

HERMESON NÓBREGA BARROS DE OLIVEIRA

SEGMENTAÇÃO E CLASSIFICAÇÃO DE IMAGENS LANDSAT TM

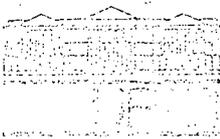
Dissertação apresentada como requisito
parcial à obtenção do grau de Mestre.
Curso de Pós-Graduação em Informática,
Setor de Ciências Exatas,
Universidade Federal do Paraná.

Orientadora: Prof.^ª Dr.^ª Olga R. P. Bellon

Co-orientador: Prof. Dr. Klaus de Geus

CURITIBA

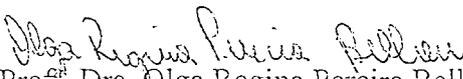
1999

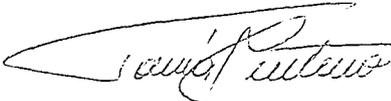


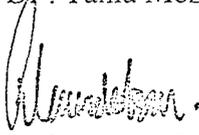
PARECER

Nós, abaixo assinados, membros da Comissão Examinadora da defesa da Dissertação de Mestrado em Informática, do aluno Hermeson Nobrega Barros de Oliveira, avaliamos o trabalho intitulado "Segmentação e Classificação de Imagens Landsat TM", cuja defesa foi realizada no dia 18 de outubro de 1999. Após a Avaliação, decidimos pela Aprovação do Candidato.

Curitiba, 18 de outubro de 1999.


Prof.^a Dra. Olga Regina Pereira Bellon
Presidente


Prof.^a Dr.^a Tania Mezzadri


Prof. Dr. Klaus de Geus


Prof. Dr. Marcos Sfair Sunye

SUMÁRIO

LISTA DE TABELAS	v
LISTA DE FIGURAS	v
RESUMO	viii
ABSTRACT	ix
1. INTRODUÇÃO	01
1.1 JUSTIFICATIVA.....	02
1.2 OBJETIVO.....	03
1.3 CONTRIBUIÇÕES.....	04
1.4 COMPOSIÇÃO.....	04
2. FUNDAMENTOS DE SENSORIAMENTO REMOTO	06
2.1 DEFINIÇÕES.....	06
2.2 ESPECTRO ELETROMAGNÉTICO.....	08
2.3 SISTEMAS SENSORES.....	10
2.3.1 TIPOS DE SENSORES.....	11
2.4 NÍVEL DE AQUISIÇÃO DE DADOS.....	13
2.4.1 SISTEMAS ORBITAIS.....	14
2.5 RESOLUÇÃO E BANDAS.....	16
3. FUNDAMENTOS DE PROCESSAMENTO DIGITAL DE IMAGENS	18
3.1 IMAGEM DIGITAL.....	19
3.2 FASES DO PROCESSAMENTO DE IMAGENS.....	21
3.3 RETIFICAÇÃO DE IMAGENS.....	23
3.3.1 CORRECÇÕES GEOMÉTRICAS.....	23
3.3.2 CORREÇÕES RADIOMÉTRICAS.....	24
3.5 RESTAURAÇÃO DE IMAGENS DE SATÉLITE.....	26
3.6 ELIMINAÇÃO OU REDUÇÃO DO RUÍDO.....	26
3.7 MELHORAMENTO DA IMAGEM.....	27
3.7.1 MANIPULAÇÃO DO CONTRASTE.....	27
3.7.2 MANIPULAÇÃO DAS CARACTERÍSTICAS ESPACIAIS.....	28

4	SEGMENTAÇÃO E CLASSIFICAÇÃO	34
4.1	DEFINIÇÃO FORMAL	35
4.2	CLASSIFICAÇÃO DE IMAGENS	35
4.2.1	CLASSIFICAÇÃO SUPERVISIONADA	36
4.2.2	ETAPA DE TREINAMENTO	40
4.2.3	CLASSIFICAÇÃO NÃO SUPERVISIONADA	40
5.	MÉTODO PROPOSTO	45
5.1	OBTENÇÃO DOS DADOS	46
5.1.1	ESCOLHA DAS BANDAS DE INFORMAÇÃO DO SATÉLITE	46
5.1.2	DEFINIÇÃO DA ESCALA DE TRABALHO	46
5.1.3	DEFINIÇÃO DAS CLASSES TEMÁTICAS	47
5.2	PROCESSAMENTO DIGITAL	48
5.2.1	REGISTRO DA IMAGEM COM A CARTE BASE	48
5.2.2	MANIPULAÇÃO DO CONTRASTE	50
5.2.3	SEGMENTAÇÃO DA IMAGEM	52
5.2.4	CLASSIFICAÇÃO DA IMAGEM	54
5.2.5	PRECISÃO DA IMAGEM CLASSIFICADA	57
6	RESULTADOS EXPERIMENTAIS	59
6.1	ESCOLHA DAS BANDAS DE INFORMAÇÃO DO SATÉLITE	59
6.2	DEFINIÇÃO DA ESCALA DE TRABALHO	60
6.3	ESCOLHA DA ÁREA PILOTO	60
6.4	DEFINIÇÃO DAS CLASSES TEMÁTICAS	61
6.5	PROCESSAMENTO DIGITAL	63
6.4.1	LEITURA DA IMAGEM	63
6.4.2	REGISTRO DA IMAGEM COM A CARTA BASE	63
6.4.3	MANIPULAÇÃO DO CONTRASTE	65
6.4.4	SEGMENTAÇÃO DA IMAGEM	68
6.4.5	CLASSIFICAÇÃO DA IMAGEM	70
7	CLASSIFICAÇÃO PIXEL-A-PIXEL X CLASSIFICAÇÃO POR REGIÕES	73
7.1	CLASSIFICAÇÃO PIXEL-A-PIXEL	73
7.1.1	CLASSIFICADOR ISODTA	73

7.1.2 CLASSIFICAÇÃO SUPERVISIONADA.....	74
7.1.3 PRECISÃO DA IMAGEM CLASSIFICADA.....	77
7.2 TABULAÇÃO CRUZADA.....	79
8 EQUIPAMENTOS E SOFTWARES	80
9 DISCUSSÃO E CONCLUSÃO.....	81
ANEXO – DISTRIBUIÇÃO X^2	83
REFERÊNCIAS BIBLIOGRÁFICAS.....	84

LISTA DE TABELAS

TABELA 1: Comparação entre os sensores fotográficos e os de varredura.....	13
TABELA 2: Características do satélite Landsat.....	14
TABELA 3: Canais e principais aplicações do sensor TM.....	17
TABELA 4: Escalas máximas das abordagens, através da utilização dos sensores acoplados ao satélite Landsat.....	47
TABELA 5: Matriz de erro.....	58
TABELA 6: Erros associados aos pontos de controle, fornecidos durante o processo de .registro da imagem.....	64
TABELA 7: Dados relativos a média, desvio padrão e variância de cada banda.....	67
TABELA 8: Momentos das bandas após manipulação do contraste.....	68
TABELA 9: Vantagens e desvantagens da utilização da distância Mahalanobis.....	71
TABELA 10: Vantagens e desvantagens do ISODATA.....	74
TABELA 11: Vantagens e desvantagens da utilização da distância mínima.....	76
TABELA 12: Vantagens e desvantagens do Maxver.....	77
TABELA 13: Matriz de erros do método Maxver.....	78
TABELA 14: Matriz de erros da distância euclidiana.....	78
TABELA 15: Comparação entre os métodos Maxver e distância euclidiana.....	78
TABELA 16: Porcentagem de concordância entre o Maxver e o algoritmo por regiões.....	79

LISTA DE FIGURAS

FIGURA 1: Elementos básicos da fase de aquisição.....	08
FIGURA 2: Gráfico representativo do campo elétrico e magnético de uma onda.....	09
FIGURA 3: Espectro eletromagnético.....	10

FIGURA 4: Componentes do sistema sensor.....	11
FIGURA 5: Sistema de coordenadas de uma imagem digital.....	19
FIGURA 6: Histogramas de frequências.....	20
FIGURA 7: Fases do processamento de imagens.....	21
FIGURA 8: Aplicação de filtros.....	29
FIGURA 9: Filtros direcionais.....	32
FIGURA 10: Etapas da classificação supervisionada.....	36
FIGURA 11: Diagrama de dispersão.....	37
FIGURA 12: Método da menor distância.....	38
FIGURA 13: Método da máxima verossimilhança.....	39
FIGURA 14: Algoritmo ISODATA.....	42
FIGURA 15: Função de equalização da banda 5.....	51
FIGURA 16: Banda 5 equalizada.....	51
FIGURA 17: Relação de vizinhança de um pixel.....	53
FIGURA 18: Região do Município de Palotina.....	61
FIGURA 19: Pontos de controle utilizados no registro da imagem.....	64
FIGURA 20: Palotina, banda3.....	65
FIGURA 21: Histograma da banda 3.....	65
FIGURA 22: Palotina, banda 4.....	66
FIGURA 23: Histograma da banda 4.....	66
FIGURA 24: Palotina, banda 5.....	66
FIGURA 25: Histograma da banda 5.....	67
FIGURA 26: Segmentação com grau de similaridade 15 e área mínima de 40 pixels.....	69
FIGURA 27: Segmentação com grau de similaridade 20 e área mínima de 40 pixels.....	69
FIGURA 28: Segmentação com grau de similaridade 30 e área mínima de 40 pixels.....	69
FIGURA 29: Segmentação com grau de similaridade 35 e área mínima de 40 pixels.....	70
FIGURA 30: Imagem classificada utilizando o algoritmo ISOSEG.....	71
FIGURA 31: Imagem após classificação supervisionada.....	72
FIGURA 32: Imagem classificada utilizando o ISOSATA.....	74
FIGURA 33: Imagem classificada pelo método da menor distância.....	75
FIGURA 34: Mapeamento final.....	75

FIGURA 35: Imagem classificada pelo método maxver.....	76
FIGURA 36: Mapeamento final utilizando o método maxver.....	77

RESUMO

Este trabalho apresenta uma metodologia híbrida de classificação de imagens Landsat-TM. Este método difere das formas tradicionais de classificação no sentido que o algoritmo de agrupamento é aplicado a um conjunto de regiões obtidas através da técnica de crescimento de regiões. O procedimento metodológico de classificação baseia-se em dois processos distintos que, de certa forma, se complementam. No primeiro processo utilizado, de classificação não supervisionada, o algoritmo tenta aglomerar pixels dentro de uma mesma variação espectral. O segundo processo foi o de classificação supervisionada, o qual é caracterizado pela seleção de regiões que representam determinadas classes para serem usadas como áreas de treinamento. Resultados experimentais, usando imagens multiespectrais, são apresentados. São apresentados os resultados da comparação entre a classificação pixel-a-pixel e a classificação por regiões. Os resultados obtidos demonstram a viabilidade da metodologia apresentada.

ABSTRACT

A hybrid unsupervised/supervised classification method is described and applied to Landsat TM images. This method differs from the conventional classification in the sense that the clustering algorithm is applied to a set of regions, obtained from the segmented image. The methodological proceedings of classification are based on two distinct processes that complement each other. In the first process used, the unsupervised classification, the algorithm tries to unite pixels with the same spectral variance. The second process was the supervised classification that is characterized by regions selections of some classes to be used as training fields. Experimental results, using multiespectral images, are presented. A comparison between the pixel-per-pixel classification and the region classification, are presented. The results show the validity of the method presented.

1. INTRODUCAO

Conhecer e representar a superfície da Terra sempre foi uma preocupação das diversas civilizações do nosso planeta. O aumento da complexidade dos trabalhos de localização, mapeamento e monitoramento da superfície terrestre, visando a garantir a soberania sobre os limites territoriais, o conhecimento, utilização e preservação de recursos naturais, são os principais responsáveis pelos avanços das formas de captação e manipulação das informações da superfície terrestre.

O Brasil, com sua imensidão territorial, caracterizada por uma grande diversidade agroecológica, associada a uma ocupação das terras muito dinâmica, convive há décadas com uma ocupação e fluxos populacionais extremamente desorientados.

A necessidade de se conhecer, mapear e monitorar, tanto recursos naturais como as migrações internas da população, visando a uma ocupação mais controlada de seu território e a utilização de seus recursos de forma mais racional, tem incentivado a execução de projetos de levantamento e mapeamento da superfície terrestre (BOGNOLA et al, 1997).

O surgimento das imagens de satélite possibilitou, além da criação de um nível de percepção mais global, complementar as fotografias aéreas e os levantamentos de campo, com a obtenção de informações radiométricas digitais de grandes extensões da superfície terrestre.

Nas classificações computacionais tradicionais, um conjunto de amostras é utilizado para caracterizar cada classe temática a ser mapeada. Os *pixels* (elementos básicos constituintes da imagem, "*picture element*") são comparados um a um às amostras fornecidas, decidindo assim a qual classe temática eles pertencem. Desta forma, elas são conhecidas por classificação pixel a pixel (BOGNOLA et al, 1997).

A necessidade de se criar métodos digitais de classificação de imagens, reduzindo a subjetividade do intérprete humano e, ao mesmo tempo, considerando algumas características do meio, e não exclusivamente o valor espectral do pixel, levou ao desenvolvimento de novos aplicativos (BOGNOLA et al, 1997).

Vários métodos de segmentação de imagens foram criados, com o objetivo de fragmentar a imagem em regiões "homogêneas", sobre as quais é então processada a

classificação. Estes métodos de classificação e pós-segmentação, diferentemente dos anteriores, são conhecidos como classificação por regiões (INPE,1996).

Tradicionalmente, esses métodos têm sido divididos em duas outras grandes categorias: supervisionada e não supervisionada, de acordo com o procedimento empregado para obter áreas de treinamento.

Técnicas de classificação computacional têm sido relativamente pouco usadas, no Brasil. Tal fato deve-se a diversas razões, como os requisitos de capacidade de processamento e armazenamento de grandes volumes de dados, a necessidade de treinamento de equipes e o desempenho geral dessas técnicas.

Alguns trabalhos foram desenvolvidos para testar o desempenho do método de segmentação na região amazônica (ALVES et al., 1995; ALMEIDA et al, 1995). Embora os resultados obtidos tenham sido considerados satisfatórios, estes trabalhos só testaram o desempenho deste método em regiões pouco heterogêneas, onde predominam grandes propriedades e reduzida variedade de formas de ocupação do solo, não refletindo portanto a enorme quantidade de situações de uso e ocupação existente no país.

Qual seria o custo, o desempenho e um método de mapeamento a ser utilizado em áreas extremamente fragmentadas e com grande diversidade de agroecossistemas, e qual o comportamento da segmentação, em trabalhos envolvendo imagens do satélite Landsat-TM, em escalas maiores que 1:100.000, tradicionalmente considerada como limite para este produto em função da sua resolução espacial. Estas são questões a serem solucionadas.

A necessidade e urgência de se conhecer e monitorar o uso das terras e dos recursos naturais, em toda extensão do território nacional, faz com que ferramentas de classificação e segmentação de imagens sejam de grande interesse, embora ainda necessitem de pesquisas, visando ao estabelecimento de rotinas e procedimentos de execução, para terem sua eficiência testada e comprovada.

1.1 JUSTIFICATIVA

Em função da dinâmica de desenvolvimento de equipamentos e programas de computador, envolvidos no processo de aquisição, armazenamento, manipulação e

expressão de dados orbitais, muitos aplicativos à disposição no mercado ainda não foram suficientemente testados e validados.

A correta associação de recursos tecnológicos disponíveis e dos objetivos de cada trabalho depende fundamentalmente dos conhecimentos relativos ao comportamento de cada um dos produtos disponíveis no mercado, quando confrontados a diferentes realidades de campo. A necessidade de reduzir o tempo e recursos gastos nos processos de identificação, delimitação e mapeamento do uso das terras, aponta para os processos automáticos de manipulação e tratamento de imagens de satélite. Como exemplos, podem ser citados o Sistema de Processamento de Imagens Georeferenciadas (SPRING), os softwares Multispec e ERDAS.

Diferentes situações do terreno, padrões de ocupação humana e escalas de trabalho, podem exigir combinações distintas destas múltiplas ferramentas. O comportamento do tratamento de imagens Landsat-TM, na escala 1:50.000, com os algoritmos de classificação e segmentação, ainda não foi suficientemente testado em áreas heterogêneas, onde diferentes modalidades de uso e situações de terreno definem uma paisagem bastante recortada.

1.2 OBJETIVO

O principal objetivo deste trabalho é estabelecer uma metodologia híbrida de segmentação e classificação de imagens Landsat-TM de áreas heterogêneas de cobertura da terra, através da segmentação inicial da imagem em regiões e, posteriormente, a utilização de um algoritmo de classificação não supervisionado por regiões, seguido de um algoritmo supervisionado para se realizar a classificação.

Assim sendo, seus objetivos específicos são os seguintes:

- Testar a eficiência e as limitações dos algoritmos de segmentação e classificação aplicados a imagens de satélites para a realização deste mapeamento;
- Combinar procedimentos metodológicos de segmentação de regiões, classificação não supervisionada e supervisionada para a concepção do mapa temático de cobertura da terra;

- Verificar a acurácia dos mapas de classificação e pós-classificação com finalidade de formação de uma base dados geográfica de uma região.
- Comparar o desempenho dos algoritmos de classificação pixel-a-pixel e o algoritmo de classificação por regiões.

1.3 CONTRIBUIÇÕES

As principais contribuições do método desenvolvido e da análise realizada são :

- a. Estabelecimento de um procedimento metodológico híbrido eficiente para a realização de um mapeamento de qualquer área utilizando técnicas de segmentação e classificação de imagens por regiões, utilizando uma imagem na escala de 1:50.000 e, aproveitando desta forma, as vantagens apresentadas pela combinação de ambas as técnicas de classificação (supervisionada e não supervisionada);
- b. Permitir ao futuro usuário uma maior flexibilidade na escolha de uma técnica de classificação que seja mais adequada para solucionar os seus problemas particulares (classificação pixel-a-pixel ou classificação por regiões);
- c. Permitir a verificação do mapeamento realizado;
- d. Permitir uma análise comparativa entre os métodos de classificação pixel-a-pixel e a classificação por regiões.

1.4 COMPOSIÇÃO

Este trabalho é composto por 8 (oito) capítulos cujas descrições sumárias são apresentadas a seguir:

CAPÍTULO 1 - INTRODUÇÃO : Apresenta o problema a ser solucionado, os objetivos do trabalho, e suas principais contribuições.

CAPÍTULO 2 – FUNDAMENTOS DE SENSORIAMENTO REMOTO: Apresenta os conceitos básicos sobre sensoriamento remoto.

CAPÍTULO 3 – FUNDAMENTOS DE PROCESSAMENTO DIGITAL DE IMAGENS: Apresenta os conceitos básicos sobre processamento digital de imagens. Aborda a definição de diversos conceitos relativos a imagens orbitais, bem como as técnicas utilizadas na sua manipulação.

CAPÍTULO 4 - SEGMENTAÇÃO E CLASSIFICAÇÃO : Apresenta os conceitos básicos relativos a segmentação e classificação de imagens. Ainda nesse capítulo, são descritas as diversas técnicas de classificação de imagens que foram utilizadas.

CAPÍTULO 5 – MÉTODO : Apresenta a metodologia proposta para solucionar o problema.

CAPÍTULO 6 – RESULTADOS EXPERIMENTAIS : Neste capítulo são concentrados os resultados experimentais obtidos demonstrando, dessa forma, a validade da metodologia proposta, bem como o excelente desempenho da técnica de classificação ao se utilizar uma etapa anterior de segmentação em regiões.

CAPÍTULO 7 – CLASSIFICAÇÃO PIXEL-A-PIXEL X CLASSIFICAÇÃO POR REGIÕES: É feita uma comparação entre as técnicas de classificação por agrupamento e de classificação por regiões.

CAPÍTULO 8 – EQUIPAMENTOS E SOFTWARES: É apresentado o equipamento e os programas que foram utilizados.

CAPÍTULO 9 – DISCUSSÃO E CONCLUSÃO: Neste capítulo, é feita uma pequena discussão sobre o trabalho, apresenta as conclusões e indica os trabalhos futuros.

2. FUNDAMENTOS DE SENSORIAMENTO REMOTO

A origem do sensoriamento remoto está ligada às experiências de Newton (1822), o qual constatou que um raio luminoso (luz branca), ao atravessar um prisma desdobrava-se num feixe colorido - um espectro de cores. Desde então os cientistas foram ampliando os seus estudos a respeito de tão fascinante matéria. Verificaram que a luz branca era uma síntese de diferentes tipos de luz, uma espécie de vibração composta, basicamente, de muitas vibrações diferentes. Prosseguindo, descobriram ainda que cada cor decomposta no espectro correspondia a uma temperatura diferente, e que a luz vermelha incidindo sobre um corpo, aquecia-o mais do que a violeta.

Além do vermelho visível, existem radiações invisíveis para os olhos, que passaram a ser denominadas de ondas, raios ou ainda radiações infravermelhas. Sempre avançando em seus experimentos os cientistas conseguiram provar que a onda de luz era uma onda eletromagnética, mostrando que a luz visível é apenas uma das muitas diferentes espécies de ondas eletromagnéticas.

Alguns autores colocam a origem do Sensoriamento Remoto ligada ao desenvolvimento de sensores fotográficos, quando as fotografias aéreas eram tiradas por balões (INPE, 1996). Fica evidente que o Sensoriamento Remoto é fruto de um esforço multidisciplinar que envolveu e envolve avanços na física, na físico-química, na química, nas biociências e geociências, na computação, na mecânica, etc...

2.1 DEFINIÇÕES

O sensoriamento remoto pode ser definido segundo BARRETT & CURTIS (1992), como a ciência de observação à distância. Isto contrasta com o sensoriamento *in situ*, onde objetos são medidos e observados no local onde ocorrem. Em outras palavras, o sensoriamento remoto está relacionado à ausência de contato físico entre o sensor e o alvo.

Sensores : são equipamentos capazes de coletar energia proveniente do objeto, convertê-la em sinal passível de ser registrado e apresentá-lo em forma adequada à extração de informações.

Energia : na grande maioria das vezes refere-se a energia eletromagnética ou radiação eletromagnética .

Segundo INPE (1996), um conceito mais específico de sensoriamento remoto pode ser: "É o conjunto das atividades relacionadas com a aquisição e a análise de dados de sensores remotos", onde:

Sensores remotos: sistemas fotográficos ou óptico-eletrônicos capazes de detectar e registrar, sob a forma de imagens ou não, o fluxo de energia radiante refletido ou emitido por objetos distantes.

Um fluxo de radiação eletromagnética ao se propagar pelo espaço pode interagir com superfícies ou objetos, sendo por estes refletido, absorvido e mesmo transmitido. As variações que essas interações produzem no fluxo considerado, dependem fortemente das propriedades físico-químicas dos elementos na superfície.

Tudo na natureza está em constante vibração, emitindo ou modificando ondas eletromagnéticas (energia) e apresentando perturbações dos campos magnéticos e gravimétricos da Terra. Todos os instrumentos que captam e transformam essa energia poderiam ser classificados como sensores: rádio, televisão, máquina fotográfica, etc.

Durante a fase de aquisição de dados pelos sensores, pode-se distinguir os seguintes elementos básicos: energia radiante, fonte de radiação, objeto (alvo), trajetória e sensor (sistema de imagens óptico e detector). A Figura 1 apresenta estes elementos e exemplifica os vários caminhos que a radiação eletromagnética pode tomar antes de atingir o sistema sensor.

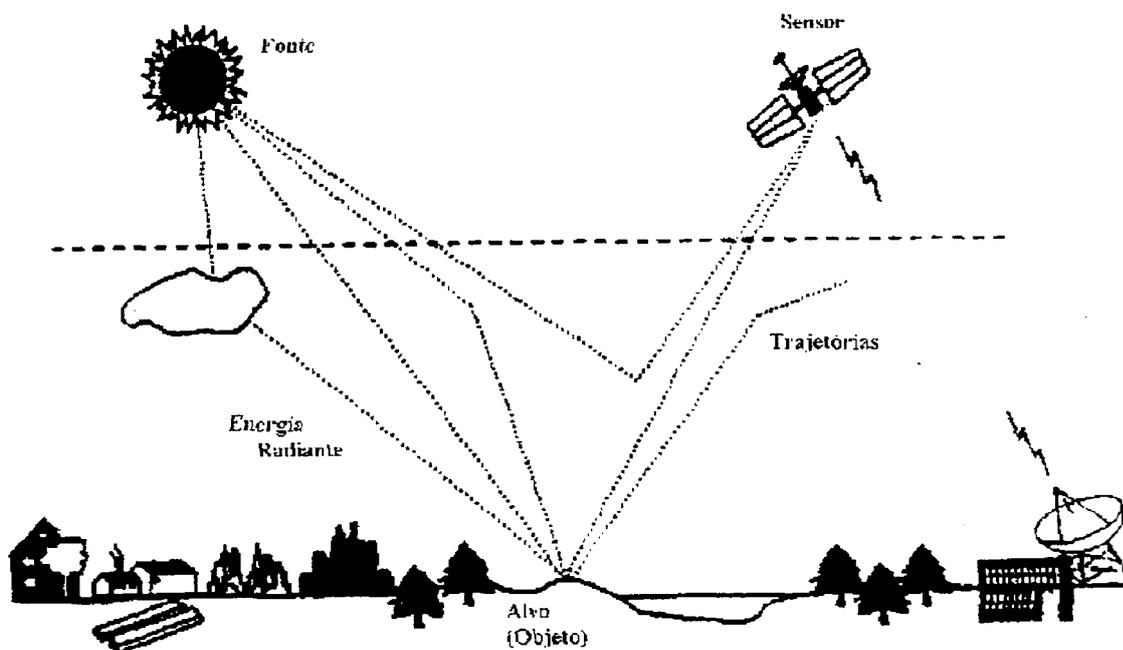


Figura 1: Elementos Básicos da Fase de Aquisição

Fonte: INPE(1996)

2.2 ESPECTRO ELETROMAGNÉTICO

A radiação (ondas) eletromagnética é constituída por diversas características físicas (intensidade, comprimento de onda, frequência, energia, polarização, etc.). Entretanto, independente dessas características, todas as ondas eletromagnéticas são essencialmente idênticas, apresentando uma independência com relação à existência ou não de um meio de propagação (propriedade importante deste processo de transferência de energia). Esta independência é fácil de entender pela Figura 2, o campo elétrico e o campo magnético são perpendiculares entre si e ambos oscilam perpendicularmente à direção de propagação da onda, assim o campo elétrico gera um campo magnético e o campo magnético gera um campo elétrico.

Onde: E = Campo elétrico
M = Campo magnético

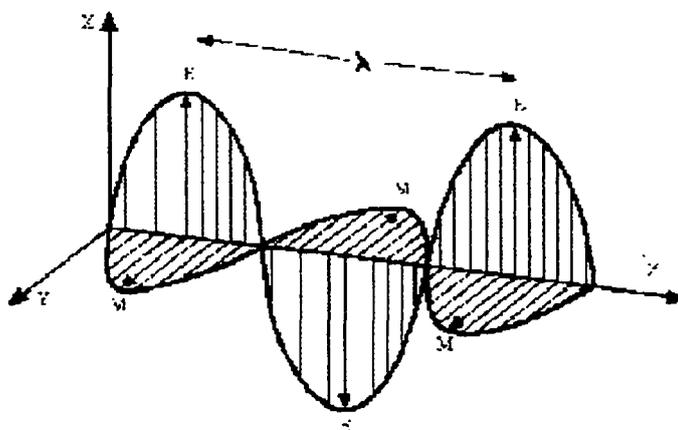


Figura 2: Gráfico representativo do campo elétrico e magnético de uma onda.

Fonte: INPE(1996)

A velocidade de propagação da onda eletromagnética no vácuo é a velocidade da luz (3×10^8 m/s). O número de ondas que passa por um ponto do espaço num determinado tempo define a frequência (f) da radiação. A frequência de onda é diretamente proporcional à velocidade de propagação da radiação. Quanto maior a velocidade de propagação da onda, maior o número de ondas que passarão por um ponto num dado tempo (t) e maior será sua frequência. A velocidade de propagação (v) num dado meio é constante.

A onda eletromagnética pode também ser caracterizada pelo comprimento de onda λ (lambda) que pode ser expresso pela equação:

$$\lambda = v / f \quad (1)$$

A faixa de comprimentos de onda ou frequências em que se pode encontrar a radiação eletromagnética é ilimitada. Com a tecnologia atualmente disponível, pode-se gerar ou detectar a radiação eletromagnética numa extensa faixa de frequência, que se estende de 1 a 10^{24} Hz, ou comprimentos de onda na faixa de 108 metros a 0.01Å.

Este espectro é subdividido em faixas, representando regiões que possuem características peculiares em termos dos processos físicos, geradores de energia em cada

faixa, ou dos mecanismos físicos de detecção desta energia. Dependendo da região do espectro, trabalha-se com energia (elétron-volts), comprimentos de onda (micrômetro), ou frequência (hertz). Por exemplo: na região dos raios gama e cósmicos - usa-se energia; na região entre U.V. e I.V. - usa-se comprimento de onda; na região microondas e radio - usa-se frequência. As principais faixas do espectro eletromagnético estão representadas na Figura 3.

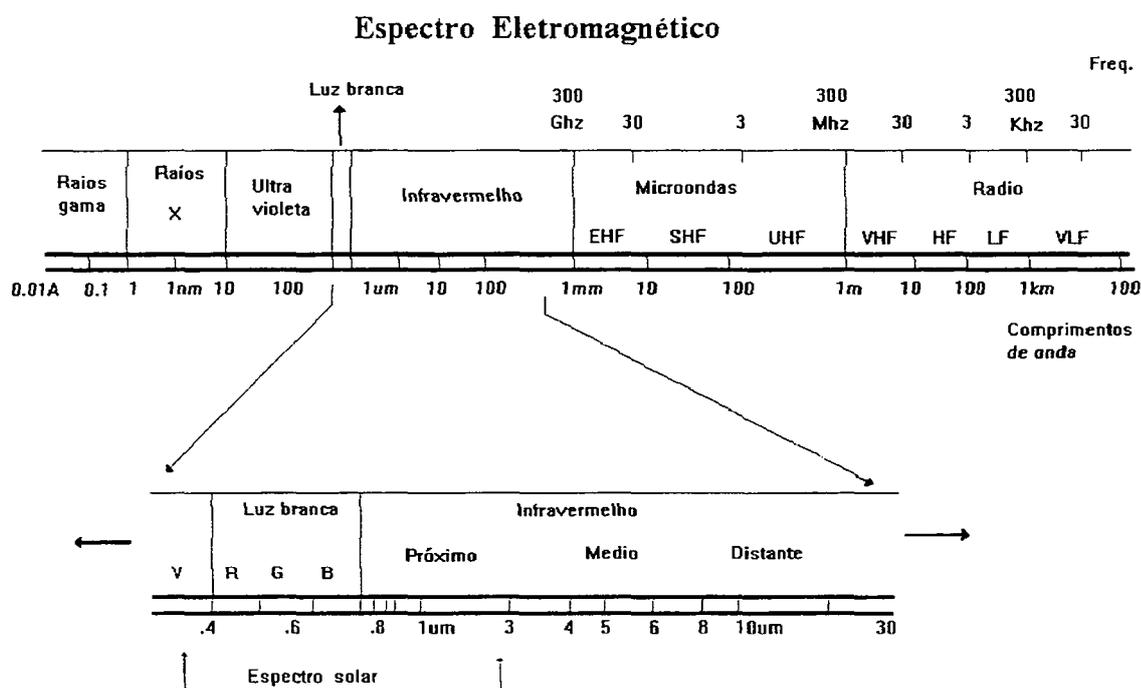


Figura 3: Espectro eletromagnético

Fonte: INPE(1996)

2.3 SISTEMAS SENSORES

Todos os materiais e fenômenos naturais absorvem, transmitem, refletem e emitem seletivamente radiação eletromagnética. Com o desenvolvimento atual é possível medir

com razoável precisão a distância e as propriedades espectrais daqueles materiais e fenômenos.

Qualquer sistema sensor apresenta componentes necessários para captar a radiação eletromagnética, representados na Figura 4.

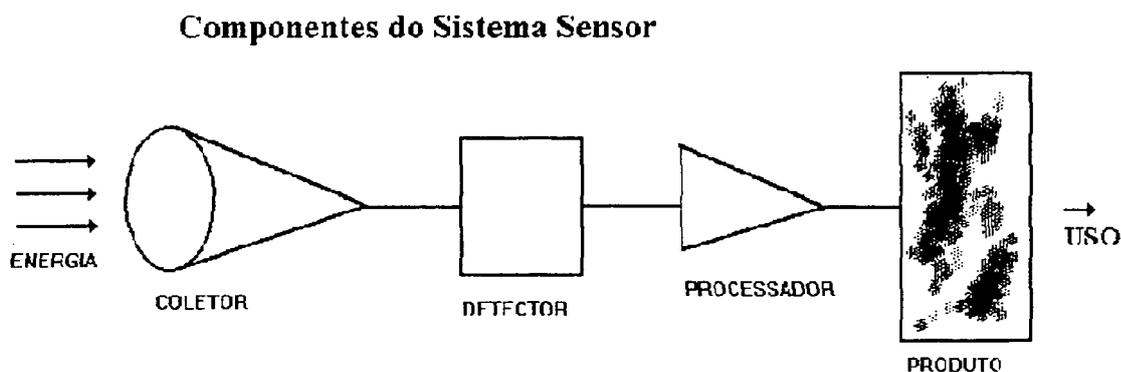


Figura 4: Componentes do sistema sensor

Fonte : INPE(1996)

onde:

coletor = recebe a energia através de uma lente, espelho, antenas, etc.

detector = capta a energia coletada de uma determinada faixa do espectro;

processador = o sinal registrado é submetido a um processamento (revelador, amplificação, etc.) através do qual se obtém o produto;

produto = contém a informação necessária ao usuário.

2.3.1 TIPOS DE SENSORES

Os sensores podem ser classificados em função da fonte de energia ou em função do tipo de produto que ele produz.

Em função da fonte de energia:

- A) **PASSIVOS** : não possui uma fonte própria de radiação. Ele mede radiação solar refletida ou radiação emitida pelos alvos. ex: sistemas fotográficos.
- B) **ATIVOS** : possui sua própria fonte de radiação eletromagnética, trabalhando em faixas restritas do espectro. ex: radares.

Em função do tipo de produto:

- A) **Não-imageadores**: não fornecem uma imagem da superfície sensoriada. ex: radiômetros (saída em dígitos ou gráficos) e espectrorradiômetros (assinatura espectral).

São essenciais para a aquisição de informações minuciosas sobre o comportamento espectral dos objetos da superfície terrestre.

- B) **Imageadores**: obtém-se como resultado uma imagem da superfície observada. Fornecem informações sobre a variação espacial da resposta espectral da superfície observada.

B.1 - **sistema de quadro** ("framing systems"): adquirem a imagem da cena em sua totalidade num mesmo instante. (ex: RBV)

B.2 - **sistema de varredura** ("scanning systems") ex: TM - MSS - SPOT.

B.3 - **sistema fotográfico**

Os sistemas de imagens por varredura vieram a cobrir a lacuna deixada pelos problemas inerentes ao uso do até então mais difundido dispositivo óptico sensor - a câmara fotográfica. Esta, apesar de apresentar condições mais fáceis de operação e custos, apresenta uma limitação em captar a resposta espectral, devido aos filmes que cobrem somente o espectro do ultravioleta próximo ao infravermelho distante. Também este tipo de sensor limita-se as horas de sobrevôo e devido a fenômenos atmosféricos não permitem freqüentemente observar o solo a grandes altitudes.

Como os dados destes sensores não fotográficos são coletados sob forma de sinal elétrico, eles podem ser facilmente transmitidos para estações distantes, onde um processamento eletrônico fará sua análise discriminatória.

A Tabela 1 apresenta uma análise comparativa dos sensores fotográficos e imageadores por varredura.

	Imageamento por sensores fotográficos.	Imageamento por sensores de varredura.
Resolução geométrica	alta *	média
Resolução espectral	média	alta *
Repetitividade	baixa	alta *
Visão sinóptica	baixa	alta *
Base de dados	analógica	digital *

* maior vantagem sobre a outra

Tabela 1: Comparação entre os sensores fotográficos e os de varredura.

2.4 NÍVEL DE AQUISIÇÃO DE DADOS

Ao passar de um nível para outro, modificam-se as dimensões da área a ser imageada, consequentemente obtemos imagens com diferentes resoluções, o que exigirá estudos para metodologias de análise diferentes.

A) **Nível de laboratório** (0 a 20 m) - trabalha-se com porções reduzidas da matéria e estuda-se seu comportamento espectral quase que sem interferência de fatores ambientais. A área passível de ser analisada por estes métodos é reduzida.

B) **Nível de Aeronave** (300 a 3.000 m) - a energia registrada pelo sensor não se refere a um determinado objeto, mas a um arranjo de objetos da cena. Alguns objetos podem ser individualmente detectados por sua configuração.

C) **Nível Orbital** (400 a 920 m) - em cada elemento de resolução no terreno, a energia registrada é a integração da resposta de diferentes objetos.

2.4.1 SISTEMAS ORBITAIS

Será abordado somente o sistema Landsat. Este sistema, no atual estado-da-arte, representa a maior fonte de dados de sensoriamento remoto e com maior potencial de continuidade ao longo do tempo. Além disso temos disponível no país, através do INPE - Instituto Nacional de Pesquisas Espaciais, toda uma infra-estrutura para recepção, processamento e distribuição das imagens enviadas por estes sistemas (<http://www.inpe.br>).

Antes da abordagem do sistema Landsat, serão apresentadas as características orbitais, as quais são baseadas nas seguintes premissas:

- a órbita deveria ser circular, para garantir que as imagens tomadas em diferentes regiões da Terra tivessem a mesma resolução e escala;
- a órbita deveria permitir o imageamento cíclico da superfície, para garantir a observação periódica e repetitiva dos mesmos lugares;
- a órbita deveria ser síncrona com o Sol (heliosíncrono), para que as condições de iluminação da superfície terrestre se mantivessem constantes;
- o horário da passagem do satélite deveria atender às solicitações de diferentes áreas de aplicação (geologia, geomorfologia, agricultura, etc.).

A Tabela 2 apresenta as características do Landsat.

	Landsat 4 e 5
Órbita	circular 98,2 graus heliosíncrono
Período	99 minutos
Altitude	705 km
Cruzamento	9:45 horas
Ciclo	16 dias
Órbita adj.	172 km
Órbita suc.	2.750 km

Tabela 2: Características do satélite Landsat.

O sistema Landsat compõe-se até o momento de 5 satélites, que foram desenvolvidos pela NASA (*National Aeronautics and Space Administration*), recebendo inicialmente o nome de *Earth Resources Technology Satellite-1* (ERST-1), que passou a ser chamado de Landsat em janeiro de 1975.

Os satélites Landsat 1 e 2 carregaram a bordo dois sistemas sensores com a mesma resolução espacial, mas com diferentes concepções de imageamento: o sistema RBV (*Return Beam Vidicom*), com imageamento instantâneo de toda a cena e o sistema MSS (*Multispectral Scanner*), com imageamento do terreno por varredura de linhas (*line-scanner*).

O imageador RBV é um sistema semelhante a uma câmera de televisão e permite o registro instantâneo de uma certa área do terreno. A energia proveniente de toda a cena impressiona a superfície fotossensível do tubo da câmera e, durante certo tempo, a entrada de energia é interrompida por um obturador, para que a imagem do terreno seja varrida por um feixe de elétrons. O sinal de vídeo pode então ser transmitido telemetricamente.

O imageador MSS é um sistema sensor que permite o imageamento de linhas do terreno numa faixa de 185 km, perpendicularmente à órbita do satélite. A varredura do terreno é realizada com auxílio de um espelho que oscila perpendicularmente ao deslocamento do satélite. Durante a oscilação do espelho, a imagem do terreno, ao longo da faixa, é focalizada sobre uma matriz de detectores. A dimensão de cada detector que compõe a matriz de detectores, é responsável pelo seu campo de visão instantâneo (área observada por cada detector na superfície da Terra). A energia registrada por cada detector é transformada em um sinal elétrico e este transmitido para as estações em terra.

A cada oscilação do espelho, o satélite desloca-se ao longo da órbita, para proporcionar o imageamento contínuo do terreno. Entretanto, o movimento de rotação da Terra provoca um pequeno deslocamento do ponto inicial da varredura para oeste a cada oscilação do espelho, ou seja, a cada seis linhas imageadas. Se considerarmos o deslocamento de 185 km ao longo da órbita do satélite, há um deslocamento de 12,5 cm entre a primeira e a última coluna de *pixels*.

Ambos os sistemas propunham-se à aquisição de dados multiespectrais, mas o desempenho do sistema MSS, em termos de fidelidade radiométrica, fez com que o 3º satélite da série tivesse seu sistema RBV modificado, de modo a prover dados com melhor

resolução espacial em uma única faixa do espectro. Por outro lado, foi acrescentada uma faixa espectral ao sistema MSS, para operar na região do infravermelho termal.

A partir do Landsat 4 e 5, ao invés do sensor RBV, a carga útil do satélite passou a contar com o sensor TM (*Thematic Mapper*), operando em 7 faixas espectrais. Esse sensor conceitualmente é semelhante ao MSS pois é um sistema de varredura de linhas (*line-scanner*). Incorpora, entretanto, uma série de aperfeiçoamentos, quer nos seus componentes ópticos, quer nos seus componentes eletrônicos.

O imageador TM é um sistema avançado de varredura multiespectral concebido para proporcionar: resolução espacial mais fina, melhor discriminação espectral entre objetos da superfície terrestre, maior fidelidade geométrica e melhor precisão radiométrica em relação ao sensor MSS.

A energia proveniente da cena atinge o espelho de varredura que oscila perpendicularmente à direção de deslocamento do satélite em sentido leste-oeste e oeste-leste. O sinal atravessa um telescópio e um conjunto de espelhos, cuja função principal é corrigir o sinal coletado pelo espelho de varredura. Dessa maneira, o sinal detectado em cada matriz de detetores de cada canal é transferido para um amplificador e convertido em sinal digital através de um sistema A/D (analógico/digital). A saída de dados é, então transmitida via telemetria.

2.5 RESOLUÇÃO E BANDAS

Resolução é uma medida da habilidade que um sistema sensor possui de distinguir entre respostas que são semelhantes espectralmente ou próximas espacialmente. A resolução pode ser classificada em espacial, espectral e radiométrica.

Características importantes de imagens de satélite são: o número de bandas do espectro eletromagnético imageadas (resolução espectral) e a área da superfície terrestre observada instantaneamente por cada sensor (resolução espacial).

A resolução espacial mede a menor separação angular ou linear entre dois objetos. Por exemplo, uma resolução de 20 metros implica que objetos distanciados entre si a menos que 20 metros, em geral, não serão discriminados pelo sistema.

A resolução espectral é uma medida da largura das faixas espectrais do sistema sensor. Por exemplo, um sensor que opera na faixa de 0.4 a 0.45 μm tem uma resolução espectral menor do que o sensor que opera na faixa de 0.4 a 0.5 μm .

A resolução radiométrica está associada à sensibilidade do sistema sensor em distinguir dois níveis de intensidade do sinal de retorno. Por exemplo, uma resolução de 10 bits (1024 níveis digitais) é melhor que uma de 8 bits.

As diferentes bandas espectrais dos sensores têm aplicações distintas em estudos de sensoriamento remoto. Para orientar a seleção das melhores bandas a serem utilizadas, apresenta-se a Tabela 3.

Satélite Landsat - Sensor TM		
Canal	Faixa Espectral (μm)	Principais aplicações
1	0.45 - 0.52	Mapeamento de águas costeiras Diferenciação entre solo e vegetação Diferenciação entre vegetação coníferas e decídua
2	0.52 - 0.60	Reflectância de vegetação verde sadia
3	0.63 - 0.69	Absorção de clorofila Diferenciação de espécies vegetais
4	0.76 - 0.90	Levantamento de biomassa Delineamento de corpos d'água
5	1.55 - 1.75	Medidas de umidade da vegetação Diferenciação entre nuvens e neve
6	10.4 - 12.5	Mapeamento de estresse térmico em plantas Outros mapeamentos térmicos
7	2.08 - 2.35	Mapeamento hidrotermal

Tabela 3: Canais e principais aplicações do sensor TM.

Fonte: INPE(1996)

3. FUNDAMENTOS DE PROCESSAMENTO DIGITAL DE IMAGENS

A análise digital de dados, mais especificamente, imagens digitais de sensoriamento remoto orbital, possibilitou, nos últimos anos, um grande desenvolvimento das técnicas voltadas para a análise de dados multidimensionais, adquiridos por diversos tipos de sensores. Estas técnicas têm recebido o nome de **processamento digital de imagens**.

De acordo com JANSEN(1986), processamento digital de imagens é o conjunto de procedimentos relativos à manipulação e análise de imagens por meio do computador.

GONZALEZ & WINTZ (1977) descrevem o objetivo do processamento digital de imagem como sendo um conjunto de procedimentos que melhoram a informação, representada em forma de pixels, para a interpretação do olho humano, bem como para o reconhecimento dos dados de uma cena pelo computador.

Recentemente, o processamento digital de imagens de sensoriamento remoto passou a estar ligado ao reconhecimento de feições e padrões registrados na imagem, através de programas computacionais, geralmente baseados em análise estatística (RICHARDS, 1993).

A área de processamento digital de imagens tem atraído grande interesse nas últimas duas décadas. A evolução da tecnologia na área da computação, bem como o desenvolvimento de novos algoritmos para lidar com sinais bidimensionais, está permitindo uma gama de aplicações cada vez maior.

A utilização de imagens multiespectrais registradas por satélites, tais como, **Landsat, SPOT, ERS1, NOAA** ou similares, tem-se mostrado como uma valiosa técnica para a extração dos dados destinados às várias aplicações de pesquisa de recursos naturais. A obtenção das informações espectrais registradas pelos sistemas nas diferentes partes do espectro eletromagnético, visando à identificação e discriminação dos alvos de interesse, depende principalmente da qualidade da representação dos dados contidos nas imagens.

As técnicas de processamento digital de imagens (PDI), além de permitirem analisar uma cena nas várias regiões do espectro eletromagnético, também possibilitam a integração de vários tipos de dados, devidamente registrados.

3.1 IMAGEM DIGITAL

Em sensoriamento remoto orbital, um grande número de dados é usado para representar uma imagem. Tais dados podem ser manipulados no formato digital, visando a extração de informações destas imagens. Cada ponto imageado pelos sensores corresponde a uma área mínima denominada "pixel" (*"picture element"*), que deve estar geograficamente identificado, e para o qual são registrados valores digitais relacionados a intensidade de energia refletida em faixas (bandas) bem definidas do espectro eletromagnético.

Uma imagem está relacionada a uma função bidimensional, da intensidade de luz refletida ou emitida por uma cena, na forma $I(x,y)$, onde x e y são coordenadas espaciais. (GONZALEZ, 1977; SABINS, 1987). Pode-se representar uma imagem por uma matriz de x linhas e y colunas que definem as coordenadas espaciais do pixel. Desta forma, uma imagem digital é uma função $I(x,y)$, definida por uma grade regular de m linhas e n colunas, representada por:

$I(i,j)$, onde:

$$0 \leq i \leq m-1$$

$$0 \leq j \leq n-1$$

para I variando de $[0, k-1]$;

onde, k = níveis de cinza .

A Figura 5, ilustra o sistema de coordenadas usualmente utilizado para representar uma imagem digital.

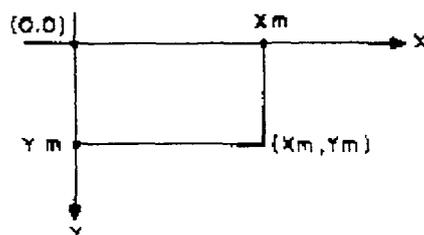


Figura 5: Sistema de coordenadas de uma imagem digital.

No caso das imagens multiespectrais, a representação digital é mais complexa, porque para cada coordenada (x,y) haverá um conjunto de valores de nível de cinza. Representa-se então cada "pixel" por um vetor, com tantas dimensões quantas forem as bandas espectrais. **Banda espectral** é o intervalo entre dois comprimentos de onda, no espectro eletromagnético.

No caso da imagem Landsat TM de uma cena inteira (185 km X 185 km), uma única banda possui: $m = 6117$, $n = 6167$ para $k = 256$ (NASA, 1988; CURRAN, 1995).

A variação de tons de cinza de uma imagem pode ser representada por histogramas de frequência, que é a maneira mais comum de se observar a distribuição dos níveis de cinza de uma imagem (Figura 6). O histograma permite obter informações sobre quantos pixels na imagem possuem determinado valor de cinza (que numa imagem de 8 bits varia de 0 a 255). Os dados discretos representados nos histogramas de frequências são de fundamental importância no que concerne ao aumento de contraste e realce de uma imagem (RICHARDS, 1994).

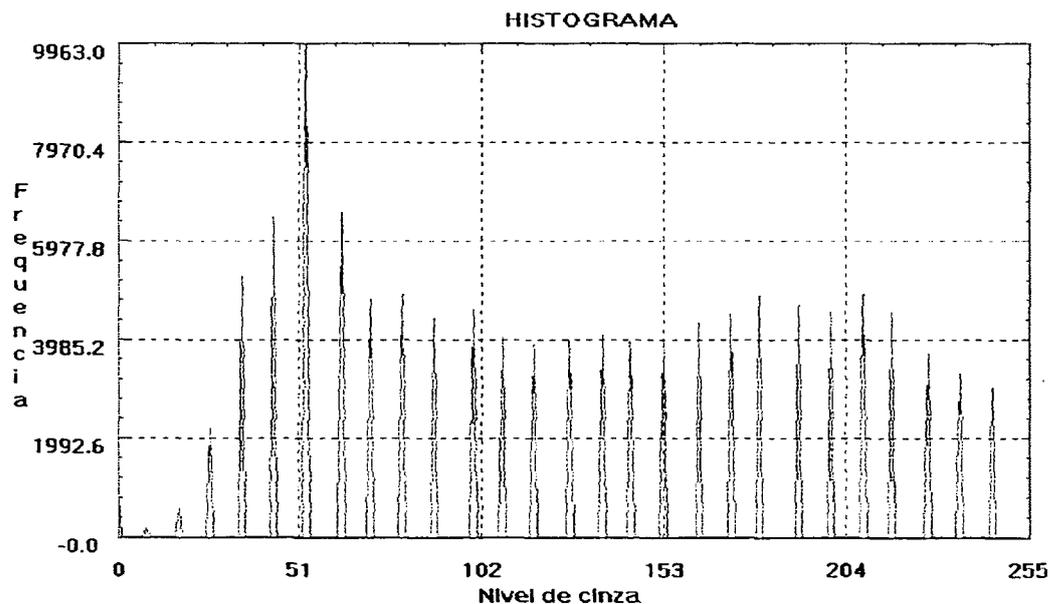


Figura 6 : Histograma de frequência

3.2 FASES DO PROCESSAMENTO DE IMAGENS

O processamento de uma imagem pode ser dividido em vários passos, como demonstrado na Figura 7. O primeiro deles é a aquisição da imagem, onde é necessário um sensor e um digitalizador do sinal produzido pelo sensor. A natureza do sensor e a imagem produzida serão determinados pelo tipo de aplicação.

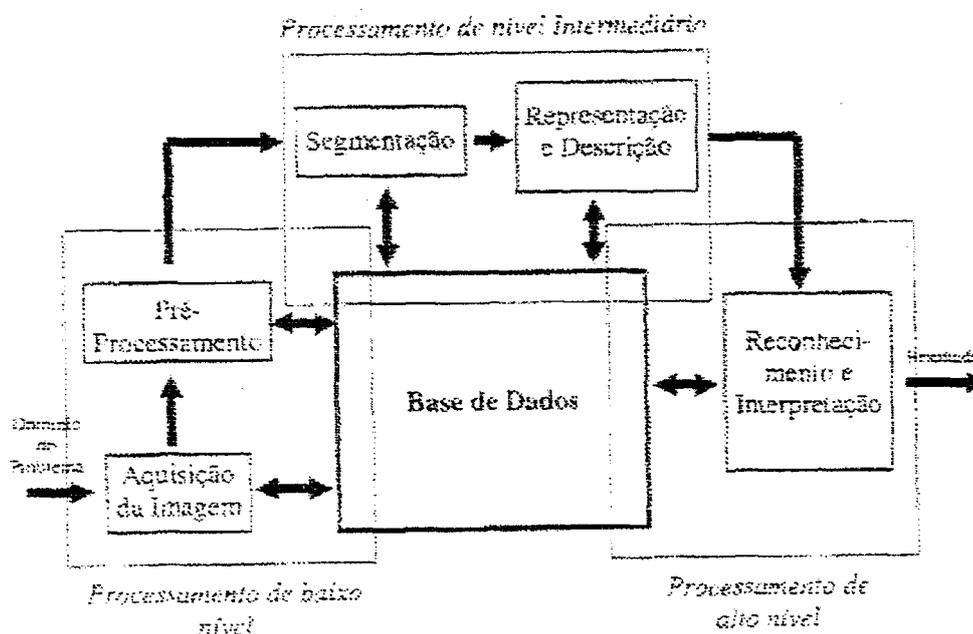


Figura 7: Fases do processamento de imagens.

Fonte: Gonzalez & Woods, 1993

Após a obtenção da imagem digital, o próximo passo diz respeito ao pré-processamento da imagem. A função principal do pré-processamento é melhorar a imagem de maneira a aumentar as chances de sucesso nos outros processos. O pré-processamento diz respeito às técnicas para aumento do contraste, remoção de ruídos e isolamento de regiões.

O próximo estágio se refere à segmentação. Ela particiona uma imagem de entrada em suas partes constituintes ou objetos. A segmentação é uma das tarefas mais difíceis no

processamento digital de imagens. O resultado do estágio de segmentação é um conjunto de pixels que constituem o contorno de uma região ou todos os pontos dentro de uma região. Em ambos os casos, é necessário converter os dados para uma forma aceitável para o seu processamento.

O estágio da representação é somente uma parte de como transformar o conjunto de dados em uma forma apropriada para o processamento. A descrição, também chamada de seleção de características, se refere à extração de características que *irão resultar em um conjunto de informações de interesse ou detalhes que serão necessárias para a diferenciação de uma classe de objetos de outra.*

O último estágio envolve o reconhecimento e interpretação. Reconhecimento é o processo que associa uma etiqueta, ou rótulo, para um objeto baseado na informação fornecida. Interpretação se refere à associação do significado a um conjunto de objetos conhecidos.

O conhecimento sobre o domínio de um problema está codificado dentro do sistema de processamento de dados na forma de base de conhecimentos, ou base de dados. Estes dados podem ser tão simples como detalhes de uma região em uma imagem onde se sabe a localização da informação de interesse. Os dados também podem ser complexos como uma base de dados de imagens contendo imagens de satélites de alta resolução de uma região. A base de dados também controla a interação entre os estágios ou módulos anteriormente citados.

As técnicas de PDI são realizadas com os **níveis de cinza (NC)** atribuídos aos pixels de uma imagem. Dependendo da técnica envolvida, o usuário trabalhará com uma única imagem (banda) ou com várias imagens. Neste caso, serão usadas técnicas conhecidas como multiespectrais, por tratarem de várias imagens da mesma cena em regiões diferentes do espectro eletromagnético. Os dados obtidos por satélites passam pelas seguintes fases:

- Pré-processamento
 1. Retificação da imagem
 2. Melhoramento da imagem
- Segmentação
- Classificação

3.3 RETIFICAÇÃO DA IMAGEM

Este processo pode ser considerado como uma operação de pré-processamento, porque ele normalmente precede posteriores análises e manipulações da imagem ou dados para extrair informações específicas.

Esta operação tem por objetivo corrigir distorções e/ou degradações da imagem com a finalidade de criar uma melhor representação possível da cena original. Envolve a correção de distorções geométricas, correções radiométricas e eliminação do ruído presente nos dados.

3.3.1 CORREÇÕES GEOMÉTRICAS

Imagens digitais, usualmente, contêm distorções geométricas tão significativas que não podem ser usadas em mapas. As fontes destas distorções podem ser desde variações na altitude e velocidade da plataforma, até fatores como curvatura da terra, refração atmosférica, etc. Segundo LILLESAND(1994) o objetivo da correção geométrica é compensar as distorções produzidas por estes fatores de modo que a imagem corrigida venha a possuir a integridade geométrica de um mapa.

Após se efetuar a correspondência entre as coordenadas da imagem e as do objeto, faz-se necessário transferir os níveis de cinza da imagem original para a sua nova posição.

O ideal seria que cada pixel da imagem corrigida se correspondesse a um único pixel da imagem original. O que realmente acontece é que os pixels da imagem corrigida se situam entre vários pixels da imagem original.

A transferência dos níveis de cinza da imagem corrigida pode ser realizado através da utilização de um dos seguintes métodos: vizinho mais próximo, interpolação bilinear e convolução cúbica.

No método do vizinho mais próximo, o valor do nível de cinza a ser atribuído ao pixel P, na imagem corrigida, terá o mesmo valor do nível de cinza, do pixel na imagem original, que se encontrar mais próximo da posição ocupada por P. O processamento é rápido, é de fácil implementação e não há alteração dos valores originais de cinza. Seu principal inconveniente, está no fato de introduzir algumas distorções geométricas na imagem corrigida, que se apresentam como linhas interrompidas.

Na interpolação bilinear, o valor do nível de cinza a ser atribuído ao pixel P, da imagem corrigida, é determinado a partir do valor dos 4 pixels vizinhos mais próximos na imagem original. Possui as vantagens de uma maior precisão geométrica e o desaparecimento das discontinuidades. Seus principais inconvenientes são a de requerer maior número de cálculos para determinar o valor de cada pixel da imagem corrigida e altera o valor original dos níveis.

A convolução cúbica considera os níveis de cinza dos 16 pixels mais próximos. O efeito visual é mais correto porém, o volume de cálculos é mais elevado.

3.3.2 CORREÇÕES RADIOMÉTRICAS

Correção radiométrica é um termo genérico, que designa aquelas técnicas que modificam os NC originais, de modo a obter um resultado próximo ao que seria no caso de uma recepção ideal. Dentro deste conceito, se englobam as distorções provocadas pela atmosfera, bem como os problemas radiométricos derivados do mal funcionamento do sensor.

Um mal funcionamento do sensor ou da antena receptora da imagem pode fazer com que ela apareça com algumas linhas ou pixels perdidos. Os processos de correção se destinam a melhorar artificialmente o aspecto visual da imagem, facilitando sua posterior interpretação.

Visto que se trata da perda de pixels, a forma mais lógica de estimar seus NC está em considerar os pixels vizinhos. Este critério de vizinhança pode ser introduzido de diversas formas. A forma mais simples é a de substituir os NC de cada linha/pixel por seus precedentes:

$$NC_{ij} = NC_{i-1,j} \quad (2)$$

onde NC_{ij} corresponde ao nível de cinza do pixel da linha i (linha defeituosa) e coluna j , e $NC_{i-1,j}$, indica o nível de cinza situado na linha precedente.

Um segundo método de substituição é a de considerar a média dos valores das linhas anterior e posterior à defeituosa. Isto é:

$$NC_{ij} = (NC_{i-1,j} + NC_{i+1,j})/2 \quad (3)$$

Um terceiro método de recuperação da informação perdida utiliza uma banda auxiliar, altamente correlacionada com a que apresenta problemas. A partir desta banda auxiliar, se estima o valor dos pixels defeituosos da seguinte forma (Bernstein et al, 1989):

$$NC_{ij,k} = (S_k/S_r) \{ NC_{ij,r} - (NC_{ij+1,r} + NC_{ij-1,r})/2 \} + (NC_{ij+1,k} + NC_{ij-1,k})/2 \quad (3)$$

onde S_k e S_r , são os desvios padrão da banda a ser restaurada “k” e da banda auxiliar “r”.

A radiação eletromagnética é notavelmente afetada pelos distintos componentes da atmosfera. A presença de aerossóis e vapor d’água dispersa de uma forma seletiva a radiação transmitida entre a superfície terrestre e o sensor. O fluxo de energia proveniente da fonte (radiância) detectada pelo sensor não corresponde exatamente àquela que parte da superfície.

Segundo CHUVIECO(1990), o método mais simples para correção é o idealizado por Chavez, que se denomina correção do histograma por seus valores mínimos (Histogram Minimum Method, HMM: Campbell, 1987). Assume-se que as áreas cobertas por materiais de forte absorção (água, zonas de sombra) deveriam apresentar uma radiância muito próxima de zero. Em consequência, uma simples aproximação da correção atmosférica consiste em subtrair de todos os NC da cada banda o NC mínimo desta mesma banda, situando a origem do histograma em zero:

$$NC_{ij,k}^{\prime} = NC_{ij,k} - NC_{min,k} \quad (4)$$

3.5 RESTAURAÇÃO DE IMAGENS DE SATÉLITE

A restauração é uma técnica de correção radiométrica cujo objetivo é corrigir as distorções inseridas pelo sensor óptico no processo de geração das imagens digitais. Pode-se dizer que a imagem digital é uma cópia borrada da cena, dado que os detalhes vistos na cena são suavizados devido às limitações do sensor.

A idéia de restaurar a imagem é reduzir este efeito de borramento, e, portanto, obter uma imagem realçada. A correção é realizada por um filtro linear. Os pesos do filtro de restauração são obtidos a partir das características do sensor, e não de forma empírica como é feito no caso dos filtros de realce tradicionais. Neste caso, o filtro é específico para cada tipo de sensor e banda espectral.

Este tipo de processamento é recomendado para ser realizado sobre a imagem original sem qualquer tipo de processamento tais como realce e filtragem, que alterem as características radiométricas da imagem. Deve-se observar também que não é possível processar uma imagem reamostrada, já que as características radiométrica e espacial da imagem foram alteradas.

3.6 ELIMINAÇÃO OU REDUÇÃO DO RUÍDO

No processo de geração de imagens, alguns ruídos são inseridos nas imagens. Geralmente, os pixels com ruído aparecem como pontos com níveis de cinza bem diferentes da sua vizinhança. Estes pontos ruidosos podem aparecer distribuídos aleatoriamente ou de forma sistemática (listras verticais e horizontais). Um exemplo comum, devido à falha de detecção do satélite, é o *line drop-out*, onde uma ou mais linhas da imagem não possuem valores, aparecendo na imagem como uma faixa preta ou marrom. Em geral este problema é solucionado por meio de um filtro que atribui a esses pixels, sem nível de cinza apropriado, valores das médias dos pixels vizinhos (JANSEN, 1986; SABINS, 1987).

3.7 MELHORAMENTO DA IMAGEM

O melhoramento da imagem envolve técnicas para aumentar as diferenças visuais entre determinadas características em uma cena. O objetivo é criar novas imagens a partir dos dados originais, de maneira a aumentar a quantidade de informação necessária para o processamento das imagens. Destaca-se a manipulação do contraste, a manipulação de características espaciais e a manipulação multiespectral.

3.7.1 MANIPULAÇÃO DO CONTRASTE

A técnica de realce de contraste tem por objetivo melhorar a qualidade das imagens. É normalmente utilizada como uma etapa de pré-processamento para sistemas de reconhecimento de padrões. O contraste entre dois objetos pode ser definido como a razão entre os seus níveis de cinza médios.

A manipulação do contraste consiste numa transferência radiométrica, isto é, uma redistribuição dos níveis de cinza de modo a abranger os 256 níveis de cinza possíveis (8 bits). A transformação radiométrica é aplicada a cada pixel, com o objetivo de aumentar a discriminação visual entre os objetos presentes na imagem. Realiza-se a operação ponto a ponto, independentemente da vizinhança. Esta transferência radiométrica é realizada com ajuda de histogramas, que são manipulados para obter o realce desejado.

OBSERVAÇÕES:

- 1- Não existe uma regra geral para se aplicar um contraste em uma imagem, pois depende de suas características, tais como; época de aquisição, ângulo de iluminação, altura do sensor e bandas.
- 2- Devem estar bem claros os motivos pelos quais deseja-se aplicar um aumento ou mesmo uma redução de contraste em uma imagem, antes mesmo de fazê-lo,

uma vez que esse processamento pode afetar o resultado de operações subsequentes.

3- Ao executar um realce de contraste como uma etapa de pré-processamento, deve-se atentar para o fato de que parte da informação pode ser perdida, dependendo da forma como é feito o aumento de contraste.

4- Um aumento de contraste não irá nunca revelar uma informação nova, que não esteja já contida na imagem original. O contraste apenas apresentará a mesma informação contida nos dados brutos, porém de uma forma mais clara .

Abaixo estão listadas algumas técnicas de manipulação de contraste (INPE, 1996):

- Mínimo e Máximo
- Linear
- Raiz Quadrado
- Quadrado
- Logaritmo
- Negativo
- Equalização de histograma

3.7.2 MANIPULAÇÃO DE CARACTERÍSTICAS ESPACIAIS

As principais operações de manipulação de características espaciais são as filtragens. As técnicas de filtragem são transformações da imagem *pixel a pixel*, que não dependem apenas do nível de cinza de um determinado *pixel*, mas também do valor dos níveis de cinza dos *pixels* vizinhos, na imagem original (INPE,1996; GONZALEZ E WOODS, 1992; JAIN et al, 1995).

O processo de filtragem é feito utilizando-se matrizes denominadas **máscaras** (Figura 8), as quais são aplicadas sobre a imagem. Exemplo: a imagem original formada por uma matriz de 512 linhas por 512 colunas de valores numéricos, sendo aplicada uma máscara matricial de 3 linhas por 3 colunas. Cada valor da matriz 3x3 da máscara corresponde a um peso.

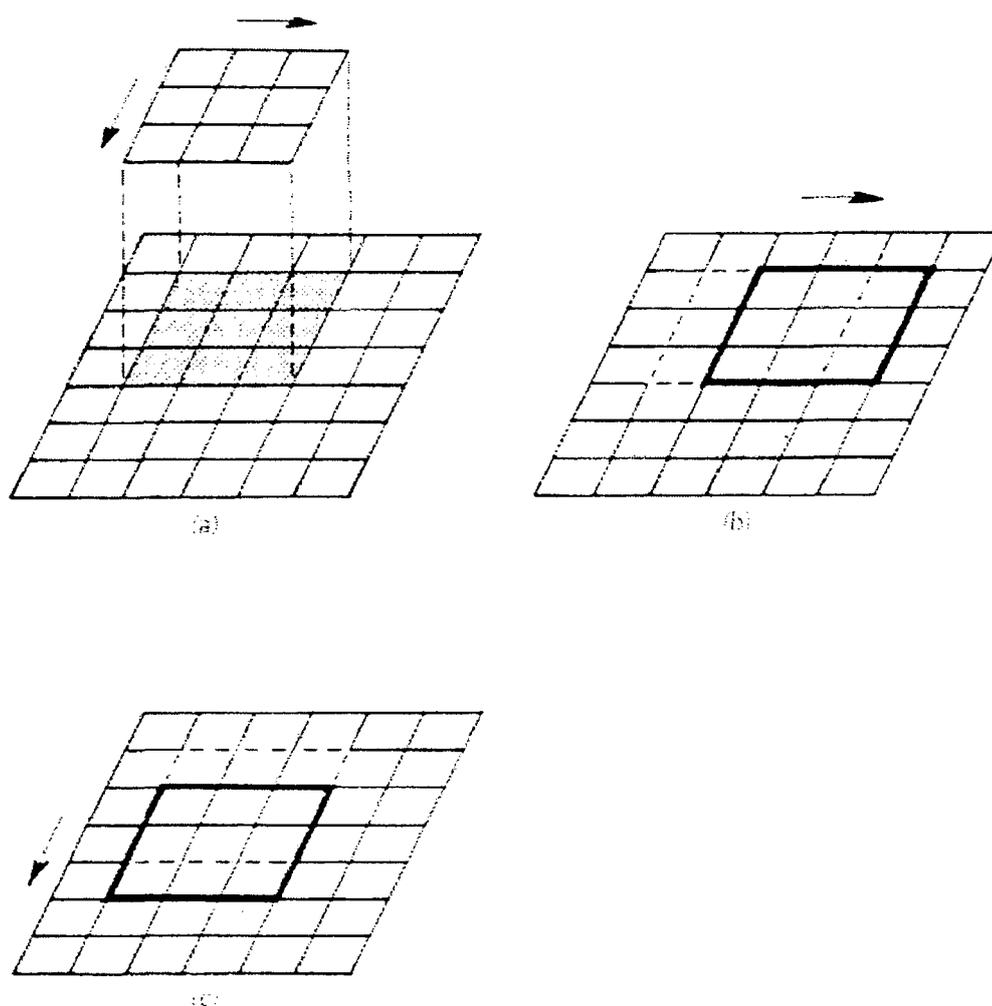


Figura 8: Aplicação de filtros.

Fonte: Lillesand, 1994

A aplicação da máscara com centro na posição (i,j) , sendo i o número de uma dada linha e j o número de uma dada coluna sobre a imagem, consiste na substituição do valor do *pixel* na posição (i,j) por um novo valor, o qual depende dos valores dos *pixels* vizinhos e dos pesos da máscara.

A imagem resultante da aplicação de um filtro é uma nova imagem com a eliminação das linhas e colunas iniciais e finais da imagem original.

Os filtros espaciais podem ser classificados em passa-baixa, passa-alta ou passa-banda. Os dois primeiros são os mais utilizados em processamento de imagens. O filtro

passa-banda é mais utilizado em processamentos específicos, principalmente para remover ruídos periódicos. Serão abordados os seguintes filtros:

1 - Filtro Linear

- Filtro Passa-Baixa
- Filtro Passa-Alta

2- Filtros Não-Lineares

- Operadores para detecção de bordas

O filtros lineares servem para suavizar ou realçar detalhes da imagem, ou ainda minimizar efeitos de ruído.

O efeito visual de um filtro passa-baixa é o de suavização da imagem e a redução do número de níveis de cinza da cena. As altas frequências, que correspondem às transições abruptas são atenuadas. A suavização tende a minimizar ruídos e apresenta o efeito de borramento da imagem.

Algumas janelas que efetuam uma filtragem passa-baixa, numa vizinhança de dimensão 3x3, 5x5 ou 7x7 estão indicadas abaixo, estes filtros são conhecidos por filtros de média, pois obtém a média entre pontos vizinhos.

$$\begin{array}{ccccccccc}
 1 & 1 & 1 & & 1 & 1 & 1 & 1 & 1 \\
 1 & 1 & 1 & \times 1/9 & 1 & 1 & 1 & 1 & 1 \\
 1 & 1 & 1 & & 1 & 1 & 1 & 1 & 1 & \times 1/25 \\
 & & & & 1 & 1 & 1 & 1 & 1 & \\
 & & & & 1 & 1 & 1 & 1 & 1 &
 \end{array}$$

$$\begin{array}{cccccccc}
 1 & 1 & 1 & 1 & 1 & 1 & 1 & \\
 1 & 1 & 1 & 1 & 1 & 1 & 1 & \\
 1 & 1 & 1 & 1 & 1 & 1 & 1 & \\
 1 & 1 & 1 & 1 & 1 & 1 & 1 & \times 1/49 \\
 1 & 1 & 1 & 1 & 1 & 1 & 1 & \\
 1 & 1 & 1 & 1 & 1 & 1 & 1 & \\
 1 & 1 & 1 & 1 & 1 & 1 & 1 &
 \end{array}$$

Outros tipos de filtro passa-baixa, conhecidos como filtros de média ponderada, são usados quando os pesos são definidos em função de sua distância do peso central. Filtros desse tipo de dimensão 3x3 são:

$$\begin{array}{ccc} 1 & 1 & 1 \\ 1 & 2 & 1 \quad X \quad 1/10 \\ 1 & 1 & 1 \end{array}$$

$$\begin{array}{ccc} 1 & 2 & 1 \\ 2 & 4 & 2 \quad X \quad 1/16 \\ 1 & 2 & 1 \end{array}$$

A filtragem passa-alta tende a realçar os detalhes, produzindo um “*sharpening*” da imagem, isto é, as transições entre regiões diferentes tornam-se mais nítidas. Exemplos: limites de um campo de cultivo, lineamento geológico, etc.

Estes filtros podem ser usados para realçar certas características presentes na imagem, tais como bordas, linhas curvas ou manchas. O efeito indesejado é o de enfatizar o ruído porventura existente na imagem.

No caso de filtragem passa-alta alguns exemplos podem ser dados, como:

$$\begin{array}{ccc} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{array} \quad \begin{array}{ccc} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{array} \quad \begin{array}{ccc} 1 & -2 & 1 \\ -2 & 5 & -2 \\ 1 & -2 & 1 \end{array}$$

Os filtros de realce de bordas atribuem valores de nível de cinza para os *pixels* da cena original, segundo a influência de seus *pixels* vizinhos. Esta maior ou menor influência será função de valores (positivos, nulos ou negativos) fornecidos pelo usuário e atribuídos aos elementos da máscara, considerados segundo a configuração do filtro utilizado. É através da combinação destes valores de entrada ou pesos, que se obterá um realce maior ou menor da cena, segundo direções preferenciais de interesse.

A Figura 9 apresenta as janelas utilizadas para o realce de bordas em vários sentidos. O nome dado às máscaras indica a direção ortogonal em que será realçado o limite de borda. Assim, a máscara norte realça limites horizontais.

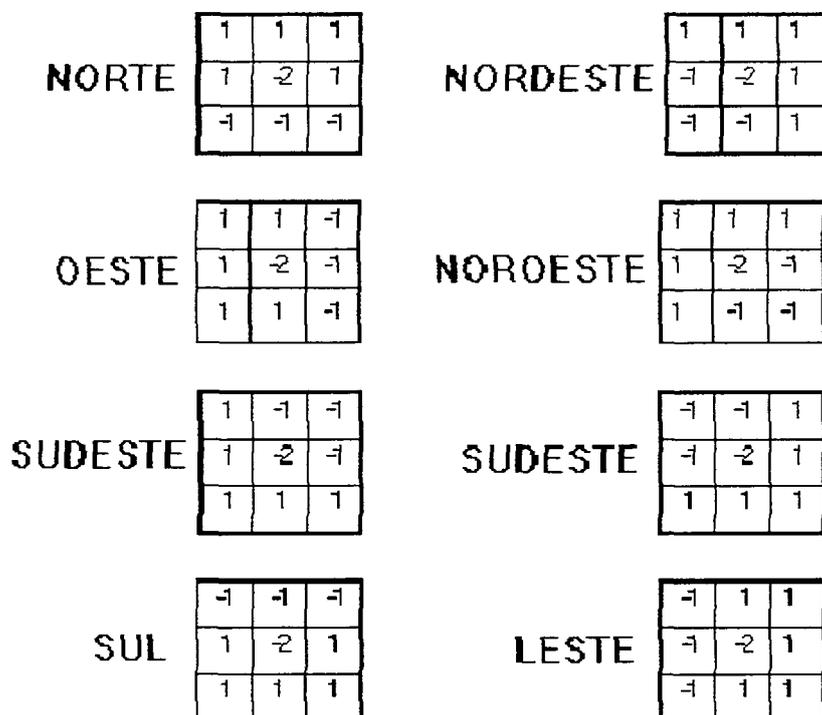


Figura 9: Filtros direcionais.

Fonte : INPE, 1996

Utilizam-se filtros **não-lineares** para alterar a imagem, sem diminuir sua resolução. Servem para minimizar/realçar ruídos e suavizar/realçar bordas. Como exemplo de filtros não-lineares pode-se citar os operadores para detecção de bordas.

A detecção de características, tais como bordas, linhas, curvas e manchas, pode ser feita também com filtros não-lineares. Como exemplo, pode-se citar os operadores de **Roberts** e **Sobel**.

Operador de Roberts: o operador gradiente de **Roberts** é o método não-linear mais simples utilizado para detecção de bordas. Apresenta a desvantagem de, dependendo da direção, certas bordas serem mais realçadas que outras, mesmo tendo magnitude igual.

Como resultado de sua aplicação, obtém-se uma imagem com altos valores de nível de cinza, em regiões de limites bem definidos e valores baixos em regiões de limites suaves, sendo 0 para regiões de nível de cinza constante.

O operador consiste na seguinte função:

$$(a') = (a - d)^2 + (c - b)^2 \quad (5)$$

a	b
c	d

onde:

a' - é o nível de cinza correspondente à localização **a**, a ser substituído;

a, b, c, d - são as localizações cujos valores serão computados para a operação.

Operador de Sobel: o operador gradiente de **Sobel** tem a propriedade de realçar linhas verticais e horizontais mais escuras que o fundo, sem realçar pontos isolados. Consiste na aplicação de duas máscaras, descritas a seguir, que compõem um resultado único.

$$\begin{array}{ccc}
 -1 & 2 & -1 \\
 0 & 0 & 0 \\
 1 & 2 & 1
 \end{array}
 \quad (a)
 \qquad
 \begin{array}{ccc}
 -1 & 0 & 1 \\
 -2 & 0 & 2 \\
 -1 & 0 & 2
 \end{array}
 \quad (b)$$

A máscara (a) detecta as variações no sentido horizontal e a máscara (b), no sentido vertical.

4. SEGMENTAÇÃO E CLASSIFICAÇÃO

Em um sistema de processamento de imagens, a segmentação constitui um importante passo para a extração de inferências significativas de dados visuais para posterior análise. O processo de segmentação de uma imagem refere-se ao particionamento das imagens em segmentos que correspondam a regiões homogêneas, existindo mudanças expressivas entre os segmentos.

4.1 DEFINIÇÃO FORMAL

GONZALEZ e WOODS(1992), fazem a seguinte definição formal para o problema de segmentação de imagens:

Considere R a representação da imagem como um todo. A segmentação pode ser vista como o processo que particiona R em k sub-regiões, R_1, R_2, \dots, R_k , tal que:

- (1) $\bigcup_{i=1}^k R_i = R$;
- (2) R_i é uma região conexa, $i = 1, 2, \dots, k$;
- (3) $R_i \cap R_j = \emptyset$, para todo i e j , $i \neq j$;
- (4) $P(R_i) = \text{VERDADEIRO}$ para $i = 1, 2, \dots, k$; e
- (5) $P(R_i \cup R_j) = \text{FALSO}$ para $i \neq j$,

onde $P(R_i)$ é um predicado lógico sobre os pontos no conjunto R_i e \emptyset é o conjunto vazio.

4.2 CLASSIFICAÇÃO DE IMAGENS

A intenção do processo de classificação é classificar todos os pixels de uma imagem digital dentre várias classes de coberturas ou temas. Os dados classificados podem ser

usados para produzir mapas temáticos da cobertura do solo existente na imagem e produzir sumários estatísticos dessas áreas.

O termo **classificação**, no que diz respeito a um conjunto de padrões, tem sido usado como sinônimo de agrupamento mas, em sentido geral, pode significar **identificação**. O objetivo da classificação é descobrir agrupamentos naturais, ou tipos, de maneira que se possa estabelecer hipóteses sobre o objeto ou fenômeno que está sendo estudado.

O termo “padrão”, segundo LILLESAND (1994), se refere às medidas de radiância obtidas nas várias bandas para cada pixel. Reconhecimento de padrões espectrais se refere ao conjunto de procedimentos de classificação que utilizam a informação espectral de cada pixel, como base para uma classificação automática.

A análise de grupos une objetos de acordo com índices de semelhança ou afinidade entre pares de objetos ou pixels. Padrão, neste trabalho, denotará um objeto, ou pixel, a ser agrupado. Um conjunto de pixels pode ser descrito de duas maneiras: uma matriz de pixels e uma matriz de proximidades.

Serão analisados os métodos de classificação de imagens destinados ao mapeamento do uso do solo. Primeiro será descrita a classificação supervisionada. Neste tipo de classificação, o usuário “supervisiona” o processo de classificação, especificando as características dos vários tipos de cobertura do solo presentes na cena. Para a sua realização, amostras representativas de coberturas conhecidas, chamadas áreas de treinamento, são utilizadas para compilar uma chave de interpretação que descreva as características espectrais de cada classe. Cada pixel do conjunto de dados é então comparado com cada classe e classificada de acordo com a classe a que ele mais se assemelha.

Após a classificação supervisionada, será abordada a classificação não-supervisionada. A diferença fundamental entre os dois métodos é que a classificação supervisionada possui uma etapa de treinamento, seguida de uma etapa de classificação. Na abordagem não supervisionada, a imagem é primeiramente classificada através do agrupamento em “*clusters*” (grupos de pixels com características comuns). Então, o usuário irá determinar a identidade da cobertura do solo destes grupos espectrais através da comparação da imagem classificada com os dados de referência.

4.2.1 CLASSIFICAÇÃO SUPERVISIONADA

O método supervisionado se inicia a partir de um certo conhecimento da área de estudo, adquirido por experiência anterior ou por trabalhos de campo.

Este método envolve 3(três) passos básicos:

- 1- Treinamento: onde são identificadas as áreas de treinamento e onde há uma descrição dos atributos espectrais de cada tipo de cobertura de interesse na cena.
- 2- Classificação: o pixel é classificado em função de suas características se assemelharem ou não a alguma classe. Caso contrário, ele é dito “desconhecido”.
- 3- Resultado: podem ser usados de diferentes maneiras. Três formas típicas de produtos são os mapas temáticos, tabelas com dados estatísticos para as várias classes de cobertura de solo e dados para posterior utilização em geoprocessamento.

A Figura 10, resume de forma sucinta, as fases anteriormente citadas:

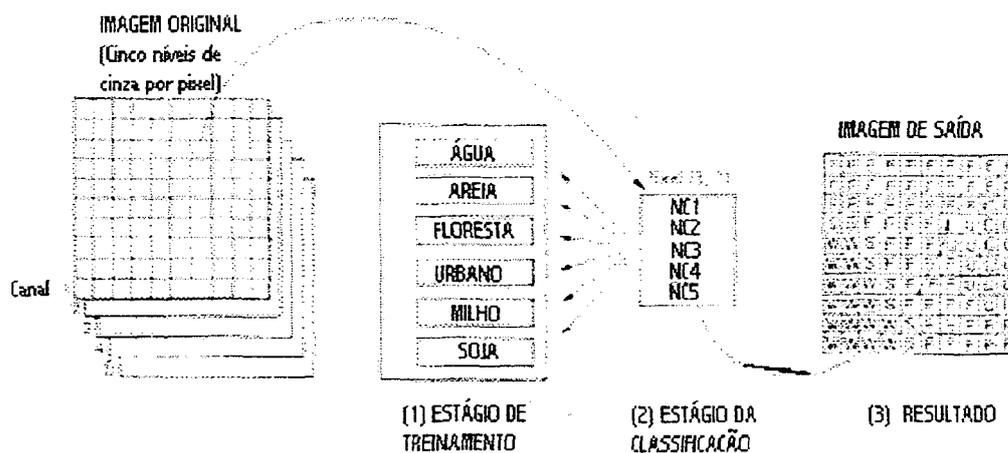


Figura 10: Etapas da classificação supervisionada.

Fonte: Lillesand,1994

Dado um conjunto de pixels, os mesmos podem ser representados graficamente através de um diagrama, como representado na Figura 11.

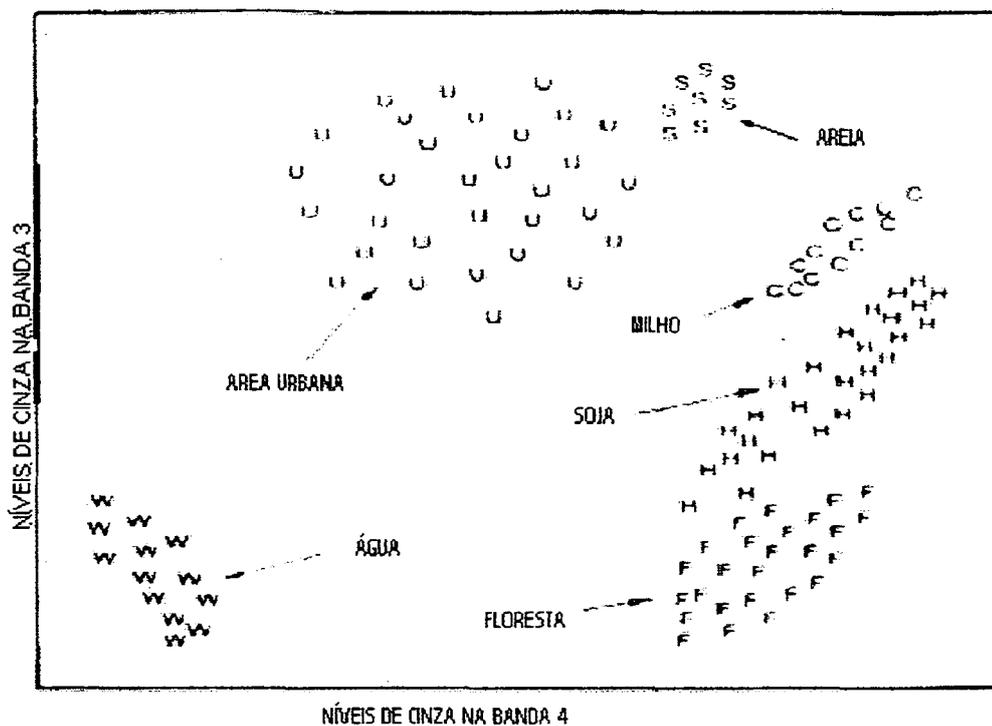


Figura 11: Diagrama de dispersão

Fonte: Lillesand, 1994

No diagrama, estão representadas apenas 2 (duas) bandas. Os valores de níveis de cinza obtidas na banda 3 são representadas no eixo y e os da banda 4 no eixo x . Por exemplo, se na banda 4 o pixel apresenta um valor 10 e na banda 3 o seu valor é 68, este pode ser representado pelo ponto localizado nas coordenadas (10,68).

Nota-se, a partir do diagrama, que os pixels dentro de cada classe não possuem o mesmo valor espectral. Ao invés, o gráfico retrata uma tendência das propriedades espectrais dentro de cada classe.

Várias são as técnicas utilizadas para se realizar a classificação supervisionada. Pode-se citar o método da mínima distância e o método da máxima verossimilhança.

O método da mínima distância é a estratégia mais simples de classificação (CHUVIECO, 1990; LILLESAND, 1994). Primeiro deve-se determinar, dentro de cada banda e para cada classe, a média dos valores dos pixels. Considerando apenas 2 bandas, o pixel desconhecido pode ser classificado através do cálculo da distância entre o pixel de valor desconhecido e o ponto que representa a média de cada classe (Figura 12).

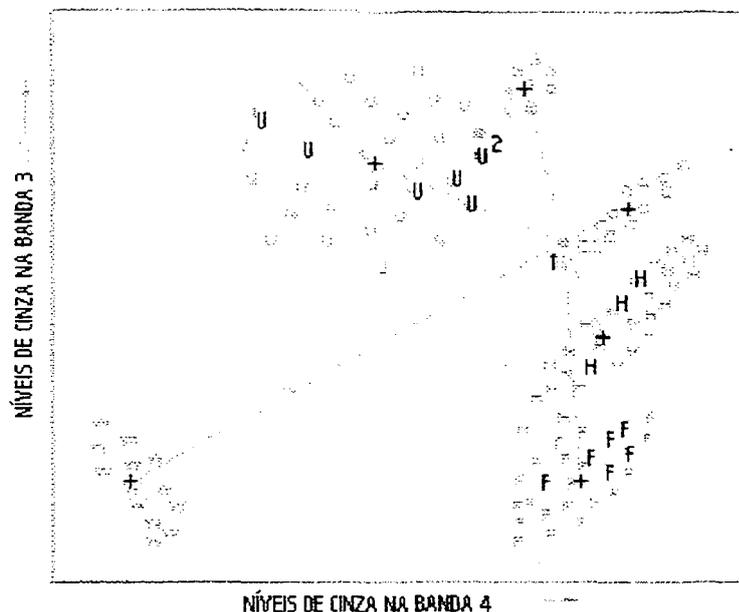


Figura 12: Método da menor distância

Fonte : Lillesand,1994

Após o cálculo das distâncias, o pixel desconhecido é associado à classe mais próxima. Caso o pixel esteja distante de todas as classes mais do que um certo limiar, ele será classificado como “desconhecido”.

Este método é matematicamente simples e computacionalmente eficiente, mas possui algumas limitações. A mais importante é a sua insensibilidade aos diferentes graus de variância dos dados espectrais. Tendo em vista este problema, este método não é muito usado em aplicações onde classes espectrais estão muito próximas uma das outras e possuem grande variância.

O método da máxima verossimilhança (Maxver) (INPE, 1996) avalia quantitativamente tanto a variância quanto a covariância dos padrões espectrais de cada pixel durante a classificação. Inicialmente, supõe-se que a distribuição dos pixels que formam os dados de treinamento é Gaussiana (distribuição normal). Deste modo, os

padrões de respostas podem ser descritos por um vetor de médias e uma matriz de covariância. De posse destes parâmetros, pode-se calcular a probabilidade de um dado pixel pertencer a um tipo particular de cobertura do solo.

O método de máxima verossimilhança, delinea um contorno elipsoidal, como representado na Figura 13.

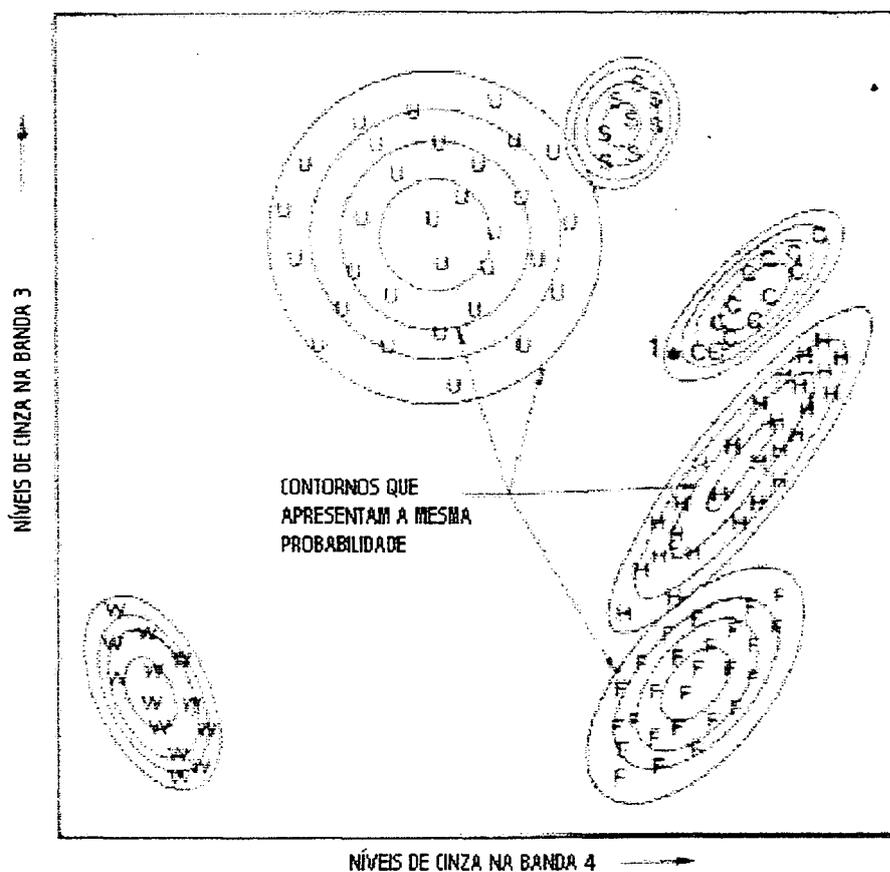


Figura 13: Método MaxVer

Fonte: Lillesand, 1994

A principal desvantagem deste método é o alto custo computacional necessário para classificar todos os pixels. Isto se torna relevante a partir do momento da existência de um grande número de bandas e de classes.

4.2.2 ETAPA DE TREINAMENTO

O objetivo desta fase é reunir um conjunto de dados estatísticos que descrevam as características espectrais de cada cobertura. Os dados de treinamento têm que ser tanto representativos como completos. Isto significa que é necessário obter dados estatísticos sobre todas as características espectrais de cada classe de interesse. Por exemplo, como dado de saída, existe a necessidade de delinear a classe “água”. Se diversos tipos de “corpos d’água” aparecem na imagem (águas mais claras e outras mais escuras), será necessário determinar um conjunto de dados de treinamento para cada classe. Dessa maneira, o tipo “água” poderá ser representado por mais de uma classe espectral.

A localização de áreas de treinamento na imagem é, normalmente, estabelecida através de janelas ou partes da cena. Os polígonos que envolvem as áreas de treinamento devem ser cuidadosamente localizados de maneira a evitar pixels de borda. Outra alternativa seria utilizar a técnica de crescimento de regiões a partir de um único pixel ou semente e, de acordo com um critério, pixels vizinhos, com características espectrais similares, seriam incorporados à área de treinamento.

Segundo LILLESAND (1994), teoricamente, o número mínimo de pixels que o conjunto de treinamento deve possuir é $n+1$ onde n é o número de bandas espectrais. Na prática, segundo CHUVIECO (1990), o número mínimo de pixels varia de $10n$ a $100n$. Isto se deve ao fato do valor da média e das matrizes de covariância serem mais precisos à medida que o número de pixels do conjunto aumenta.

4.2.3 CLASSIFICAÇÃO NÃO SUPERVISIONADA

Com o desenvolvimento da computação digital, nos últimos anos, os métodos de agrupamento têm despertado o interesse de pesquisadores nas mais diversas áreas, pela possibilidade de sua aplicação a grandes conjuntos de amostras de uma imagem (pixel) que apresentam características similares. Em uma imagem, características diferentes

manifestam diferentes combinações de níveis de cinza baseados em suas reflectâncias espectrais e suas propriedades de emissão.

Este método se destina a definir as classes espectrais presentes na imagem. Assume-se que os níveis de cinza de uma imagem formam uma série de agrupamentos, conglomerados ou *clusters*. Estes grupos equivaleriam a pixels com um comportamento espectral homogêneo e, portanto, deveriam definir classes temáticas de interesse. Segundo CHUVIECO (1990), esta classificação se baseia em 3(três) processos:

- 1 - Seleção das variáveis que intervêm na análise;
- 2 - Seleção de um critério para medir a distância entre os casos;
- 3 - Seleção de um critério para agrupar os casos similares.

Neste contexto, as variáveis são bandas espectrais selecionadas para a classificação. Os casos são os pixels que compõem a imagem, cada um deles definido por vetor de tamanho n (número de bandas que intervêm na análise). Neste espaço multivariado, trata-se de encontrar os grupos de pixels com níveis de cinza similares, para depois equipará-los com uma dada legenda.

Para se encontrar os grupos homogêneos, pode-se representá-los através de um gráfico bivariado onde aparecem tantos pontos quanto pixels, localizados de acordo com seus níveis de cinza em cada banda.

A delimitação de cada grupo espectral se inicia definindo 2 (dois) critérios: um que meça a semelhança entre pixels e outro que marque as condições do processo de agrupamento. No que se refere ao primeiro aspecto, utiliza-se a distância Euclidiana:

$$D_{a,b} = \sqrt{\left(\sum_1^m (NC_{a,k} - NC_{b,k})^2 \right)} \quad (7)$$

Onde $D_{a,b}$, indica a distância entre dois pixels quaisquer a e b ; $NC_{a,k}$ e $NC_{b,k}$ indicam os níveis de cinza destes pixels na banda k ; m indica o número de bandas.

No que se refere ao processo de agrupamento, temos o Self-Organizing Data Analysis Technique ou ISODATA e o K-means (CELINSKI, 1998).

DUBES & JAIN (1976) apresentam um fluxograma simplificado (Figura 14) para os algoritmos *K-means* e ISODATA, sendo que o algoritmo *k-means* não faz o ajuste do número de grupos, limitando-se ao laço interno do fluxograma.

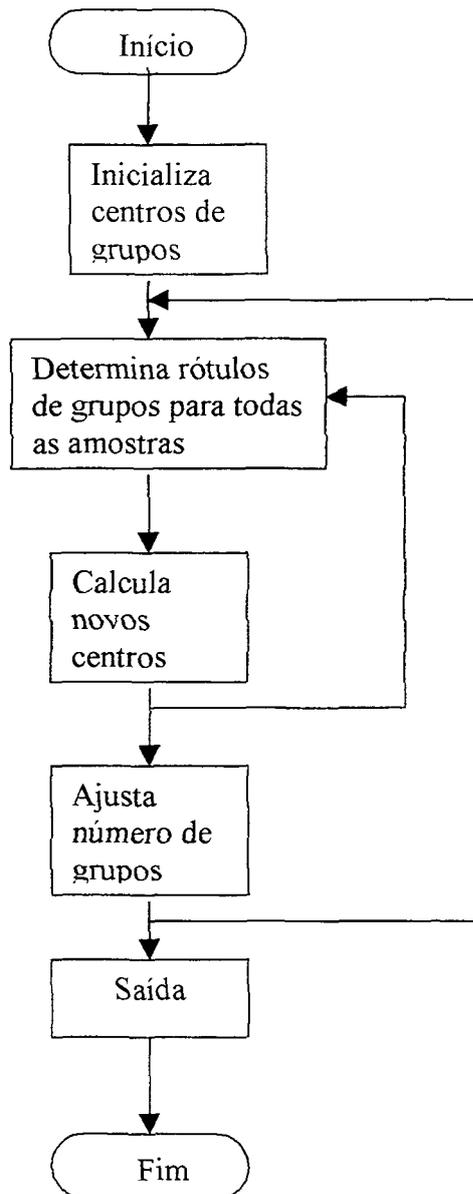


Figura 14: Algoritmo ISODATA

Fonte: DUBES & JAIN, 1976

O método K-means pode ser definido da seguinte forma:

Passo 1. Estabelece os centros de grupo iniciais, arbitrariamente;

Passo 2. Distribui os elementos entre os grupos utilizando a distância Euclidiana, isto é, atribuindo um elemento ao grupo cujo centro é mais próximo;

Passo 3. Calcula centros de grupo dos grupos existentes, pela média de todos os componentes de cada grupo;

Passo 4. Os passos 2 e 3 devem se repetir até que não haja mais trocas nos centros de grupos ou que se atinja o número máximo de iterações definido.

Este método recebe do analista um número de *clusters* para serem locados nos dados. O algoritmo arbitrariamente posiciona aquele número de centros de agrupamento em um espaço multidimensional. Cada pixel na imagem é então associado a um agrupamento cujo centro é mais próximo. Após todos os pixels terem sido classificados desta maneira, calcula-se um novo centro para cada agrupamento através da média de todos os componentes de cada grupo. O valor do novo centro é usado como base para reclassificar os dados da imagem. O procedimento continua até não haver mais mudança significativa da posição do centro da classe entre iterações sucessivas do algoritmo. Quando este ponto foi atingido, pode-se identificar a identidade de cada classe espectral.

Uma vantagem deste algoritmo é a sua independência de limiares fornecidos pelo usuário, sendo necessários apenas o número de grupos, que é fixo, e o número de iterações e/ou outras variáveis que possam estabelecer a parada do algoritmo. Porém, uma boa estimativa para o número de grupos nem sempre ocorre.

Uma vez que o conjunto de amostras é finito, há um número finito de partições possíveis. Assim, na teoria, o problema do agrupamento pode ser resolvido sempre por enumeração exaustiva.

Uma maneira de superar esta desvantagem é executar o algoritmo diversas vezes com diferentes inicializações, na tentativa de se alcançar um valor para o erro-quadrático que, embora mínimo local, seja mais próximo do mínimo global (CELINSKI, 1998).

O método ISODATA, que é uma outra forma de implementação do K-means, utiliza heurísticas para criar novos grupos enquanto tenta encontrar o número de grupos requisitado pelo usuário. A capacidade de divisão e união de grupos existente permite realizar uma melhor seleção dentre uma variedade de agrupamentos. Pode ser definido da seguinte forma:

Passo 1. Estabelece os centros de grupo iniciais, arbitrariamente;

Passo 2. Distribui os elementos entre os grupos utilizando a distância Euclidiana, isto é, atribuindo um elemento ao grupo cujo centro é mais próximo;

- Passo 3. Calcula centros dos grupos existentes, pela média de todos os componentes de cada grupo;
- Passo 4. Os passos 2 e 3 devem se repetir até que não haja mais trocas nos centros de grupos ou que se atinja o número máximo de iterações definido.
- Passo 5. Remove grupos contendo menos de N amostras, e trata as amostras envolvidas como fora de contexto (ruído);
- Passo 6. Une e/ou divide grupos restantes. Se não é necessário união ou divisão, pára;
- Passo 7. Calcula novos centros de grupo e repete passos 2 a 6.

O processo se repete iterativamente até que o centro da classe não se desloque significativamente, o que indica um bom ajuste dos grupos presentes na imagem. Antes de iniciar uma nova iteração, o algoritmo verifica se o número máximo de grupos para interromper o agrupamento foi alcançado, se algum grupo possui um número de pixels inferior ao mínimo assinalado e se algum grupo está a uma distância inferior a mínima permitida entre grupos para realizar uma fusão.

O usuário não conhece, no início, o número de grupos espectrais presentes na imagem, nem o valor da dispersão interna ou da distância entre grupos. Tendo em vista isso, faz-se necessário usar parâmetros de controle. Dois parâmetros, T_{i1} e T_{i2} , fornecidos pelo usuário controlam a divisão e união de grupos. O primeiro controla a admissão para divisão e união da seguinte maneira: define K^2_i como a parte inteira de $(1 + T_{i1})K_i$, onde K_i é o número de grupos desejado e fornecido pelo usuário. Se o número corrente de grupos excede K_i , o subprograma de união é ativado. Se não o subprograma de divisão é ativado. O segundo parâmetro, T_{i2} , determina limiares internos nos subprogramas de união e divisão. O limiar de divisão é T_{i2} vezes o erro médio, enquanto o limiar de união é T_{i2} vezes a distância média entre centros de grupos (CELINSKI, 1998).

O processo de inicialização no método ISODATA é mais elaborado: o primeiro dos centros de grupo iniciais é o centróide de todos os elementos. Todos os elementos são testados e aquele designado para a remoção constitui um novo centro de grupo inicial. Tal procedimento dá uma distribuição mais uniforme dos centros de grupos iniciais.

5 MÉTODO PROPOSTO

A execução do trabalho envolveu seis etapas distintas: obtenção dos dados, pré-processamento da imagem (registro e contraste), processamento (segmentação e classificação), amostragem de campo para verificação do mapeamento, análise dos dados coletados em campo, elaboração do documento final.

O registro vem a ser uma transformação geométrica que relaciona, neste caso, coordenadas geométricas (latitude e longitude) com coordenadas da imagem (linhas e colunas) (INPE, 1996). O contraste tem como objetivo equalizar as bandas, de forma a permitir que todas as bandas exerçam influência semelhante no processo de segmentação da imagem (INPE, 1996). O processo de segmentação da imagem, tem como objetivo dividir a imagem em regiões homogêneas (AIT et al., 1992; WOODCOCK et al., 1994). A técnica de segmentação proposta, é referente a delimitação de objetos pelo método de crescimento de regiões. Inicialmente, o processo rotula cada pixel como sendo uma região distinta (VENTURIERI, 1995). A partir daí, os pixels com valores de similaridade inferiores ao limiar estabelecido são agrupados (LIPORACE, 1994). Com isto a imagem é fragmentada em sub-regiões, as quais são reagrupadas a seguir, segundo um limiar de agregação estabelecido (INPE, 1996; KHODJA et al., 1995; KHODJA & MENGUE, 1996). O procedimento metodológico de classificação baseou-se em dois processos distintos, mas que de certa forma se complementam. O primeiro processo utilizado, de classificação não supervisionada, é muito dependente da automação computacional, uma vez que um algoritmo trata de aglomerar pixels dentro de uma mesma variação espectral (BOGNOLA, 1997). O segundo processo, foi a classificação supervisionada, a qual foi controlada através da seleção de regiões que representassem determinada classe. Foi um processo de seleção de amostras (Khodja & Mengue, 1996). Em uma primeira fase, o processo não-supervisionado foi utilizado para selecionar áreas espectralmente homogêneas, que foram utilizados, em uma segunda fase, como áreas de treinamento para a classificação supervisionada.

Assim, a primeira etapa do método consiste em particionar a imagem em regiões e extrair seus atributos (BINS et al., 1993; ERTHAL et al., 1991). A segunda etapa envolve a classificação das regiões usando um algoritmo de agrupamento. A terceira etapa vem a ser

a seleção de algumas regiões, classificadas na etapa anterior, e a utilização da mesmas como áreas de treinamento em uma classificação supervisionada.

5.1 OBTENÇÃO DOS DADOS

5.1.1 ESCOLHA DAS BANDAS DE INFORMAÇÃO DO SATÉLITE

O principal fornecedor de imagens de satélite Landsat no Brasil é o Instituto Nacional de Pesquisas Espaciais (INPE). O motivo pelo qual deve-se escolher imagens obtidas a partir do satélite Landsat 5 para a execução dos trabalhos é o fato deste produto ser o principal instrumento de trabalho na área de geoprocessamento no Brasil e possuir resolução espectral satisfatória para a execução de qualquer trabalho/projeto de pesquisa .

As imagens são fornecidas em diversos níveis de correção, a saber:

1. correções geométricas ao longo da linha
2. correções geométricas com reamostragem por "vizinho mais próximo"
3. correções geométricas básicas com reamostragem por "convolução cúbica"

A escolha das bandas deve levar em consideração o objetivo de cada trabalho e as características individuais de cada banda do satélite Landsat 5 .

5.1.2 DEFINIÇÃO DA ESCALA DE TRABALHO

A definição da escala de trabalho de abordagem, deve considerar inicialmente quais elementos da paisagem serão representados. A partir deste ponto, deve-se procurar os meios e aplicativos mais adequados para a execução do trabalho.

JANSEN (1995), definiu as melhores escalas de trabalho para os sensores do satélite Landsat, como mostra a Tabela 5.

ESCALAS	SATELITE
1:250.000 – 1:500.000	Landsat – MSS
1: 100.000	Landsat – TM

Tabela 4: Escalas máximas das abordagens através da utilização dos sensores acoplados ao satélite Landsat

Fonte: adaptada de Jansen(1995).

Segundo esta tabela, a escala espacial mais indicada para se trabalhar com imagens do satélite Landsat 5 (sensor TM) seria 1:100.000.

A imagem digital do satélite Landsat-TM, originalmente composta por pixels de 30 X 30 metros, para as bandas 1-5 e 7, apresenta dificuldades para a execução de classificação analógicas em escala acima de 1:50.000, em função da granulação e da conseqüente perda da definição dos limites das unidades. Na escala 1:50.000, por exemplo, o pixel desta imagem, representando uma superfície de 30 X 30 metros no campo, corresponderá a um quadrado de 0.06 X 0.06 centímetros na imagem. Na escala 1:25.000, este mesmo pixel corresponderá a um quadrado de 0.12 X 0.12 centímetros, sendo possível identificá-lo a olho nu, o que determinará a granulação e redução da definição dos elementos da imagem.

5.1.3 DEFINIÇÃO DAS CLASSES TEMÁTICAS

Para a definição das classes do mapeamento deve ser realizada uma etapa de campo preliminar na área definida para execução do projeto/trabalho. O objetivo é o de conhecer os elementos que constituem as diversas formas de uso das terras existentes. Algumas formas de uso das terras que poderiam ser observados são: área urbana, vegetação nativa, mata ciliar, culturas vegetais (milho, soja, etc.) e outros.

5.2 PROCESSAMENTO DIGITAL

O processamento digital irá envolver as etapas de pré-processamento (registro e contraste) e o processamento propriamente dito (segmentação e classificação).

5.2.1 REGISTRO DA IMAGEM COM A CARTA BASE

Para a sobreposição da imagem de satélite pela cartografia básica, é necessário realizar a operação de registro imagem/carta. O produto desta transformação permitirá a sobreposição das principais vias de acesso da área de estudo à imagem de satélite, apoiando a execução da etapa de levantamento de dados no campo.

O registro é uma transformação geométrica que relaciona coordenadas reais do ponto (latitude e longitude) com coordenadas da imagem (linhas e colunas). Essa transformação corrige distorções existentes na imagem, causadas no processo de sua formação, pelo sistema sensor e por imprecisão no posicionamento da plataforma (INPE, 1996).

De acordo com CHUVIECO (1990), o registro se realiza em três fases:

1. Localização de pontos de controle na imagem e no mapa;
2. Cálculo das funções de transferência entre as coordenadas da imagem e as do mapa;
3. Transferência dos valores dos pixels originais para a nova posição definida na etapa anterior.

Para se calcular qualquer função a partir de duas ou mais variáveis, é necessário obter uma série de observações comuns a todas elas. Da mesma forma, as funções que permitem transformar coordenadas da imagem em coordenadas cartográficas precisam de uma série de pontos de controle na imagem e no mapa. A partir das coordenadas destes pontos, pode-se estimar uma função que relacione ambos os documentos.

Para que o ajuste ou calibração entre a imagem e o mapa seja correto, é necessário atender a três aspectos na seleção dos pontos de controle: número, localização e distribuição dos pontos (CHUVIECO, 1990).

O número necessário de pontos de controle irá depender do tamanho e da complexidade geométrica da imagem. Por exemplo, se a região apresenta um relevo bastante acentuado, o número de pontos será maior do que se a região for relativamente plana. No entanto, o número mínimo de pontos deverá ser 6 (seis) (INPE, 1996; GONZALEZ & WOODS, 1993; JAIN, 1995).

No que se refere à localização, é recomendável que sejam pontos claramente identificáveis tanto na imagem como no mapa. De preferência deve-se selecionar aspectos da paisagem não sujeitos a variação temporal, por exemplo: cruzamentos de estradas, represas, estradas de ferro, etc. Com relação à distribuição dos pontos, é conveniente que se escolham pontos de controle que estejam uniformemente distribuídos pela imagem.

A correção geométrica ou registro de uma imagem se realiza através de uma função matemática, que estabelece uma relação entre as coordenadas da imagem e do mapa. Esquemáticamente, esta transformação pode ser expressa como (CHUVIECO, 1990; GONZALES, 1992):

$$S = \sum_{j=0}^m \sum_{k=0}^{m-j} a_{jk} x_j y_k \quad (8)$$

Onde S indica a coordenada da imagem corrigida, que se determina a partir das coordenadas x e y da imagem de entrada. O índice m indica o grau do polinômio de ajuste. O caso mais simples seria o de uma equação linear, onde:

$$S = a_0 + a_1 x_i + a_2 y_i \quad (9)$$

ou, em termos de coordenadas:

$$X = a_0 + a_1 x_i + a_2 y_i \quad (10)$$

$$Y = b_0 + b_1 x_i + b_2 y_i \quad (11)$$

onde a_0 , a_1 , a_2 , b_0 , b_1 e b_2 são os coeficientes de regressão, x e y são as variáveis independentes e, X_i e Y_i indicam as variáveis dependentes. Neste caso, as variáveis independentes são as coordenadas do ponto na imagem e, as dependentes, são as coordenadas do ponto no mapa.

Os *softwares* utilizados em geoprocessamento já possuem implementados essas transformações, tornando desnecessárias, por parte do futuro usuário, suas respectivas implementações.

Os métodos utilizados para efetuar esta transferência são citados na seção 3.4.1, e são os seguintes:

1. Vizinho mais próximo;
2. Interpolação bilinear;
3. Convolução cúbica.

Cabe ao usuário a escolha do melhor método de transferência a ser utilizado para atender as suas necessidades específicas.

5.2.2 MANIPULAÇÕES DE CONTRASTE

A técnica de realce de contraste tem por objetivo melhorar a qualidade das imagens. É normalmente utilizada como uma etapa de pré-processamento para sistemas de reconhecimento de padrões (INPE, 1996).

No caso de imagens multiespectrais, a técnica de realce de contraste, visa a normalizar as bandas, de forma a permitir que todas exerçam influência semelhante no processo de segmentação de imagem.

Inicialmente, deve-se observar os histogramas das diversas bandas das imagens e analisar a distribuição dos pixels na imagem. Caso a dispersão, também chamada variância, não seja muito grande, será necessário redistribuir os valores ao longo do intervalo compreendido entre 0 e 255, que são os 256 níveis de cinza possíveis a partir de uma imagem de 8 bits por pixel.

A melhor operação para efetuar a correção dos níveis de cinza é, inicialmente, a equalização do histograma, seguido de um ajuste linear. Deve-se tomar como referência a banda que possui a maior variância.

A equalização consiste em uma transformação não-linear que gera uma imagem resultante, cujo histograma será aproximadamente uniforme (INPE, 1996).

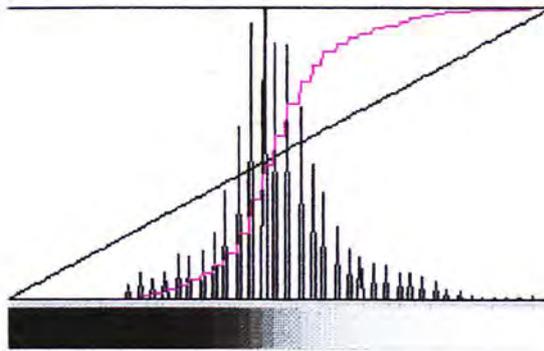


Figura 15: Função de equalização da banda 5.

A equalização parte do princípio que o contraste de uma imagem seria otimizado se todos os 256 possíveis níveis fossem igualmente utilizados ou, em outras palavras, todas as barras verticais que compõem o histograma fossem da mesma altura (INPE,1996). Isto não é possível devido à natureza discreta dos dados. No entanto, uma aproximação é conseguida ao se espalhar os picos do histograma da imagem, deixando intocadas as partes mais “chatas” do mesmo. Como observa-se na Figura 15, a função de transferência possui uma alta inclinação toda vez que o histograma original apresentar um pico, e uma baixa inclinação no restante do histograma. Na Figura 16 pode-se observar o resultado da equalização do histograma.

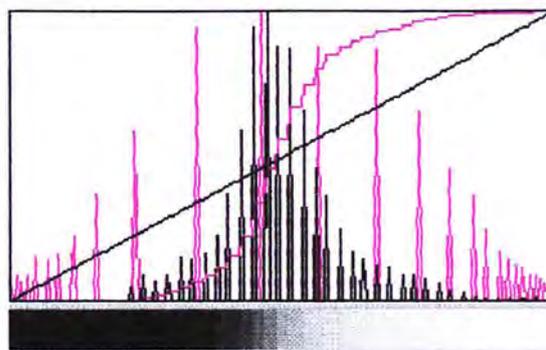


Figura 16: Banda 5 equalizada

5.2.3 SEGMENTAÇÃO DA IMAGEM

Esta etapa do método constitui-se em uma etapa de pré-classificação. Nesta fase a imagem será subdividida em regiões espectralmente homogêneas. O processo de segmentação de imagens tem por objetivo fragmentar uma região, em unidades homogêneas, considerando algumas de suas características intrínsecas como, por exemplo, o nível de cinza dos pixels, textura e contraste (WOODCOCK et al, 1994).

Segundo WOODCOCK & HARVARD (1992), o objetivo da segmentação em sensoriamento remoto é definir regiões na imagem que correspondam a objetos na superfície terrestre. Para KHODJA et al. (1995), a segmentação é um processo com objetivo de reagrupar regiões possuidoras de uma mesma propriedade. Entende-se por região um conjunto de pixels contíguos e apresentando uniformidade (INPE, 1996).

Para AIT BELAID et al. (1992), o algoritmo de segmentação particiona uma imagem em função de algumas características espaciais homogêneas, segundo dois caminhos:

- definição de bordas, através da detecção de descontinuidades nas imagens;
- extração de regiões, através de algoritmos específicos para detectar similaridade entre pixels.

O tipo de segmentação que será tratado neste trabalho será o referente à delimitação de objetos pela técnica de crescimento de regiões.

O crescimento de regiões é uma técnica de agrupamento de dados, na qual somente as regiões adjacentes espacialmente podem ser agrupadas. Inicialmente este processo de segmentação rotula cada pixel como sendo uma região distinta. A partir daí, são agrupados os pixels com valores de similaridade inferiores ao limiar estabelecido, baseado em um teste realizado com as médias entre as regiões. Com isto a imagem é fragmentada em sub-imagens, as quais são reagrupadas a seguir, segundo um limiar de agregação (tamanho mínimo aceitável para uma sub-região), estabelecido também pelo usuário (INPE, 1996).

Para VENTURIERI (1995), o algoritmo de crescimento de regiões gera, a partir de um pixel (i,j) , uma região, contendo (i,j) e possuindo um valor médio de nível de cinza

próximo ao de (i, j) . O grau de similaridade é determinado por um parâmetro t , representado pela distância euclidiana entre os vetores associados a cada segmento.

Segundo LIPORACE (1994) (citado por VENTURIERI, 1995), tomando-se uma distância (R_i, R_j) como medida de similaridade entre regiões R_i e R_j , e sendo “A” (número de pixels), uma constante determinando o tamanho mínimo aceitável para uma região, o algoritmo de crescimento de regiões considera:

- a. Inicialmente cada pixel como sendo uma região (R_1, R_2, R_3, R_4 e R_5) onde vizinhos de (R_1) = R_2, R_3, R_4 e R_5 (vizinhança 4) (Figura 17).

R6	R3	R7
R2	R1	R4
R9	R5	R8

Figura 17: Relação de vizinhança de um pixel.

- b. Sejam R_i e R_j duas regiões, onde R_i é o vizinho mais próximo de R_j e vice-versa. Uma região R_i é a vizinha mais próxima de R_j quando a distância $(R_j, R_i) \leq$ distância (R_j, R_k) para todo R_k vizinho de R_j ;
- c. Se a distância $(R_j, R_i) < t$, uma região $R_1 = R_j \cup R_i$ é criada e retorna-se ao passo (b);
- d. Para cada região R_j , cujo tamanho em pixels for menor ao estabelecido por “A”, cria-se um segmento $R_k = R_j \cup R_i$, onde R_i é o vizinho mais próximo de R_j . Este processo se repete até não haver mais nenhuma região com tamanho inferior a “A”. Toda inclusão de um novo pixel a uma região ou união de duas regiões é seguida por uma redefinição das características destas, como média e variância, área, perímetro.

Existem alguns algoritmos de segmentação que consideram, ao invés de apenas quatro vizinhos, como no exemplo acima, os oito vizinhos de $R_1 = R_2, R_3, R_4, R_5, R_6, R_7, R_8$ e R_9 (KHODJA et al. 1995)(KHODJA & MENGUE, 1996).

O algoritmo de crescimento de regiões utilizado depende da definição de duas variáveis: grau de similaridade e tamanho mínimo para o estabelecimento de uma região. A imposição de graus de similaridade muito baixos cria um número muito grande de

fragmentos na imagem original. Como a outra variável definida é o tamanho mínimo de uma região, se esta definir áreas muito grandes, haverá um reagrupamento de fragmentos, formando polígonos muito heterogêneos. O oposto, graus de similaridade altos e área mínima muito pequena, também culminará com a formação de fragmentos heterogêneos (INPE, 1996).

Os valores ótimos, a serem fixados para a segmentação de imagens, dependem, principalmente, dos padrões de repartição espacial dos objetos de cada área. Não existe, portanto, uma padronização de valores destas variáveis para a obtenção de bons resultados. Neste trabalho, foram feitas várias aproximações, até a obtenção de um nível de fragmentação da imagem considerado adequado para o estudo.

5.2.4 CLASSIFICAÇÃO DA IMAGEM

Classificar uma imagem espectral consiste em atribuir a cada pixel que compõe a imagem, um grupo ou uma classe. Cada superfície possui características específicas e apresenta um comportamento específico ao longo do espectro eletromagnético, o que permite sua identificação.

O procedimento metodológico de classificação baseia-se em dois processos distintos, mas que de certa forma se complementam. O primeiro método utilizado, de classificação não supervisionada, é muito dependente da automação computacional, uma vez que um algoritmo trata de aglomerar regiões dentro de uma mesma variação espectral. O segundo processo, classificação supervisionada, é controlada através da seleção de um conjunto de regiões que representasse determinada classe. Foi um processo de seleção de amostras.

Em uma primeira fase, o método não supervisionado foi utilizado para selecionar áreas espectralmente homogêneas, que foram utilizadas, em uma segunda fase, como áreas de treinamento para a classificação supervisionada.

A classificação não supervisionada se destina a definir as classes espectrais presentes na imagem. Na classificação por regiões, são formadas regiões espectralmente

homogêneas. Estes grupos/regiões, equivaleriam a pixels com um comportamento espectral homogêneo e, portanto, deveriam definir classes temáticas de interesse.

A técnica de classificação não supervisionada irá auxiliar na seleção das áreas de treinamento na imagem.

A única hipótese adotada para os dados é a de que eles obedeçam uma distribuição normal k -variada, onde k é o número de bandas considerado. Isto é, a distribuição da observação em cada pixel é dada pela expressão:

$$\frac{1}{(2\pi|C|)^{k/2}} \exp\left(-\frac{1}{2}(y - \mu)^T C^{-1}(y - \mu)\right) \quad (12)$$

onde $|C|$, denota o determinante da matriz de covariâncias C , e μ é o vetor de médias.

Assim, pode-se definir a distância de *Mahalanobis* entre dois pontos x e y como:

$$(y - x)^T C^{-1} (y - x) \quad (13)$$

Supondo-se também válida a independência entre diferentes observações, então o valor da fórmula 13 é uma variável aleatória com distribuição X^2 (BINS et al, 1993). Empregando-se a tabela de X^2 com k graus de liberdade, é possível a hipótese do valor x ser uma ocorrência de uma certa distribuição normal multivariada. Desta forma, o valor x poderá ou não ser atribuído a uma certa classe, formando assim uma regra de decisão.

O algoritmo, descrito a seguir, utiliza a matriz de covariância e o vetor média das regiões para estimar os centros das classes. O algoritmo consiste, basicamente, de três etapas. Na primeira a lista de regiões é ordenada em ordem decrescente pela área. Espera-se que regiões com maior área sejam aquelas mais representativas da classe. O limiar de aceitação, dado em percentual, define a distância máxima de Mahalanobis a qual as regiões podem estar afastadas do centro da classe para serem consideradas como pertencentes a esta classe. De outra forma, pode-se dizer que este limiar define um hiperelipsóide no espaço de atributos de tal forma que todas as regiões, cujas médias estiverem dentro dele serão consideradas como pertencentes a uma dada classe. Os valores das distâncias para cada percentual estão definidas na tabela do X^2 .

A segunda etapa envolve a detecção das classes iniciais. O procedimento é o seguinte: toma-se os parâmetros estatísticos da primeira região na lista, como sendo os parâmetros iniciais da classe. Em um processo iterativo, remove-se da lista todas as regiões cuja distância de Mahalanobis da classe seja inferior ao limiar de aceitação. Os novos parâmetros estatísticos da classe são recalculados. Este processo é repetido até que não haja mais nenhuma remoção de regiões da lista. As próximas classes são reconhecidas da mesma forma, até que a lista de regiões fique vazia.

Na etapa anterior pode ocorrer que uma dada região tenha sido classificada erroneamente. Na terceira etapa, as regiões são reclassificadas segundo os centros definidos na etapa anterior, para corrigir eventuais distorções.

A classificação supervisionada necessita de um conjunto inicial de informações sobre as classes a serem classificadas. Esses conjuntos iniciais são denominados de áreas de treinamento.

As áreas de treinamento devem ser selecionadas na imagem levando em consideração informações disponíveis sobre a vegetação da região, dados de campo, mapas e a classificação executada na etapa anterior.

Alguns procedimentos devem ser adotados a fim de selecionar áreas de treinamento representativas: a) as amostras com número de pixels suficientemente grande para permitir a estimativa das características espectrais das classes a serem mapeadas ; b) área de treinamento mais homogêneas possíveis; c) avaliação do histograma de cada amostra a fim de manter a distribuição mais próxima possível da normal; d) interpretação prévia da imagem e de levantamentos de campo (NOVO, 1992; LAUER, 1994; FULLER, GROOM & JONES, 1994).

O classificador utilizado será o que utiliza a distância *Bhattacharya*. Ele é um classificador supervisionado utilizado para classificar imagens segmentadas, ou seja, o objeto a ser classificado não é necessariamente um pixel, mas uma região da imagem. As fases deste processo de classificação são semelhantes às mesmas fases do processo de classificação supervisionada de pixels. No treinamento, cada classe será caracterizada pela coleta de segmentos de imagem a ela pertencentes. Cada segmento contém informações estatísticas sobre os pixels nele contidos (vetor de médias e matriz de covariâncias). Uma classe que contém N segmentos pode ser vista como sendo composta de N subclasses,

cada uma com o mesmo vetor de médias, (calculado como a média ponderada dos vetores de médias dos segmentos) e com matriz de covariância igual à matriz de covariância de cada segmento. Na fase de classificação, cada segmento será associado à classe mais próxima. Neste caso, tanto o segmento como cada classe (subclasse) são massas de dados e, para medir a proximidade, usa-se uma medida de distância que não é pontual (como a euclidiana), mas uma medida que compara conjunto de dados. É o caso da distância *Bhattacharya*. Esta medida é tradicionalmente utilizada como medida de separabilidade entre classes para fins de seleção de atributos de imagens. Esta medida pode ser calculada da seguinte forma:

$$B = \frac{1}{8}MH + \frac{1}{2} \ln \left[\frac{((C_a + C_b))/2}{((C_a || C_b))^{1/2}} \right] \quad (14)$$

onde:

C_a e C_b , são as matrizes de covariâncias das classes A e B;

MH é a distância Mahalanobis definida para duas classes distintas segundo a equação:

$$MH = \left[(\mu_a - \mu_b)^T \left(\frac{C_a + C_b}{2} \right)^{-1} (\mu_a - \mu_b) \right] \quad (15)$$

onde, μ se refere às médias das respectivas classes.

5.2.5 PRECISÃO DA IMAGEM CLASSIFICADA

Para verificar se as informações que compõem o mapa de vegetação possuem confiabilidade temática, faz-se necessário avaliar a precisão, ou acurácia, da classificação.

O método tradicional de verificação da precisão de uma classificação utiliza uma matriz de erros ou tabela de contingência (CONGALTON et al, 1983). Esta tabela é o resultado da seleção de áreas de teste na imagem e a comparação destas com tipo de cobertura existente no local correspondente no campo. A matriz de erros representa a tabulação dos erros cometidos na classificação e usualmente toma a forma da Tabela 6,

onde as linhas representam as classes existentes no campo durante a verificação, e as colunas representam as classes determinadas no projeto.

Classes	Dados de Referência (Dados de campo)					Total
	j = 1	j = 2	j = k		
i = 1	X ₁₁		:		X _{1k}	X _{1*}
:	:		:		:	:
:	:		:		:	:
:	:		X _{ij}		:	X _{i*}
:	:		:		:	:
:	:		:		:	:
i = k	X _{k1}		:		X _{kk}	X _{k*}
Total	X _{*1}				X _{*k}	X _{**}

Tabela 5: Exemplo de uma Matriz de erro

Na matriz de erros, a diagonal principal contém o número de pixels corretamente classificados para cada categoria. A última coluna totaliza os pixels de referência para cada classe. A última linha totaliza o número de pixels atribuídos a determinada categoria.

6. RESULTADOS EXPERIMENTAIS

Neste capítulo, são apresentados os resultados experimentais que ilustram a aplicabilidade do método desenvolvido. Inicialmente, na Seção 6.1, são apresentados alguns detalhes relativos a escolha da imagem a ser utilizada. A seguir, na Seção 6.2, é apresentada algumas considerações relativas à definição da escala de trabalho. Na Seção 6.3, é apresentada a área piloto selecionada para a execução dos experimentos. A seção 6.4 apresenta a definição das classes temáticas. Finalmente, na Seção 6.5, é realizado o processamento digital e são mostrados os resultados visuais da segmentação e classificação da imagem.

6.1 ESCOLHA DAS BANDAS DE INFORMAÇÃO DO SATÉLITE

A escolha das bandas para o desenvolvimento deste trabalho foi feita com base na análise de diversas publicações e nas características individuais de cada banda do satélite Landsat 5. LILLESAND (1994) especifica algumas potencialidades para cada uma das sete bandas deste satélite, como mostra a Tabela 1.

As imagens selecionadas para a execução do trabalho foram as referentes à banda 3, 4 e 5. Essas bandas foram selecionadas por apresentarem um maior número de informações, tendo em vista a finalidade deste trabalho.

O nível de correção foi o referente à reamostragem pela técnica do “vizinho mais próximo”, pois esta técnica não altera o valor original do pixel.

6.2 DEFINIÇÃO DA ESCALA DE TRABALHO

Foi definida a escala cartográfica 1:50.000 para expressão dos resultados. Esta seleção considerou características como padrão de fragmentação, heterogeneidade da paisagem e o nível generalizado desejado para o mapeamento final.

Segundo a Tabela 4, a escala espacial mais indicada para se trabalhar com imagens do satélite Landsat 5 (sensor TM) seria 1:100.000. Apesar disto, optou-se por uma abordagem na escala 1:50.000, considerada uma escala limite para os produtos Landsat-TM.

6.3 ESCOLHA DA ÁREA PILOTO

A escolha da área de estudo teve por premissa básica selecionar uma área heterogênea sob o ponto de vista da forma de ocupação, com a intenção de submeter o segmentador e o classificador a uma série de situações diferentes, para os mesmos tipos de cobertura, e com isso verificar seu comportamento e medir o desempenho do processo automático de mapeamento através da utilização da combinação desses métodos.

O ajuste mais fino da área, para execução do projeto, foi feito através da observação da carta Topográfica de Palotina (DSG, 1998), visando a escolher um fragmento onde houvesse uma densa rede de estradas e caminhos, viabilizando a visitação de grande parte de sua extensão. As dimensões desse fragmento foram estabelecidas procurando envolver o maior número de situações de relevo e uso das terras, sem, contudo, desequilibrar a relação custo/benefício deste trabalho.

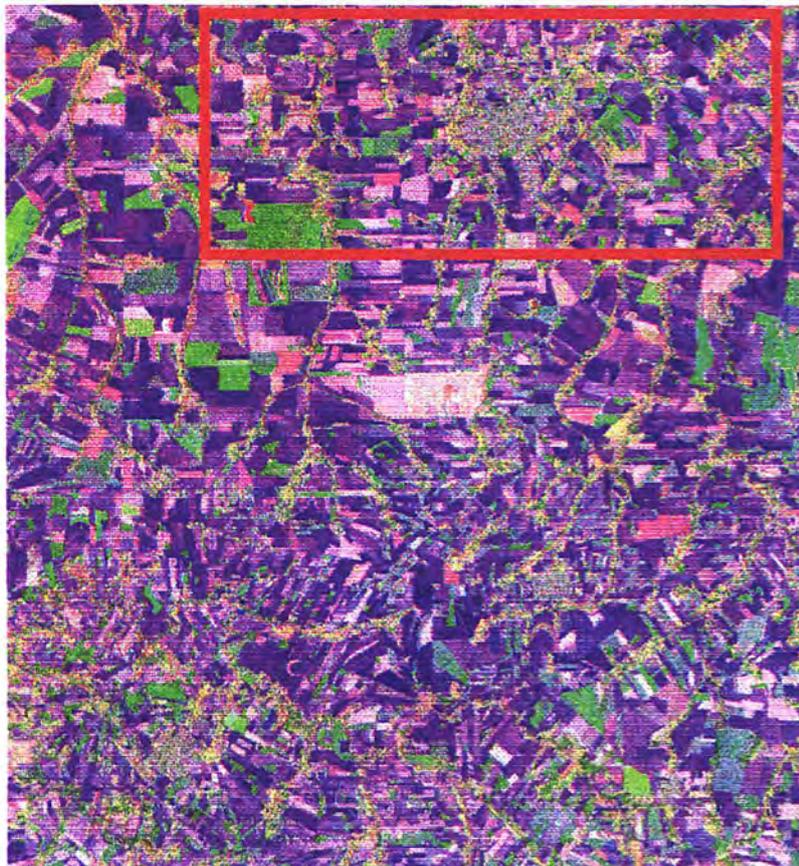


Figura 18 : Região do Município de Palotina
Fonte: COPEL, 1998

6.4 DEFINIÇÃO DAS CLASSES TEMÁTICAS

Para a execução deste trabalho, foram definidas as oito classes abaixo listadas, de cobertura vegetal e usos das terras. Foram observadas as principais formas de uso presentes, destacando as classes:

Área urbanizada: caracterizada pela presença de algumas edificações;

Matas: pequenos fragmentos, remanescentes da vegetação original da área. Esta categoria procurou envolver desde os remanescentes maiores, como a reserva do IAPAR (Instituto Agrônômico do Paraná), até pequenos fragmentos localizados em propriedades particulares.

Solo Exposto: esta classe caracteriza-se pela total inexistência de cobertura vegetal. Normalmente, trata-se de uma área que já sofreu a colheita ou está sendo preparada para o plantio.

Cultura Estágio 1: esta classe caracteriza-se pelo fato de, aproximadamente, 75% do solo estar exposto. Os 25% restantes tratam-se de área coberta pela cultura de milho/soja em seu estágio inicial de desenvolvimento, isto é, as plantas possuem de 10 a 20 cm de altura.

Cultura Estágio 2: nesta classe a cultura está cobrindo 50% do solo e as plantas possuem mais de 30 cm de comprimento.

Cultura Estágio 3: A área da cultura cobre 75% do solo. As plantas estão em seu nível intermediário de desenvolvimento.

Cultura Estágio 4: nesta classe a área das folhas cobrem 100% da área. Não é mais possível se observar o solo.

Vegetação Ciliar: vegetação que acompanha o traçado dos rios. Em alguns locais as árvores são bastante altas e em outros trata-se de vegetação rasteira.

Existem ainda outros tipos de classes na região em estudo. São elas: pastos e soja. Tendo em vista que não possuem muita representatividade, isto é, sua existência se restringe a 4 locais em toda a cena, elas não foram consideradas.

6.5 PROCESSAMENTO DIGITAL

6.5.1 LEITURA DA IMAGEM

A área de interesse deste trabalho, com aproximadamente 700 km² e delimitada na carta topográfica “Folha Palotina” MI-2.800/3 ou SG.22-V-A-I-3, escala 1:50.000 (DSG, 1998), representou apenas uma parte da cena da imagem, que cobre uma superfície de aproximadamente 185x185 Km. Para a leitura do fragmento da imagem, correspondente à área escolhida, foram estimadas e fornecidas as coordenadas aproximadas e a imagem foi gravada em disco.

6.5.2 REGISTRO DA IMAGEM COM A CARTA BASE

Para o registro da imagem com a carta base, foram selecionados diversos pontos notáveis de coordenadas conhecidas. As coordenadas destes pontos podem ser calculadas matematicamente a partir da carta ou através da utilização de um GPS.

Para este trabalho foram utilizados 6 (seis) pontos. A grande precisão e correspondência existente entre os pontos obtidos na carta topográfica e os encontrados na imagem de satélite (Figura 19), foi responsável pelo reduzido número de pontos necessários para o registro da imagem com erros considerados bastantes baixos (Tabela 6).



Figura 19: Pontos de controle utilizados no registro da imagem de satélite

Os erros associados aos pontos de controle indicam a diferença, em pixels, existente entre a localização da coordenada, calculada através da carta topográfica no ato da aquisição do ponto de controle, e a posição calculada para o mesmo ponto ao final do processo de registro da imagem (INPE, 1996).

PONTOS DE CONTROLE	ERRO HORIZONTAL / VERTICAL (pixel)
1	0.170 / 0.053
2	0.423 / 0.168
3	0.335 / 0.211
4	0.515 / 0.155
5	0.280 / 0.155
6	0.492 / 0.056

Tabela 6 : Erros associados aos pontos de controle, fornecidos durante o processo de registro da imagem.

Como os erros detectados foram, na sua grande maioria, inferiores a 0.5 pixels, valor tido como satisfatório para este tipo de operação (INPE, 1996), os 6 pontos fornecidos foram considerados suficientes para o registro e correção geométrica de toda a

imagem. O ponto número 4, apesar de manifestar um erro de 0.515 pixels no eixo Leste-Oeste, foi considerado no cálculo final, pois o deslocamento no eixo Norte-Sul foi de 0.155.

6.5.3 MANIPULAÇÕES DE CONTRASTE

Neste ponto, a técnica de realce de contraste visou a equalizar as bandas, de forma a permitir que todas exercessem influência semelhante no processo de segmentação de imagem.



Figura 20 : Palotina banda 3

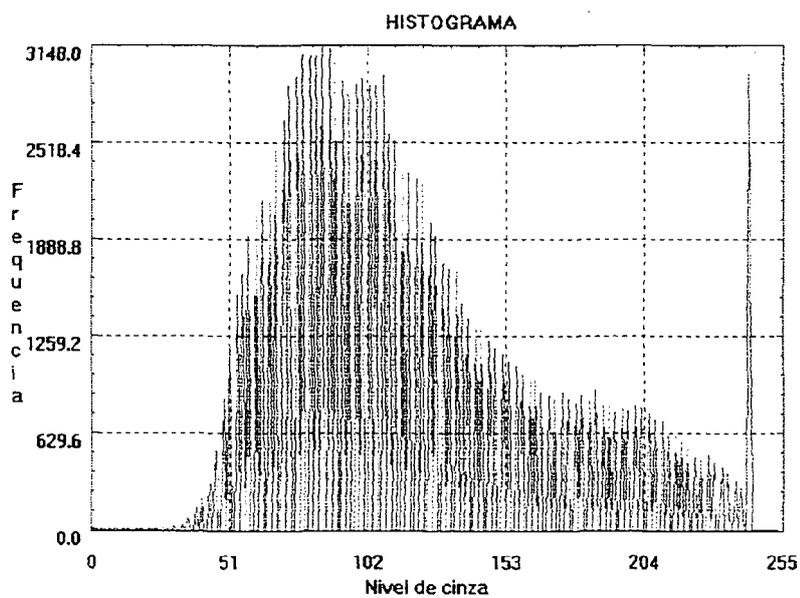


Figura 21 : histograma da banda 3



Figura 22: Palotina banda 4.

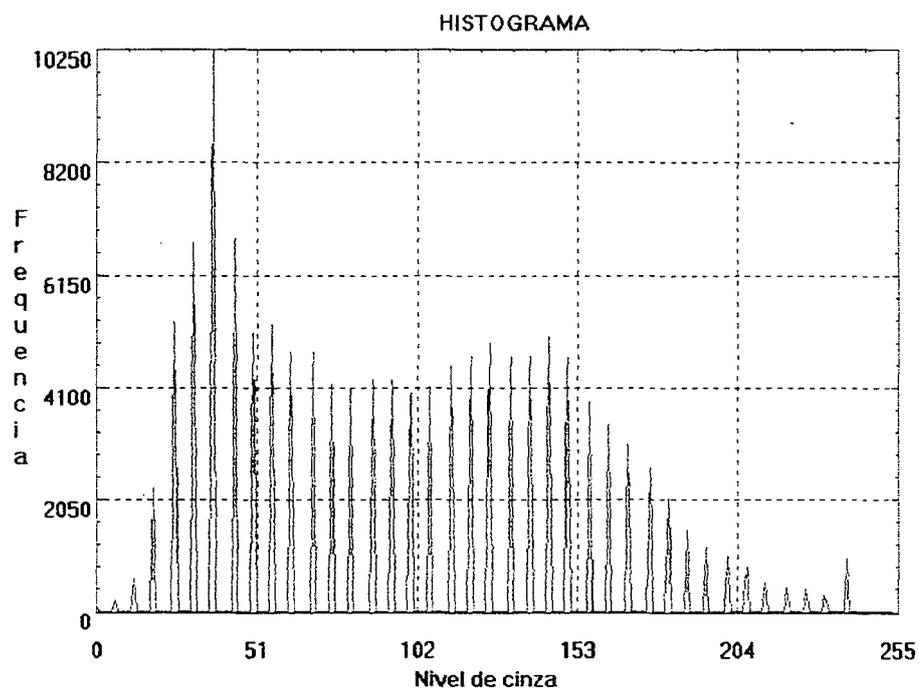
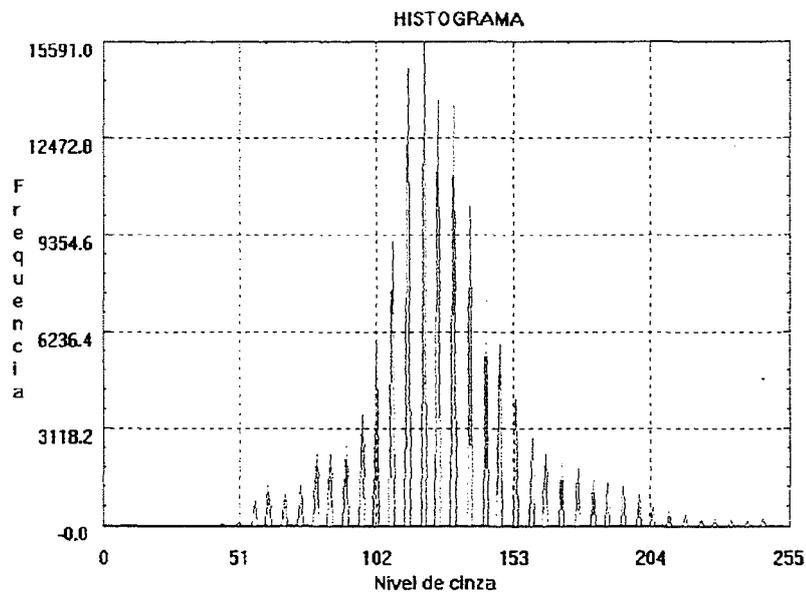


Figura 23 : Histograma da banda TM4



Figura 24: Palotina Banda 5



Figurar 25 : Histograma da banda 5

	MEDIA	DESVIO PADRÃO	VARIÂNCIA
BANDA 3	119.33	49.69	2468.85
BANDA 4	97.17	53.43	2855.07
BANDA 5	127.55	28.32	801.84

Tabela 7: Dados relativos a média, desvio padrão e variância de cada banda

Como demonstrado nas Figuras 20 a 25 e na Tabela 8, a banda 5 foi a que apresentou um histograma de distribuição menos abrangente, em relação aos 256 níveis de cinza possíveis (imagem de alto contraste), e as bandas 3 e 4 apresentaram histogramas de distribuição de pixels mais largos.

Foi necessário redistribuir os níveis de cinza das bandas 3, 4 e 5, de forma a abranger os 256 níveis de cinza possíveis em cada uma delas. A operação envolvida na correção dos níveis de cinza foi, inicialmente a equalização dos três histogramas, seguida de um ajuste linear sobre a banda 4.

Após a manipulação do contraste de todas as bandas da imagem, teremos os dados representados na Tabela 9:

	MÉDIA	DESVIO PADRÃO	VARIÂNCIA
BANDA 3	130.09	72.47	5251.54
BANDA 4	137.70	73.56	5411.66
BANDA 5	135.89	72.82	5304.55

Tabela 8: Momentos das bandas após manipulação do contraste

6.5.4 SEGMENTAÇÃO DA IMAGEM

Neste trabalho, foram feitas várias aproximações, até a obtenção de um nível de fragmentação da imagem considerado adequado para o estudo.

Após a definição das combinações das variáveis índice de similaridade e tamanho mínimo dos polígonos, utilizadas pelo segmentador, foram produzidas algumas imagens segmentadas, para a detecção do nível de fragmentação mais adequado à escala de abordagem e à realidade de campo.

As Figuras 26 a 29 mostram vários níveis diferentes de fragmentação, obtidos através da aplicação de combinações diferentes das variáveis apresentadas pelo segmentador. A combinação escolhida (Figura 29), ilustra a situação mais próxima à ideal, visto que os polígonos aí definidos não são muito heterogêneos, as áreas mínimas mapeáveis estão próximas do desejado, considerando-se a escala de expressão dos dados e o nível de fragmentação da paisagem observado em campo. Na Figura 29 foram determinados 1162 polígonos.

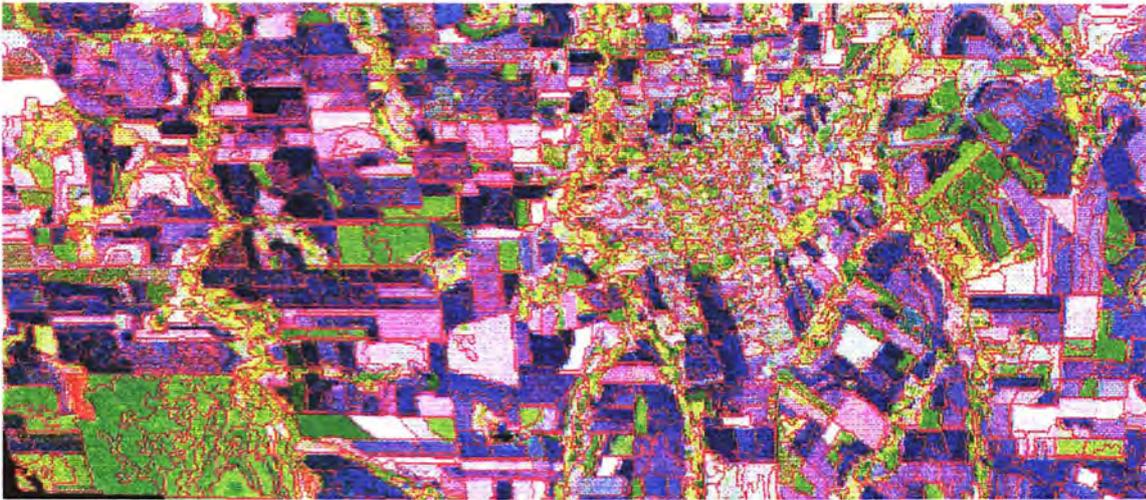


Figura 26 : Segmentação com grau de similaridade 15 e área mínima de 40 pixels.

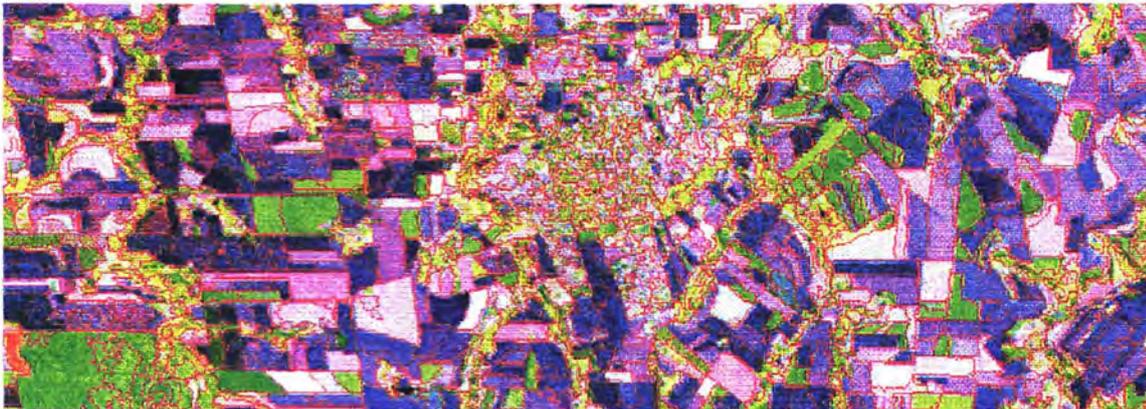


Figura 27: Segmentação com grau de similaridade 20 e área mínima de 40 pixels.

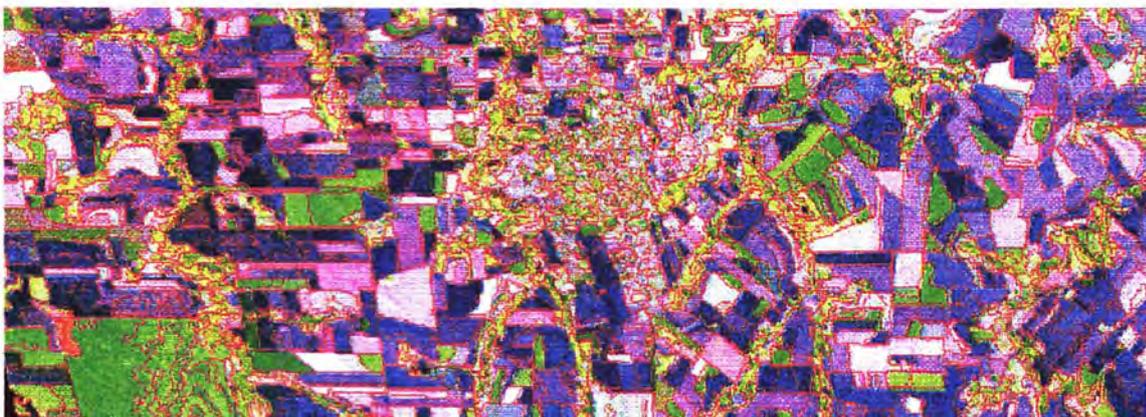


Figura 28: Segmentação com grau de similaridade 30 e área mínima de 30 pixels



Figura 29 : Segmentação com grau de similaridade 35 e área mínima de 40 pixels

6.5.5 CLASSIFICAÇÃO DA IMAGEM

Esta fase foi subdividida em outras duas: a classificação não supervisionada e a classificação supervisionada.

O objetivo da classificação não supervisionada foi, através da aplicação de um algoritmo de classificação não supervisionada, definir as classes espectrais presentes na imagem. Posteriormente, algumas amostras de cada classe foram utilizadas como áreas de treinamento.

O classificador não supervisionado por regiões (ISOSEG) é um algoritmo de agrupamento de dados não-supervisionado, aplicado sobre um conjunto de regiões, que por sua vez são caracterizadas por seus atributos estatísticos de média e matriz de covariância, e também pela área (INPE, 1996). O método utiliza a distância *Mahalanobis*, que é similar à distância mínima, exceto pelo fato da utilização da matriz de covariância. Variância e covariância são utilizadas, visto que *clusters* que possuem uma variância muito alta pertencem a uma classe que também apresenta uma variância alta.

DISTÂNCIA	MAHALANOBIS
VANTAGENS	DESVANTAGENS
Leva em consideração a variância das classes.	Se existe uma dispersão muito grande de pixels em cluster, então a matriz de covariância também conterá valores altos.
Pode ter uma maior utilidade do que o método da mínima distância em casos em que critérios estatísticos tenham que ser levados em consideração.	Demora mais tempo para ser calculado do que o método da mínima distância .

Tabela 9: Vantagens e desvantagens da utilização da distância Mahalanobis

Após o algoritmo ser aplicado sobre a região alvo, obteve-se o resultado apresentado na Figura 30:



Figura 30 : Imagem classificada após aplicação do algoritmo ISOSEG

A partir da imagem segmentada e após a utilização deste algoritmo, obtiveram-se 24 regiões ou classes, cujos respectivos pixels apresentam características espectrais semelhantes. O algoritmo de agrupamento permitiu reunir pixels espectralmente muito próximos. A imagem contendo os agrupamentos serviu como referência no processo supervisionado de classificação.

Para a execução da classificação supervisionada, houve a necessidade de serem selecionadas áreas de treinamento para a realização da classificação.

As áreas de treinamento foram selecionadas na imagem levando em consideração informações disponíveis sobre a vegetação da região, dados de campo, mapas e as áreas espectralmente similares identificadas na fase anterior.

As áreas de treinamento foram coletadas da imagem nas composições coloridas das bandas 3, 4 e 5. As amostras ou áreas de treinamento, foram delimitadas através de digitalização de um ou mais polígonos na imagem. Estes foram compostos por pixels que apresentavam determinada homogeneidade espectral.

O resultado da classificação pode ser observado na Figura 31.

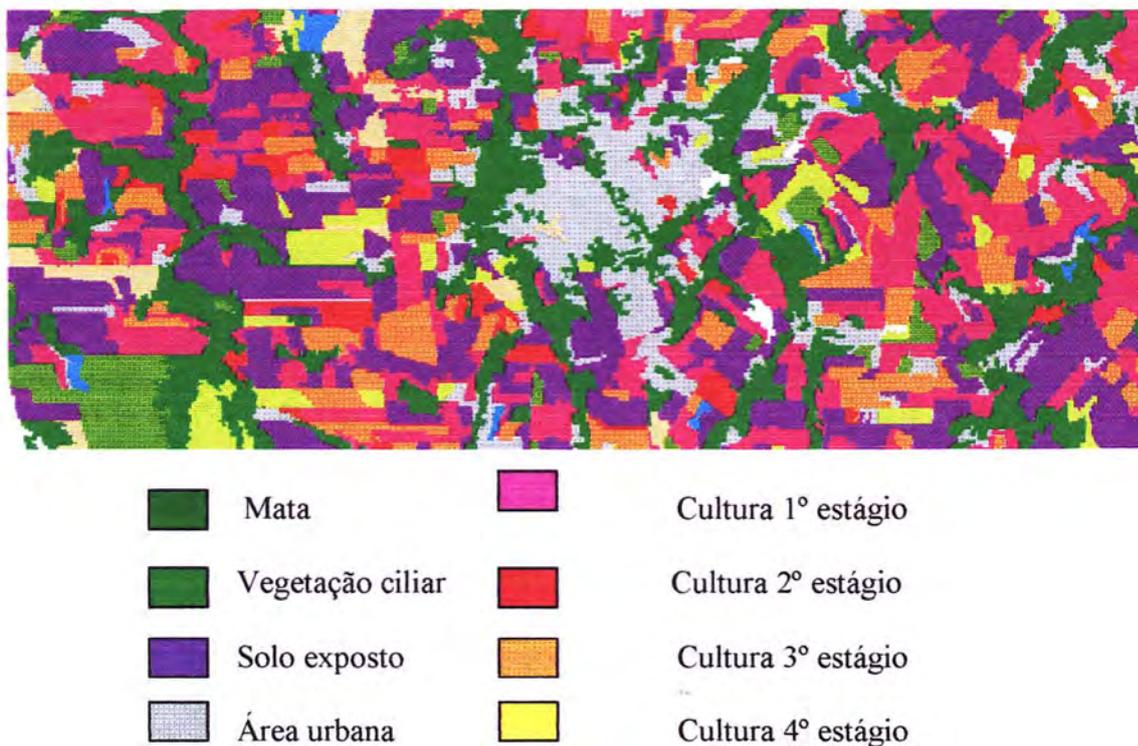


Figura 31: Imagem após a classificação supervisionada

7. CLASSIFICAÇÃO PIXEL-A-PIXEL X CLASSIFICAÇÃO POR REGIÕES

7.1 CLASSIFICAÇÃO PIXEL-A-PIXEL

O método também se aplica a este tipo de classificação. O único detalhe que deve ser observado é que não existe a etapa de segmentação. As outras fases são idênticas a da classificação por regiões.

7.1.1 CLASSIFICADOR ISODATA

O termo ISODATA se refere a “*Iterative Self-Organizing Data Analysis Technique*”. É iterativo, isto é, executa repetidamente a classificação e recalcula os dados estatísticos. “*Self-Organizing*” se refere ao modo como os “*clusters*” são estabelecidos com um mínimo de dados de entrada.

O método ISODATA usa a distância espectral mínima para associar um pixel candidato a cada “*cluster*”. O processo inicia um número específico de *clusters* e então ele executa de maneira repetitiva, procurando determinar a nova média dos *clusters*.

Foram realizados testes com vários valores diferentes de iterações e número de classes iniciais. O que apresentou os melhores resultados foi um número inicial de classes igual a 26 e um número de 20 iterações (Figura 32).

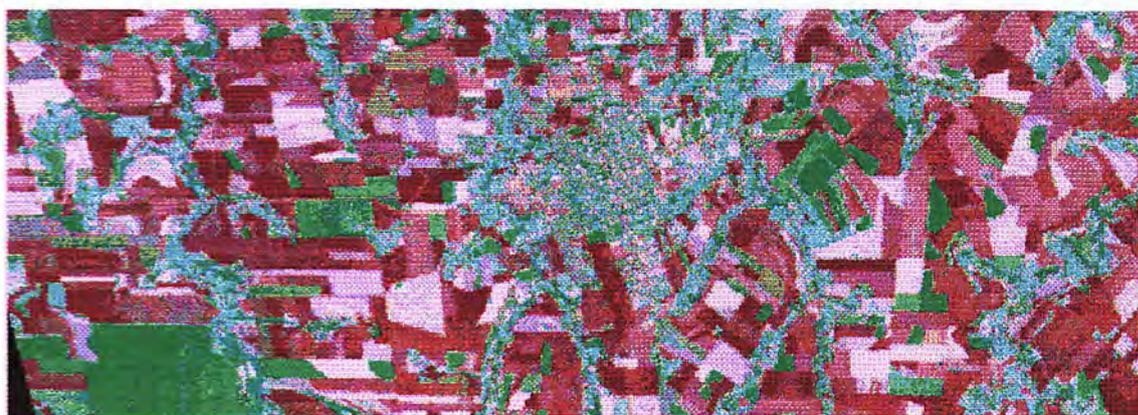


Figura 32: Imagem classificada utilizando o ISODATA

A Tabela 11 apresenta as vantagens e desvantagens deste método.

VANTAGENS	DESVANTAGENS
Não faz diferença onde os valores médios dos clusters iniciais estão localizados, o importante é que um número suficientes de iterações seja executado.	Este método pode ser repetido por diversas iterações, tornando-o, desta forma, de elevado custo computacional.
	Não leva em consideração a homogeneidade espacial do pixel

Tabela 10: Vantagens e desvantagens do ISODATA

7.1.2 CLASSIFICAÇÃO SUPERVISIONADA

Para a classificação supervisionada foram testadas duas técnicas: a da distância mínima e a da máxima verossimilhança.

O método da distância euclidiana ou distância mínima tende a minimizar a distância de um determinado pixel a ser classificado e o centróide de uma classe. Logicamente não se trata de distância geográfica, e sim espectral. O método compara o nível de cinza de cada pixel com os centros das diversas categorias, procedimento este feito para todas as bandas que intervêm na análise.

A equação para se realizar a classificação através da distância espectral é baseada na equação euclidiana .

As Figuras 33 e 34 apresentam a imagem classificada e a imagem mapeada, respectivamente.

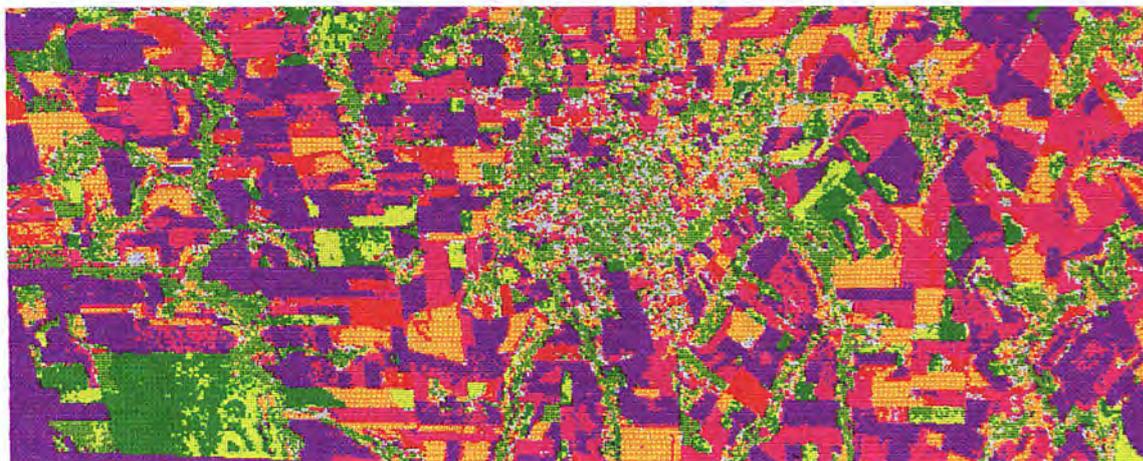
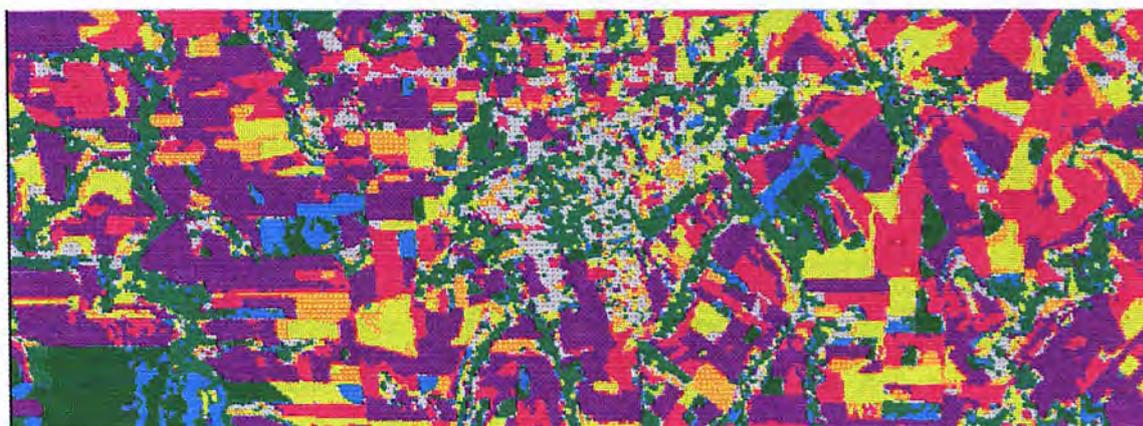


Figura 33 : imagem classificada pelo método da distância mínima



	Mata		Cultura 1º estágio
	Vegetação ciliar		Cultura 2º estágio
	Solo exposto		Cultura 3º estágio
	Área urbana		Cultura 4º estágio

Figura 34: Mapeamento final

VANTAGENS	DESVANTAGENS
Visto que cada pixel está espectralmente próximo de qualquer classe, não ocorrerá o caso de pixels não classificados.	Pixels que deveriam permanecer não classificados (isto é, não estão espectralmente próximos das médias de qualquer classe, dentro de um limiar estabelecido) serão classificados. A solução seria estabelecer um limiar a partir do qual os pixels seriam rotulados como desconhecidos.
É o método mais rápido.	Não considera a variância de uma classe. Por exemplo, a área urbana que é formada por pixels que apresentam uma variância muito alta, tende a ter um maior afastamento em relação a média.

Tabela 11: Vantagens e desvantagens do método da distância mínima.

O método da máxima verossimilhança é baseado na probabilidade do pixel pertencer a uma classe em particular. A equação básica assume que estas probabilidades são iguais para todas as classes e que as bandas possuem uma distribuição normal.

As Figuras 35 e 36 apresentam a imagem classificada e a imagem mapeada, respectivamente.



Figura 35 : Imagem classificada pela técnica Maxver

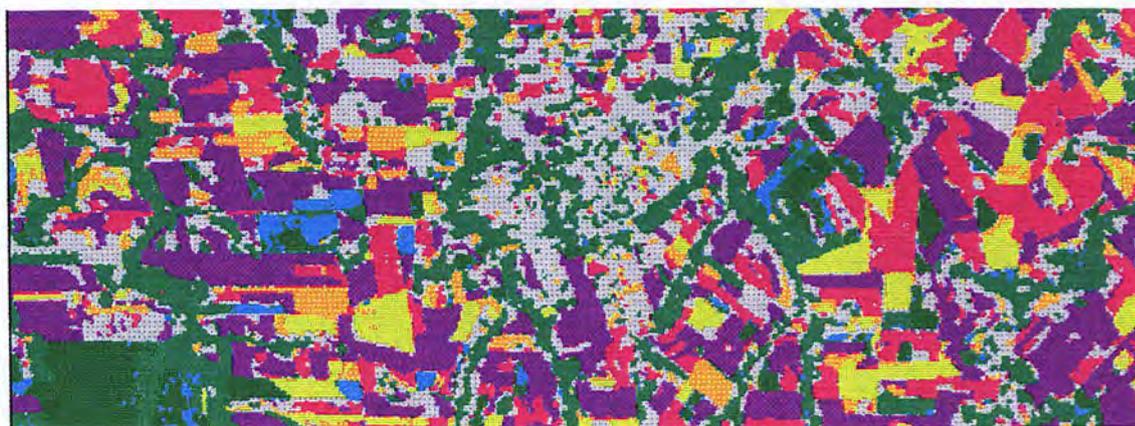


Figura 36 : Mapeamento final

VANTAGENS	DESvantagens
Se as amostras possuírem distribuição normal, é o método mais preciso dentre os classificadores pixel-a-pixel.	O cálculo é muito complexo, tornando-se custoso em termos computacionais. O tempo de processamento é proporcional ao número de bandas.
Leva em consideração a variância das classes, através da utilização de uma matriz de covariância.	Se a dispersão dos pixels nos clusters ou amostras forem grandes, a matriz de covariância daquela classe conterá valores grandes.

Tabela 12: Vantagens e desvantagens da Maxver.

7.1.3 PRECISÃO DA IMAGEM CLASSIFICADA

As Tabelas 14 e 15 apresentam as matrizes de erros referentes aos diferentes métodos de classificação:

	mata	solo	Est 1	Est 2	Est 3	Est 4	ciliar	urbana	Rej
Mata	94,12%	0	0	0	0	5,88%	0	0	0
Solo	0	100%	0	0	0	0	0	0	0
Est 1	0	0	98,13%	0	0	0	0	1,87%	0
Est 2	0	0	0,32%	90,35 %	6,43%	0	0,32%	2,57%	0
Est 3	0	0	0,20%	1,39%	97,43 %	0	0	0,99%	0
Est 4	10,62%	0	0	0	0	87,50%	1,88%	0	0
Ciliar	2,12%	0	0,47%	1,18%	0	1,41%	84,94%	9,88%	0
Urbana	0	0	6,75%	11,55 %	2,40%	0,22%	14,38%	64,71%	0

Tabela 13 : Matriz de erros método MaxVer

	mata	solo	Est 1	Est 2	Est 3	Est 4	ciliar	urbana	Rej
Mata	92,08%	0	0	0	0	7,92%	0	0	0
Solo	0	99,31 %	0,69%	0	0	0	0	0	0
Est 1	0	0,51 %	82,35%	15,09 %	0,77%	0	0	1,28%	0
Est 2	0	0	1,31%	94,10 %	0	0	1,31%	3,28%	0
Est 3	0	0	0	2,17%	97,71 %	0	0	0,13%	0
Est 4	47,32%	0	0	0	0	45,85%	4,39%	2,44%	0
Ciliar	17,32%	1,72 %	0,81%	1,20%	9,47%	3,61%	58,52%	3,61%	0
urbana	6,84%	1,05 %	13,42%	11,53 %	9,01%	0,42%	17,61%	46,12%	0

Tabela 14: Matriz de erros método da Distância Euclidiana

MÉTODO	MaxVer	Dist Euclid
DESEMPENHO MEDIO(%)	87,77	80,17

Tabela 15 : Comparação entre os métodos

7.2 TABULACÃO CRUZADA

Como pode ser observado na Tabela 16, o método de classificação supervisionada através da técnica da máxima verossimilhança foi a que apresentou o maior percentual de acerto. Os resultados obtidos por essa técnica foram comparados com os resultados obtidos pela técnica de classificação por regiões. Esta comparação foi feita através da verificação da porcentagem de concordância entre a técnica de segmentação e o algoritmo de máxima verossimilhança, isto é, qual o percentual de pixels classificados pela técnica de segmentação que foram igualmente classificados pela técnica de agrupamento. Os resultados obtidos são mostrados na Tabela 17.

	Concordância(%)
Mata	77,27
Solo	87,97
Est 1	69,94
Est 2	57,82
Est 3	75,26
Est 4	68,01
Veg Ciliar	58,37
Área urbana	44,39

Tabela 16: Porcentagem de concordância

A concordância média, levando em consideração toda a imagem, foi de aproximadamente 70%.

8. EQUIPAMENTOS E SOFTWARES

O equipamento utilizado possuía a seguinte configuração: PC INTEL 166 MMX, 48 MB de memória RAM e 2.1 GB (gigabytes) de memória em disco rígido. Recomenda-se a utilização de equipamentos com um configuração superior à utilizada para se obter uma maior rapidez na fase de processamento.

Os *softwares* utilizados foram os seguintes:

- a) SPRING, Sistema de Processamento de Imagens Georeferenciadas versão 3.0 – concebido pelo Instituto Nacional de Pesquisas Espaciais em ambiente *WINDOWS* e *UNIX*. Incorpora funções de processamento digital e Sistema de Informações geográficas (SIG).
- b) ERDAS, Imagine versão 8.4 – concebido em ambiente *WINDOWS* para processar dados *raster* (pixels). No âmbito da Universidade Federal do Paraná, este software se encontra disponível no Centro Integrado de Estudos de Geoprocessamento (CIEG).

9. DISCUSSÃO E CONCLUSÃO

Neste trabalho, foi apresentada uma metodologia híbrida de classificação temática de imagens do satélite Landsat, sensor TM. O procedimento metodológico de classificação baseia-se em dois processos distintos mas que, de certa forma, se complementam. O primeiro processo utilizado, de classificação não supervisionada, é muito dependente da automação computacional, um vez que um algoritmo trata de aglomerar regiões dentro de uma mesma variação espectral sem a intervenção do usuário. O segundo processo, classificação supervisionada, é controlada através da seleção de um conjunto de regiões que representa determinada classe. Foi um processo de seleção de amostras.

Antes de ser iniciada a etapa de classificação, há a necessidade da segmentação da imagem. A técnica de segmentação tem por objetivo fragmentar uma região em unidades homogêneas, considerando algumas de suas características intrínsecas como por exemplo o nível de cinza dos pixels, textura e contraste. O algoritmo de segmentação utilizado é o de crescimento de regiões e depende de duas variáveis: grau de similaridade e tamanho mínimo da região.

Durante a etapa de segmentação foram feitas as seguintes aproximações (grau de similaridade/tamanho mínimo): 15/40, 20/40, 30/30, 35/40. O nível de fragmentação considerado adequado para o estudo foi aquele que representa um grau de similaridade de 35 e uma área mínima de 40 pixels. Após a definição das combinações das variáveis, foi produzida uma imagem segmentada para a verificação da adequação ou não do nível de fragmentação à escala de abordagem e a realidade de campo. Foram encontrados 1162 polígonos.

Para a etapa de classificação não supervisionada foi utilizado um algoritmo de classificação por regiões que possui como critério a distância *Mahalanobis*, que é similar a distância mínima, exceto pelo fato da utilização da matriz de covariância. Durante os testes foram encontradas 24 regiões distintas, cujos pixels apresentam características espectrais semelhantes.

Na etapa de classificação supervisionada foram utilizadas amostras do produto da etapa anterior como áreas de treinamento. O critério utilizado nesta etapa foi a distância *Bhattacharyya*.

Pela análise dos resultados obtidos, verifica-se que a classe temática “área urbana” foi a que apresentou o menor percentual de eficiência, em termos de pixels classificados corretamente. Isto deve-se ao fato de que a área urbana da cidade de Palotina é muito bem arborizada, com árvores ultrapassando 10 (dez) metros de altura, e possui poucas edificações. A superfície asfáltica, em sua maior parte, é coberta pelas folhagens das árvores. Estas características peculiares da região contribuíram para o baixo desempenho na classificação desta classe e também interferiram, com menor intensidade, na classificação das classes temáticas referentes à mata e à vegetação ciliar.

O resultado obtido através da utilização da metodologia proposta não apresenta pixels isolados (como ruídos) ou não classificados, constituindo-se, desta forma, como uma vantagem sobre a classificação pixel-a-pixel. Da mesma forma, as áreas segmentadas apresentam poucas falhas.

A metodologia apresentada exigiu um menor esforço do usuário para obter resultados com os níveis de concordância apresentados na Tabela 17. Isto se deve ao fato da não exigência de ser gasto muito tempo em uma outra etapa de campo para a seleção de amostras, ocasionando, desta forma, uma economia considerável de tempo.

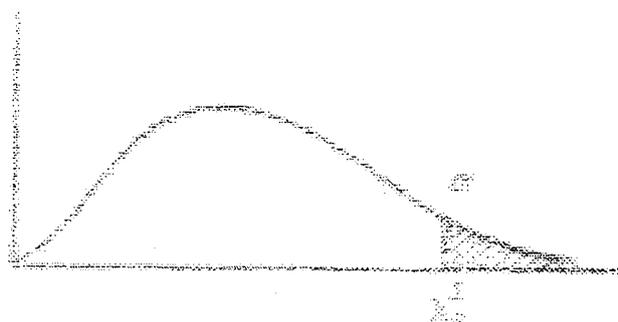
Para concluir, pode-se considerar que os resultados gerais apresentados pela utilização de uma classificação híbrida por regiões foram satisfatórios. A metodologia apresentada apresenta bom potencial para o uso em atividades similares à executada, podendo ser a base para a geração de mapas de uso da terra de uma forma mais rápida que a classificação convencional.

Para regiões caracterizadas por culturas vegetais sazonais, recomenda-se estudos sobre a dinâmica do uso e ocupação do solo, mapeando séries multitemporais para o seu melhor monitoramento.

Como trabalhos futuros, os seguintes temas podem ser explorados:

- (1) A elaboração de um mapeamento temático em 3-D através da elaboração de um modelo digital do terreno;

- (2) Utilização da metodologia apresentada na elaboração de um mapeamento de solos;
- (3) Elaboração de um levantamento estatístico através da aplicação da metodologia em diversas regiões distintas, com o objetivo de nortear a elaboração de mapas temáticos.
- (4) Utilização da metodologia apresentada para a realização de um mapeamento de uso e ocupação do solo.

ANEXO – Tabela de Distribuição χ^2 (chi-quadrado)

	Probabilidade de $X^2 \geq$ Qui-quadrado													
	0,99	0,98	0,95	0,90	0,80	0,70	0,50	0,30	0,20	0,10	0,05	0,02	0,01	0,001
1	0,000	0,000	0,003	0,016	0,064	0,15	0,46	1,07	1,64	2,71	3,84	5,41	6,64	10,83
2	0,02	0,04	0,10	0,21	0,45	0,71	1,39	2,41	3,22	4,60	5,99	7,82	9,21	13,82
3	0,12	0,18	0,35	0,58	1,00	1,42	2,37	3,66	4,64	6,25	7,82	9,84	11,34	16,27
4	0,30	0,43	0,71	1,06	1,65	2,20	3,36	4,88	5,99	7,78	9,49	11,64	13,28	18,46
5	0,55	0,75	1,14	1,61	2,34	3,00	4,35	6,06	7,29	9,24	11,07	13,39	15,09	20,52
6	0,87	1,13	1,64	2,20	3,07	3,83	5,35	7,23	8,56	10,64	12,59	15,03	16,81	22,46
7	1,24	1,56	2,17	2,83	3,82	4,67	6,35	8,38	9,80	12,02	14,07	16,62	18,48	24,32

REFERÊNCIAS BIBLIOGRÁFICAS

- 1 AIT BELAID, M; EDWARDS, G.; JATON, A., THOMSON, K.P.B.; BEAULIEU, J.M. **Pos-segmentation classification of images containing small agricultural fields.** In: Geocarto International, 1992. n. 3, p.53-60, 1992.
- 2 ALMEIDA, S. A. S. et al. **Mapeamento de cobertura da terra utilizando técnicas de Processamento de imagens na região de Arquimedes (RO), com ênfase às florestas secundárias.** São José dos Campos: INPE, 1995.
- 3 ALVES, D. S. et al. **Mapeamento do uso da terra em Rondônia utilizando técnicas de segmentação e classificação de imagens TM.** São José dos Campos: INPE, 1995.
- 4 ANDRADE, L. A. de. **Mapas temáticos utilizando dados do Sensor thematic mapper do satélite landsat.** Brasília: - Diretoria de Serviço Geográfico do Exército, 1985.
- 5 BARRETT, E. C.; CURTIS, L. **Introduction to environmental remote sensing.** Londres: Chapman & Hall, 1992.
- 6 BINS, L.S; ERTHAL, G. J.; FONSECA, L. M.G. **Três abordagens para segmentação de imagens de sensoriamento remoto.** In: VI Simpósio Latinoamericano de Percepción Remota. Cartagena, Colombia, 1993.
- 7 BOGNOLA, I. A.; MIRANDA, J.R. ; MANGABEIRA, J. A. de C.; TOLEDO, M.A., YOSHI, C. **Caracterização e mapeamento da adequabilidade do uso atual das terras no município de Jaguariúna - SP, com auxílio de geoprocessamento,** Campinas: EMBRAPA, 1997.
- 8 CELINSKI, T. M. **Métodos de agrupamento: uma abordagem comparativa com aplicação em segmentação de imagens de profundidade.** Curitiba, 1998. Dissertação (Mestrado em Informática) - Setor de Ciências Exatas, Universidade Federal do Paraná.
- 9 CHUVIECO, Emílio. **Fundamentos de teledeteccion espacial.** Madrid : Ed. RIALP, 1990.
- 10 CONGALTON, R. **A review of assensing the accuracy of classification remotely sensed data.** Remote sensing of environment, USA, nº 37, p.35-36. 1991.

- 11 CURRAN, Paul J. **Principles of remote sensing**. USA: Longman Scientific & Technical, 1992.
- 12 FULLER, R. M.; GROOM, G. B.; JONES, A. R. **The land cover map of Great Britain** – automated classification of landsat thematic mapper. USA: Photogrammetric Engineering and Remote Sensing, 1994. Vol. 60, nº 5, p. 553-562.
- 13 GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. New York: Ed. Addison-Wesley Publishing Company, 1993.
- 14 GONZALEZ, R. C, WINTZ, P. **Digital image processing**. Massachussets: Addison Wesley Publishing Company Inc, 1977.
- 15 INPE. Departamento de Processamento de Imagens. Manual de operação do SPRING: versão 2.0.1. São José dos Campos, SP. URL: file:/home/spring/help, outubro de 1996.
- 16 JAIN, Ramesh & Rangachar Kasturi . **Machine vision**. USA : McGraw-Hill Inc, 1995.
- 17 JANSEN, J. R. **Introductory digital image processing**. New Jersey: Prentice Hall, 1986.
- 18 JAIN, A. K., Dubes, R. C. **Algorithms for clustering data**. Englewood Cliffs, NJ: Prentice Hall, 1988.
- 19 KHODJA, A.; HOTYAT, M.; CHATELAIN, A.; GILG, J. P. **Partition d'une image satellitaire et caractérisation de son contenu par une méthode de segmentation d'images**: application à la forêt de Bouconne (France) et à la ville d'Oran (Algérie). Paris: Photo-Interpretation, 1995. n. 1995/1, p.25-30.
- 20 KHODJA, A.; MENGUE, A. **Amélioration de l'aport thématique d'une image SPOT XS par les processus spatiaux et une méthode de segmentation**: application à la région de Lagdo (Nord-Cameroun). London: International Journal of Remote Sensing, 1996. v.17, n.5, p.879-886.
- 21 LAUER, D. Production process for extracting information from satellite data. In: DENÉGRE, J. **Thematic mapping from satellite imagery guide book on behalf of International Cartographic Association**. Pergamon Press, 1994. P.32-46.
- 22 LEGUIZAMÓN, S. **Experiências com classificação no supervisada utilizando el algoritmo k-means**, Argentina, 1985.
- 23 LIPORACE, F. dos S. **Um sistema neural para monitoração do desflorestamento**

- na região amazônica utilizando imagens do landsat.** Rio de Janeiro, 1994. Dissertação (Mestrado em Engenharia Elétrica) Universidade Federal do Rio de Janeiro.
- 24 NIERO, M.; FORESTI, C. **Uso do solo urbano da área metropolitana de São Paulo através da análise automática de dados LANDSAT.** São José dos Campos: INPE, 1983.
- 25 NOVO, E.M.L.M. **Análise Comparativa entre Fotografias Aéreas Convencionais e imagens LANDSAT para fins de levantamento do uso da terra.** São José dos Campos: INPE, 1978.
- 26 NASA. **Earth System Science: a closer viewer.** NASA, Advisory Council Washington, DC, 1988.
- 27 RICHARDS, A. J. **Remote Sensing Digital Image Analysis.** Berlim: Springer – Verlag, 1993.
- 28 SABINS, F. F. **Remote Sensing: Principles and Interpretation.** San Francisco: W. H.
- 29 VENTURIERI, A. **Utilização da segmentação de imagens e lógica nebulosa para treinamento de uma rede neural artificial na caracterização de classes de uso da terra na região de Tucuruí – PA.** São José dos Campos, 1995. Dissertação (Mestrado em Computação Aplicada), INPE.
- 30 WOODCOCK, C.; HARWARD, V.J. **Nested-hierarchical scene models and image segmentation.** International Journal of Remote Sensing, London, v.13, n. 16, p.3167-3187, 1992.
- 31 WOODCOCK, C. E.; COLLINS, J. B.; GOPAL, S.; JAKABHAZY, V.D.; LI, X.; MACOMBER, S.; RYHERD, S.; HARWARD, V.J.; LEVITAN, J.; WU, Y.; WARBINGTON, R. **Mapping forest vegetation using landsat TM imagery and a canopy reflectance model.** New York: Remote Sensing of Environment, 1994k, v. 50, n.3, p.240-254.