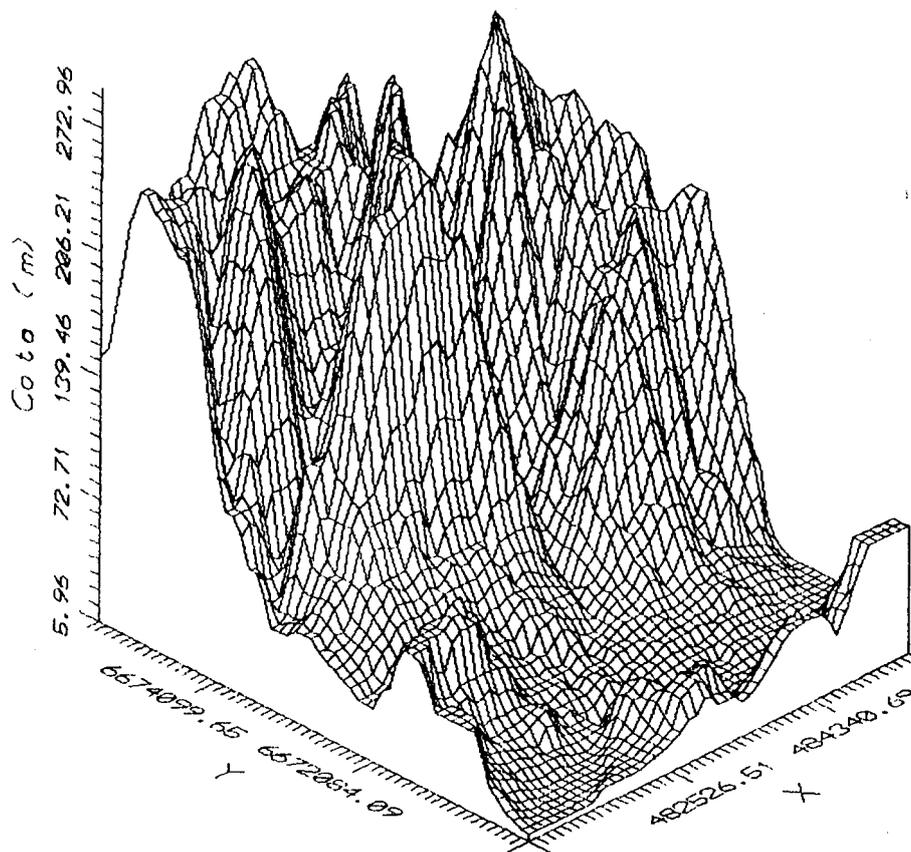


Figura 5.11 - MNT da rea sob estudo.
(As coordenadas X e Y correspondem  projeo UTM)

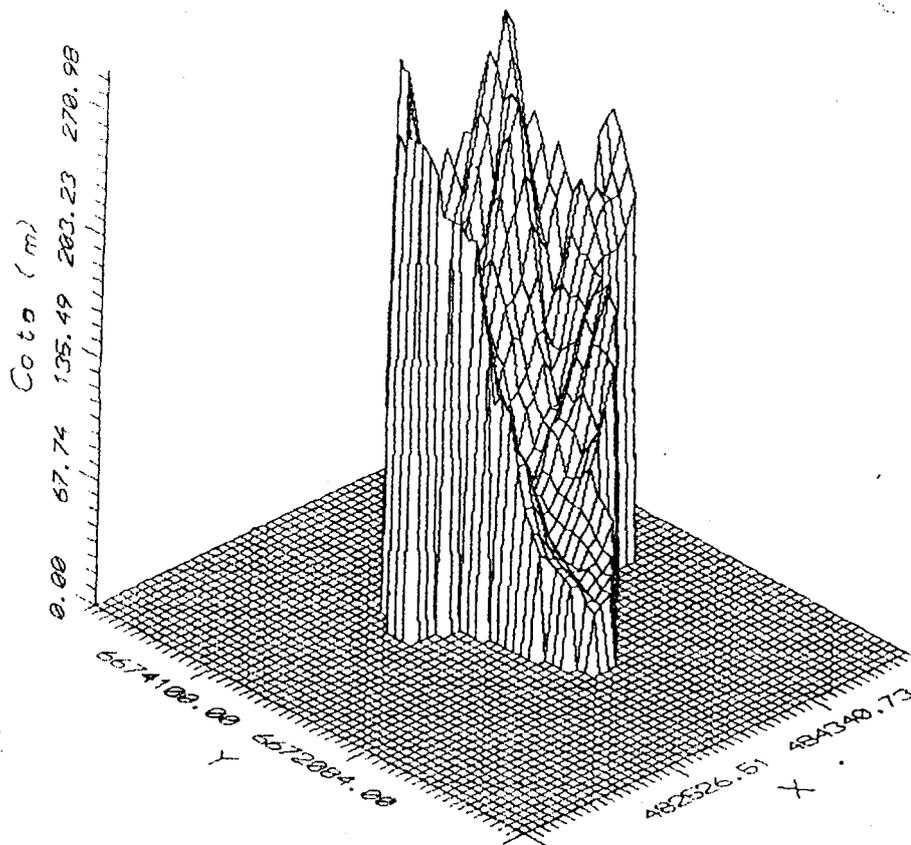


Figura 5.12 - MNT da bacia do Arroio do Meio
 (As coordenadas X e Y correspondem à projeção UTM)

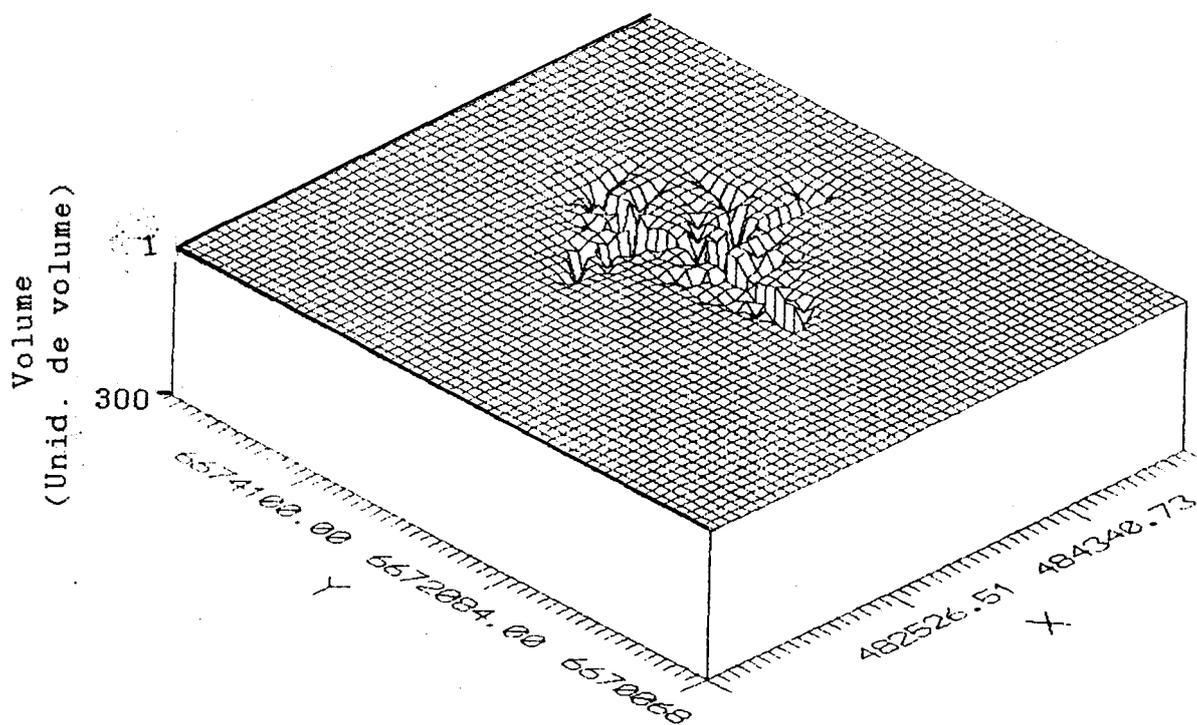


Figura 5.13 - Representação volumétrica da rede de drenagem
 ba bacia do Arroio do Meio.

(As coordenadas X e Y correspondem à projeção UTM)

tabela 5.5 - Distribuição da área da bacia do arroio do Meio em função da altitude.

Altitude (m)	Área		Área acumulada	
	km ²	%	km ²	%
< 19.33	0.041	1.00	4.085	100.00
19.33 - 38.66	0.580	14.21	4.044	99.00
38.66 - 58.00	0.414	10.13	3.464	84.79
58.00 - 77.33	0.490	12.00	3.050	74.66
77.33 - 96.67	0.447	10.94	2.560	62.66
96.67 - 116.00	0.299	7.33	2.113	51.72
116.00 - 135.33	0.368	9.01	1.814	44.39
135.33 - 154.67	0.331	8.10	1.446	35.38
154.67 - 174.00	0.359	8.79	1.115	27.28
174.00 - 193.33	0.248	6.07	0.756	18.49
193.33 - 216.67	0.204	5.00	0.508	12.42
216.67 - 232.00	0.155	3.80	0.304	7.42
232.00 - 251.33	0.033	0.81	0.149	3.62
251.33 - 279.67	0.033	0.81	0.116	2.81
279.67 - 295.00	0.083	2.00	0.083	2.00

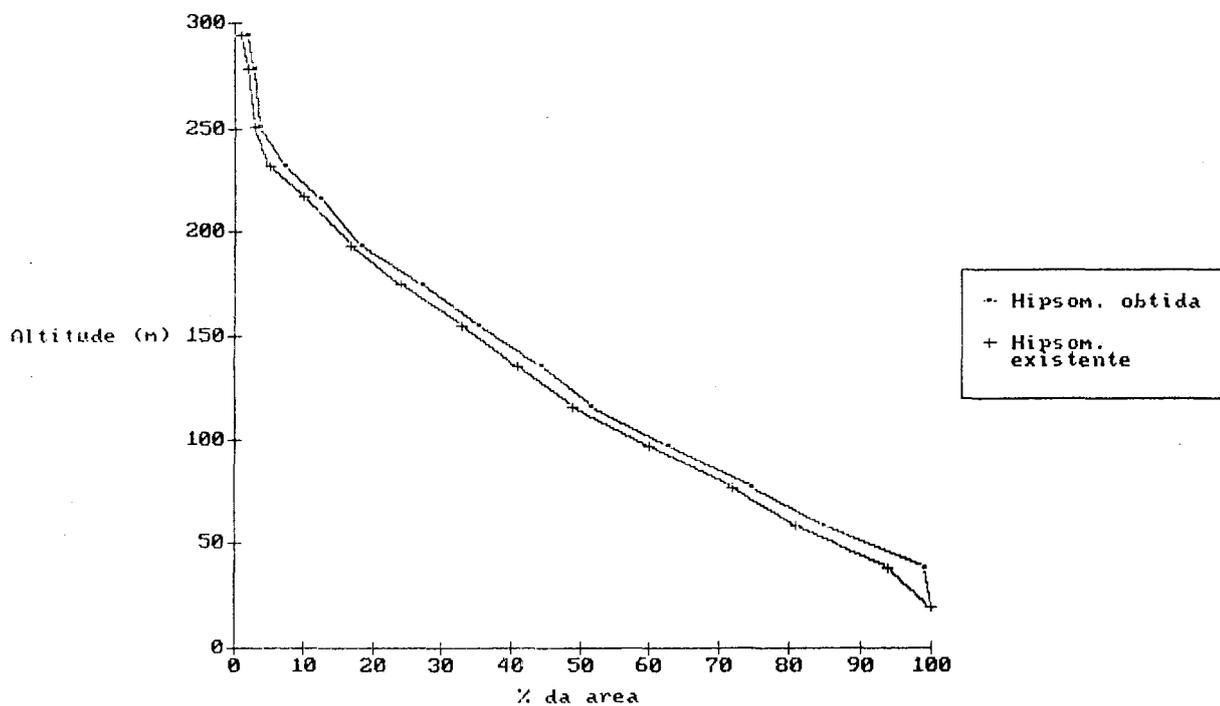


Figura 5.14 - Curva hipsométrica.

6 - CONCLUSÕES E LIMITAÇÕES

Determinação da fração de áreas impermeáveis:

No processo de classificação de imagens digitais foram evidenciados três aspectos críticos. O primeiro, diz respeito à definição das diferentes categorias de cobertura do solo, consideradas como classes "puras" ou componentes primários. Em áreas urbanas, como a área em estudo, a diversidade de tipos de cobertura é bastante ampla. Infelizmente, muitos desses materiais apresentam características espectrais similares, que impossibilita sua diferenciação no processo de classificação. Portanto, constitui uma limitação ao número de classes puras possíveis de considerar.

O segundo aspecto está associado restrições próprias do algoritmo de classificação, isto é, o simplex de sinais bem-condicionado. Isso significou, também, numa limitação do número de classes puras consideradas.

O terceiro aspecto tem relação direta com os parâmetros estatísticos das diferentes classes definidas no espaço espectral, mais especificamente a variância e covariância. Em testes prévios à obtenção dos resultados finais, verificou-se que os melhores resultados acontecem quando as diferentes classes apresentam variâncias e covariâncias comparáveis, isto é, da mesma ordem de grandeza. Se uma classe apresenta variância e covariância muito grande em relação às outras classes, o algoritmo de classificação superestima o grau de associação dos pixels com essa classe. Assim, recomenda-se que as classes puras, ou componentes primários de cena,

sejam escolhida de modo apresentarem variâncias e covariância da mesma ordem de grandeza.

Recomenda-se também a utilização do algoritmo de classificação baseado na função pertinência de tipo linear, visto que descreve melhor a mistura dos componentes primários no pixel, em relação ao algoritmo baseado na função pertinência de tipo exponencial.

Além da precisão dos resultados obtidos, um fator que justifica a utilização da metodologia desenvolvida, para a estimação da fração de áreas impermeáveis, é a rapidez com que são obtidos os resultados. Para a área em estudo, com aproximadamente 4 km² foram necessárias 0.60 horas, enquanto que pelo método convencional demandou 6.30 horas. A vantagem da utilização da metodologia proposta neste trabalho torna-se ainda mais evidente quanto maior for a área de estudo.

Extração da estrutura topográfica:

O algoritmo implementado para a determinação de algumas características topográfica da bacia, mostrou-se altamente satisfatório em relação à rapidez e precisão dos resultados obtidos.

O aspecto mais importante a destacar é em relação à densidade dos pontos a partir dos quais é gerado o modelo numérico do terreno (matriz de altitudes). Quanto maior a densidade dos pontos, menor é a quantidade de depressões, que surgem no processo de geração da matriz de altitudes. Considerando-se que o algoritmo utilizado para a delimitação da bacia exige que as depressões sejam preenchidas, quanto menor o número delas, mais eficiente será o algoritmo. Portanto, recomenda-se utilizar uma quantidade

suficientemente densa de pontos para a geração da matriz de altitudes, uma vez que ela constitui o dado primário na determinação das características topográficas da bacia.

Assim, a utilização de tecnologia moderna, como são as técnicas de sensoriamento remoto e a técnica do sistema de informações geográficas, são recomendáveis no campo dos recursos hídricos, particularmente para a determinação das características físicas e topográficas, como foi feito neste trabalho.

7 - BIBLIOGRAFIA

- ADAMS, J; KAPOV, V; SMITH, M.O.; ALMEIDA FILHO Jr.; GILLESPIE, A.R; ROBERTS, D.A. A new Landsat view of land use in Amazonia. In: INTERNATIONAL SYMPOSIUM ON PRIMARY DATA ACQUISITION, 1. Manaus, AM. Proceedings. São José dos Campos, INPE. 1990.
- AGTERBERG F.D. Recent developments in geomathematics. GEOPROCESSING Vol. 2, pp. 1-32. 1982.
- AGUIAR, D.A.P. Utilização de atributos adicionais derivados de separações de classes na classificação multiespectral de imagens de sensoriamento remoto. Dissertação de Mestrado. São José dos Campos, INPE. 1991.
- ANDERSON J. R. A land use and land cover classification system for use with remote sensor data. USGS Professional Paper 964, U.S. GOV. Printing office, Washington, DC. 1976.
- ANDRADE V., PEREIRA M. Uso das características texturais na classificação digital de áreas urbanas. ANAIS IV SIMPOSIO LATINOAMERICANO DE PERCEPCION REMOTA, Vol. I, pp. 401-413. Bariloche, Argentina. 1989.
- BONDELID T. R., JACKSON T. J. e Mc. CUEN R .H. Estimating runoff curve numbers using remote sensing data. JOURNAL OF THE HYDRAULIC DIVISION. 1981.
- BURROUGH P.A. Principles of geographical information systems for land resources assessment. CLARENDON PRESS. Oxford. 1986.
- CERUTI A. A method for drawin slope maps from contour maps by automatic dara acquisition and processing. COMPUT GEOSCI. 6, pp. 289-297. 1980.
- CORREIA, V.R.M. Estudo das medidas de qualidade para estimação de proporções de classes em elementos de resolução de imagens. Dissertação de Mestrado em Análise de Sistemas. São José dos Campos, INPE. 1982.
- COWEN D. Computer mapping vs. GIS: implications for applied

- geography. PAPER AND PROCEEDINGS OF THE ELEVENTH APPLIED GEOGRAPHY CONFERENCE. Knoxville, Tn., pp 43-51. 1987.a.
- COWEN D. GIS vs. CAD vs. DBMS: what are the differences?. PROCEEDING OF THE SECOND INTERNATIONAL WORKSHOP ON GEOGRAPHIC INFORMATION SYSTEMS, GIS'87, San Fransisco, Ca., Vol 1, pp 46-56. 1987.b.
- COWEN D. GIS vs. CAD vs. DBMS: what are the differences?. PHOTOGRAMMETRIC ENGINEERING AND REMOTE SENSING, Vol. 54, pp 1551-1555. 1988.
- DUDA, R.O. e HART, P.E. Pattern classification and scene analysis. New York, NY, Wiley Interscience. 1973.
- GOODCHILD M.F. Geographic information systems in undergraduate geography: a contemporary dilemma. THE OPERATIONAL GEOGRAPHER. 8:34-38. 1985.
- GUEBERT M.D. e GARDNER T.W. Unsupervised SPOT classification and infiltration rates on surface mined watersheds central Pennsylvania. PHOTOGRAMMETRIC ENGINEERING AND REMOTE SENSING, vol. 55, Nro. 10, october, pp 1479-1486. 1989.
- HORWITZ, H.M.; NALEPKA, R.F.; RYDE, P.D.; MORGENSTERN, J.P. Estimating the proportions of objects within a single resolution element of a multispectral scanner. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 7. Ann Arbor, MI. Proceedings. Ann Arbor. MI, Willow Reen Laboratories, p. 1307-1320. 1971.
- HORWITZ, H.M; HIDE, P.D; RICHARDSON, W. Improvements in estimation proportions of objects from multispectral data; report. Ann Arbor. MI, ERIM, 72 p. (NASA CR_ERIM 190/00-24-T). 1975.
- HUNT G.R. Electromagnetic radiations: the communication link in remote sensing. REMOTE SENSING IN GEOLOGY. New York, Wiley. Cap. 2, pp 5-54. 1980.
- INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS - INPE. Circular técnica. São José dos Campos, SP. 1991.
- JENSEN, J.R. Urban/suburban land use analysis In: ESTES J.E.

- MANUAL OF REMOTE SENSING. American Society of Photogrammetry
Vol II- pp.1571-1666. 1983.
- JOHNSON, L.E. MAPHYD - A digital map-based hydrologic modeling
system. PHOTOGRAMMETRIC ENGINEERING AND REMOTE SENSING, vol.
55, Nro. 6, pp.911-917. 1989.
- LAM, N.S. Spatial interpolation methods: a review. Am. Cartogr.
Nro. 10, pp. 129-149. 1983
- LILLESAND, T.M., KIEFER, R.W. REMOTE SENSING AND IMAGE
INTERPRETATION. Ed. Wiley, segunda edição, 721 p. 1987.
- LINDGREN, D.T. Land use planning and remote sensing. Martinus
Nijhoff Publishers, 173 p. 1985.
- MARK D.M. Automated detection of drainage networks from
digital elevation models. CARTOGRAPHICA Nro. 21, pp.168-178.
1984.
- MARK D.M., DOZIER J and FREW J. Automated basin delineation
from digital elevation data. GEOPROCESSING Nro. 2, pp
299-311. 1984.
- PEUKER T. K. and DOUGLASD.H. Detection of surface-specific
points by local parallel processing of discrete terrain
elevation data. COMPUT GRAPH IMAGE PROCESS. Nro. 4, pp.
375-387. 1975.
- RAGAN R. M., JACKSON THOMAS J. Use of satellite data in
urban hydrologic models. JOURNAL OF THE HYDRAULIC DIVISION
December, 1975, pp. 1469-1475.
- RAGAN R.M., JACKSON T.J. Runoff synthesis using Landsat and
SCS model. JOURNAL OF THE HYDRAULIC DIVISION .May, 1980. pp
667-678.
- RIPLEY B. Spatial statistic. Wiley, New York. 1981.
- ROOT R.R. Identification of urban watershed units using remote
multispectral sensing. ENVIRONMENTAL RESOURCES CENTER,
Completion Report Series Nro. 29. 1972.
- SANCHEZ J., TUCCI C. E. e SIMÕES LOPES M. Bacia representativa
urbana do arroio Dilúvio em Porto Alegre, RS. V SIMPOSIO
BRASILEIRO DE HIDROLOGIA E RECURSOS HÍDRICOS Blumenau, SC,

- Brasil. 1983. Revista Brasileira de Engenharia. ANAIS 1, pp. 91-105.
- SCHUT G. Review of interpolation methods for digital terrain models. In Archives of the International Society for photogrammetry, 13 th. Congress, Helsinki, Finland. Vol. 21, part 3. 1978.
- SHIMABUKURO, Y.E. Shade images derived from linear mixing models of multispectral measurements of forested areas. Doctor of Philosophy Dissertation, Fort Collins, CO, Colorado State University. 1987.
- SOIL CONSERVATION SERVICE. National Engineering Handbook Section 4: Hydrology. Washington, D.C.. 1972.
- SOIL CONSERVATION SERVICE Urban hidrology for small watersheds. Technical Release Nro. 55. 1975.
- STANKOWSKI J.S. Population density as an indirect indicador of urban and suburban land-surface modifications. Professional Paper 800-b, United States Geological Survey, pp. b219-b224. 1972.
- STEFFEN C.A., LORENZETTI J.A., STECH J.L. e SOUZA, R.C.M. SENSORIAMENTO REMOTO: princípios físicos, sensores e produtos e sistema LANDSAT. São José dos Campos, INPE. 72 p. 1981. (INPE-2226 - MD/013).
- SWITZER, P. Estimation of the accuracy of qualitative maps. IN DISPLAY AND ANALYSIS OF SPATIAL DATA. Ed. J.C. Davis and M.J. Mc Cullagh, pp. 1-13. 1975. Wiley, NY.
- TOV, J.T e GONZALEZ, R.C. PATTERN RECOGNITION PRINCIPLES. Massachusetts, Addison-Wesley Publishing Company. 1974.
- TUCCI C., BRAGA B. Jr. e SILVEIRA A. Avaliação do impacto da urbanização nas cheias urbanas. REVISTA BRASILEIRA DE ENGENHERIA. 1989.
- URBAN DRAINAGE AND FLOOD CONTROL DISTRICT URBAN STORM DRAINAGE CRITERIAL MANUAL. Denver, Colorado. 1985.
- WANG F. Fuzzy supervised classification of remote sensing images. IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING,

- Vol. 28, Nro. 2, pp. 194-201. 1990.a.
- * WANG F. Improving remote sensing image analysis through Fuzzy information representation. PHOTOGRAMMETRIC ENGINEERING AND REMOTE SENSING , Vol.56, Nro. 8, pp. 1163-1169. 1990.b.
- WEBSTER, R. Sampling and bulking strategies for estimating soil properties in small regions. J. Soil Set, 35, 127-40.
- WILLIAMS Jr. R.S. Geological applications. MANUAL OF REMOTE SENSING. Virginia, American Society of Photogrammetry, Chap. 31, p. 1667-1953. 1983.
- XU JIYAN and WEBSTER R. A geostatistical study of topsoil properties in Zhangwu Conty, China. Catena 11, pp. 13-26. 1984.
- YOELI P. Cartographic contouring with computer and plotter. Am. Cartogr. 11, pp. 139-155. 1984.