



AUTORES AUTHORS	PALAVRAS CHAVES/KEY WORDS		AUTORIZADA POR/AUTHORIZED BY
	Textura Processamento de Imagens Classificação de Imagens Resolução Espacial		<i>Ralf Gielow</i> Ralf Gielow Pres. Cons. PG

AUTOR RESPONSÁVEL RESPONSIBLE AUTHOR	DISTRIBUIÇÃO/DISTRIBUTION	REVISADA POR / REVISED BY
<i>Valéria M. B. Andrade</i> Valéria Maria B. Andrade	<input type="checkbox"/> INTERNA / INTERNAL <input checked="" type="checkbox"/> EXTERNA / EXTERNAL <input type="checkbox"/> RESTRITA / RESTRICTED	<i>Gerald Jean F. Banon</i> Gerald Jean F. Banon

CDU/UDC	DATA / DATE
621.376.5	

TÍTULO/TITLE	AUTORES/AUTHORSHIP	PUBLICAÇÃO Nº PUBLICATION NO INPE-4888-TDL/379	ORIGEM ORIGIN PG/DPI
		CLASSIFICAÇÃO DE IMAGENS DE ALTA RESOLUÇÃO USANDO ATRIBUTOS DE TEXTURA	PROJETO PROJECT FRH/CAP
Nº DE PAG. NO OF PAGES 102	ULTIMA PAG. LAST PAGE A.2		
VERSÃO VERSION	Nº DE MAPAS NO OF MAPS		
		Valéria Maria Barros de Andrade	

RESUMO - NOTAS / ABSTRACT - NOTES

A maioria dos classificadores atualmente utilizados na análise de imagens usam apenas as características espectrais para diferenciar as classes. Esses classificadores foram originalmente desenvolvidos para análise de dados Landsat-MSS. Com o surgimento de novos sensores de variadas resoluções espaciais, é necessária a revisão dos métodos de classificação. Estudos a respeito da influência da resolução na classificação apontam dois fatores responsáveis pelo desempenho de classificação: os pixels misturados e o "ruído de cena". Da presença do ruído de cena decorre o aparecimento de uma característica adicional na imagem, a textura. Na primeira parte deste trabalho, é feita uma avaliação do desempenho de classificação em função da resolução espacial. É verificado um decréscimo da confusão média na classificação à medida que a resolução diminui. No entanto, nas imagens de baixa resolução, observa-se bem, devido ao aumento dos pixels misturados, o aumento da abstenção média. Na segunda parte, são propostas algumas medidas (ou atributos) de textura, que podem ser extraídas de pequenas janelas de imagem. Extraíndo-se atributos de textura para cada pixel, são geradas "bandas de textura". As vinte "bandas de textura" propostas são analisadas visualmente e estatisticamente numa imagem da região urbana de São José dos Campos. A partir desta análise duas "bandas de textura" foram selecionadas e usadas na classificação daquela imagem. É verificada uma melhoria no desempenho de classificação no sentido de que se observa um decréscimo na confusão média, sem um real acréscimo na abstenção.

OBSERVAÇÕES / REMARKS

Dissertação de Mestrado em Computação Aplicada em 28 de fevereiro de 1989.

INSTITUTO DE PESQUISAS ESPACIAIS

DISSERTAÇÃO

CLASSIFICAÇÃO DE IMAGENS DE ALTA RESOLUÇÃO
USANDO ATRIBUTOS DE TEXTURA

SUBMETIDA POR

Valéria Maria Barrós de Andrade

Em cumprimento parcial dos requisitos exigidos para
obtenção do título de Mestre em Computação Aplicada

1989

Aprovada pela Banca Examinadora
em cumprimento a requisito exigido
para a obtenção do Título de Mestre
em Computação Aplicada

Dr. Nelson Delfino d'Ávila Mascarenhas



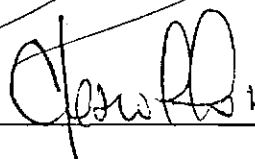
Presidente

Dr. Gerald Jean Francis Banon



Orientador

Dr. Clésio Luis Tozzi



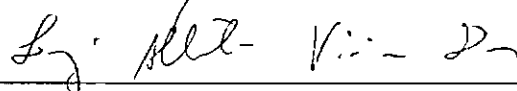
Membro da Banca
-convidado-

Dr. Raimundo Almeida Filho



Membro da Banca

Dr. Luiz Alberto Vieira Dias



Membro da Banca

Candidata: Valéria Maria Barros de Andrade

São José dos Campos, 28 de fevereiro de 1989

Ao Rogério que, com apoio, carinho e incentivo, muito contribuiu para a realização deste trabalho.

AGRADECIMENTOS

Ao INPE, Instituto de Pesquisas Espaciais, pela oportunidade de realizar o Curso de Mestrado e também pelo apoio dado à pesquisa, fornecendo materiais e equipamentos.

Ao Dr Gerald Jean Francis Banon, pela orientação e principalmente pela atenção que sempre me dispensou.

Ao CNPq, Conselho Nacional de Desenvolvimento Científico e Tecnológico, e à FAPESP, Fundação de Amparo à Pesquisa do Estado de São Paulo, pela concessão de bolsa de estudos durante a realização do curso e desenvolvimento da dissertação de mestrado.

Aos pesquisadores e funcionários do Departamento de Processamento de Imagens, em especial Fernando Augusto Mitsuo Ii, pelos valiosos esclarecimentos.

Aos pesquisadores e funcionários do Departamento de Sensoriamento Remoto, pela colaboração.

À pesquisadora Madalena Niero Pereira, pela inestimável ajuda.

Aos amigos do INPE, em especial Antônio Miguel Vieira Monteiro e Leonardo Sant'Anna Bins, pelo companheirismo.

RESUMO

A maioria dos classificadores atualmente utilizados na análise de imagens usam apenas as características espectrais para diferenciar as classes. Esses classificadores foram originalmente desenvolvidos para análise de dados Landsat-MSS. Com o surgimento de novos sensores de variadas resoluções espaciais, é necessária a revisão dos métodos de classificação. Estudos a respeito da influência da resolução na classificação apontam dois fatores responsáveis pelo desempenho de classificação: os pixels misturados e o "ruído de cena". Da presença do ruído de cena decorre o aparecimento de uma característica adicional na imagem, a textura. Na primeira parte deste trabalho, é feita uma avaliação do desempenho de classificação em função da resolução espacial. É verificado um decréscimo da confusão média na classificação à medida que a resolução diminui. No entanto, nas imagens de baixa resolução, observa-se bem, devido ao aumento dos pixels misturados, o aumento da abstenção média. Na segunda parte, são propostas algumas medidas (ou atributos) de textura, que podem ser extraídas de pequenas janelas de imagem. Extraíndo-se atributos de textura para cada pixel, são geradas "bandas de textura". As vinte "bandas de textura" propostas são analisadas visualmente e estatisticamente numa imagem da região urbana de São José dos Campos. A partir desta análise duas "bandas de textura" foram selecionadas e usadas na classificação daquela imagem. É verificada uma melhoria no desempenho de classificação no sentido de que se observa um decréscimo na confusão média, sem um real acréscimo na abstenção.

ABSTRACT

Most classifiers commonly used in image analysis rely solely on spectral characteristics to differentiate classes. These classifiers were originally developed to be used with Landsat-MSS data. With the new sensors at different spatial resolutions it is necessary to revise the image classification methods. Studies about spatial resolution effects on classification shows that classification accuracy is influenced by two factors: the mixed pixels and "scene noise". The presence of "scene noise" provides one more image characteristic, the texture. In the first part of this work, an evaluation of the classification accuracy as a function of spatial resolution is made. It is verified that confusion error rates decrease with smaller resolutions. However, for small resolution image, it can be observed, due to the increasing rate of mixed pixels, an increasing rate of non-classified pixels. In the second part, some texture measures (or features) are proposed. They are extracted from small image windows. By extraction of the textural feature at each pixel, "texture bands" are created. The twenty proposed "texture bands" are visually and statistically analysed from an image of São José dos Campos urban area. From this analysis, two "texture bands" are selected and used to classify this image. A better classification accuracy is verified, in the sense that a decreasing confusion error rate without a significant increasing rate of non-classified pixels is observed.

SUMÁRIO

	<u>Pág.</u>
LISTA DE FIGURAS	xi
LISTA DE TABELAS	xiii
<u>CAPÍTULO 1 - INTRODUÇÃO</u>	1
<u>CAPÍTULO 2 - INFLUÊNCIA DA RESOLUÇÃO ESPACIAL NA CLASSIFICAÇÃO</u>	5
<u>CAPÍTULO 3 - TEXTURA</u>	21
3.1 - Introdução	21
3.2 - Caracterização de textura	22
3.3 - Método proposto	31
<u>CAPÍTULO 4 - PARTE EXPERIMENTAL</u>	43
4.1 - Introdução	43
4.2 - Avaliação da influência da resolução na classificação	48
4.2.1 - Descrição dos experimentos	48
4.2.2 - Análise dos resultados	59
4.3 - Teste dos atributos de textura	61
4.3.1 - Introdução	61
4.3.2 - Seleção de atributos de textura	62
4.3.3 - Classificação	71
4.3.4 - Análise dos resultados	75
<u>CAPÍTULO 5 - COMENTÁRIOS FINAIS</u>	77
REFERÊNCIAS BIBLIOGRÁFICA	81
APÊNDICE A - ATRIBUTOS DE TEXTURA PROPOSTOS POR HARALICK ET ALII (1973)	

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 - Estrutura organizacional de uma cena urbana ...	7
2.2 - Mudança na sobreposição das classes no espaço de atributos	11
2.3 - Probabilidade de erro na classificação.....	12
2.4 - Imagem simulada (TM - banda 3) de uma área florestal ao norte da Califórnia com o gráfico da variação local em função da resolução para esta imagem	13
2.5 - Imagem simulada (TM - banda 3) de Washington com o gráfico da variação local em função da resolução para esta imagem	13
2.6 - Histograma multimodal	18
4.1 - Imagem TM/LANDSAT de São José dos Campos (R:banda 5, G:banda 4, B:banda 3)	44
4.2 - Composição colorida: R - banda 5, G - banda 4, B - banda 3 com amostras de treinamento	46
4.3 - Amostras teste	46
4.4 - Imagem simulada com resolução próxima ao MSS ..	50
4.5 - Imagem simulada com resolução próxima ao SSR ..	50
4.6 - Classificação usando imagem TM (banda 3).....	52
4.7 - Classificação usando imagem MSS	52
4.8 - Classificação usando imagem SSR	53
4.9 - Classificação usando imagens TM e MSS	53
4.10 - Classificação usando imagens TM e SSR	54
4.11 - Classificação usando imagens MSS e SSR	54
4.12 - Classificação usando imagem TM, MSS e SSR	55
4.13 - Imagem de São José dos Campos banda 3 do TM/LANDSAT	69

	<u>Pág.</u>
4.14 - Banda de textura (5T6)	70
4.15 - Banda de textura (5T12)	70
4.16 - Classificação da imagem teste usando bandas 3, 4 e 5 do TM	72
4.17 - Classificação da imagem teste usando bandas 3, 4 do TM e 5T12	72
4.18 - Classificação da imagem teste usando bandas 3 do TM, 5T6 e 5T12	73

LISTA DE TABELAS

	<u>Pág.</u>
3.1 - Propriedades locais definidas por Irons e Petersen (1981)	41
4.1 - Número de pontos para amostras de treinamento e amostras teste	47
4.2 - Matrizes de classificação para amostras de treinamento e amostras teste usando imagem TM ..	56
4.3 - Matrizes de classificação para amostras de treinamento e amostras teste usando imagem MSS .	56
4.4 - Matrizes de classificação para amostras de treinamento e amostras teste usando imagem SSR .	57
4.5 - Matrizes de classificação para amostras de treinamento e amostras teste usando imagens TM e MSS	57
4.6 - Matrizes de classificação para amostras de treinamento e amostras teste usando imagens TM e SSR	58
4.7 - Matrizes de classificação para amostras de treinamento e amostras teste usando imagens MSS e SSR	58
4.8 - Matrizes de classificação para amostras de treinamento e amostras teste usando imagens TM, MSS e SSR	59
4.9 - Resultados do cálculo de alfa para "bandas de textura"	64
4.10 - Matrizes de classificação para amostras de treinamento e amostras teste usando bandas 3 4 5 TM	74
4.11 - Matrizes de classificação para amostras de treinamento e amostras teste usando bandas 3 4 TM e 5t12	74
4.12 - Matrizes de classificação para amostras de treinamento e amostras teste usando bandas 3 TM 5t6 e 5t12	75

CAPÍTULO 1

INTRODUÇÃO

A maioria dos classificadores atualmente empregados na análise de imagens obtidas por sensores remotos usam apenas as características espectrais da imagem para diferenciar as classes. Esses classificadores foram originalmente desenvolvidos para serem usados com os dados do LANDSAT Multispectral Scanner (MSS), com resolução espacial de 80 m.

Entretanto, novos satélites vêm sendo equipados com sensores de variadas resoluções espaciais. Resoluções mais altas como a do sensor Thematic Mapper (TM) que foi incluído nos satélites LANDSAT 4 e 5 (30 m), o sensor HRV (Haute Resolution Visible) do satélite SPOT (10 e 20 m) e o sensor MESSR do Satélite de Observação Marítima Japonês com 50 m de resolução (Ishizawa, 1981). Já o sensor AVHRR, que equipa os satélites da série NOAA (Tucker et alii, 1985), possui resolução bem mais baixa (1,1 km a 4 km). O futuro Satélite Brasileiro de Sensoriamento Remoto (SSR-1) está projetado para ser equipado com sensores de 200 m de resolução.

Os usuários de imagens de satélite para sensoriamento remoto têm agora a possibilidade de escolher imagens nas escalas entre 10 m e 4 km. A escolha apropriada da escala ou resolução espacial para determinada aplicação depende de vários fatores (Woodcock e Strahler, 1987). Esses incluem a informação desejada a respeito da cena em questão (por exemplo, a área plantada em um determinado estado do Brasil ou o tipo de floresta predominante em uma região), o método de análise a ser usado para extrair a

informação (interpretação visual, classificação automática, etc) e também a estrutura espacial da própria cena.

Análises feitas em imagens de alta resolução, usando-se métodos tradicionais de classificação, têm verificado, para algumas aplicações, um decréscimo no desempenho de classificação em relação àquele obtido com imagens MSS.

Investigações a respeito do efeito da resolução espacial no desempenho de classificação ponto-a-ponto, usando-se técnicas tradicionais, concluíram que esse dependerá fundamentalmente da combinação de dois fatores (Woodcock e Strahler, 1987; Markham e Townshend, 1981).

O primeiro fator é a influência dos pixels misturados (pixels misturados são aqueles que representam uma área com mais uma classe). À medida que a resolução espacial se torna mais fina a proporção destes pixels decresce. A redução no número de pixels misturados resulta em uma melhora no resultado de classificação.

O segundo fator influente no desempenho de classificação é aumento na variância espectral das classes associado ao aumento da resolução. Este aumento da variância faz decrescer a separabilidade espectral das classes resultando num baixo desempenho de classificação. Esse fator é freqüentemente chamado de "ruído de cena" (scene-noise)(Markham e Townshend, 1981).

Para uma dada cena, a variação no resultado da classificação, em função da resolução espacial, dependerá da importância relativa do "ruído de cena" e dos pixels misturados. Por exemplo, uma cena com pequenos talhões uniformes deverá apresentar uma melhora na

classificação à medida que a resolução aumentar. Alternativamente, uma imagem com grandes talhões heterogêneos deverá apresentar resultado oposto.

Assim sendo, é necessário que os métodos de classificação sejam revistos, a fim de que os fatores ocasionados pelo aumento da resolução possam influenciar positivamente no processo de classificação.

A idéia de textura, causada pela impressão de rugosidade dada pela variabilidade de tonalidades na imagem, pode ser usada como informação adicional na diferenciação de classes.

O objetivo inicial deste trabalho é tentar extrair das imagens algumas medidas que possam caracterizar textura e usá-las como atributos adicionais no processo tradicional de classificação. Em vista da necessidade de se extrair medidas de textura para cada região de imagem circunvizinha a um pixel, buscou-se, por razões de deficiência computacional, trabalhar com pequenas vizinhanças (ou janelas).

No Capítulo 2 é discutido, com mais detalhes, como os fatores relacionados com a resolução espacial podem influenciar a classificação de imagens. Essa discussão visa a mostrar a importância do uso da textura, presente em imagens de alta resolução, na tentativa de se melhorar a diferenciação das classes.

No Capítulo 3 é feito um breve relato sobre alguns dos modelos de textura existentes, apresentando o método usado na extração de atributos de textura e, ainda, os motivos pelos quais se optou por este método.

A verificação experimental do que é discutido nos Capítulos 2 e 3 é feita no Capítulo 4, sendo apresentados, no Capítulo 5, os comentários finais.

CAPITULO 2

INFLUÊNCIA DA RESOLUÇÃO ESPACIAL NA CLASSIFICAÇÃO

Ao longo deste capítulo definem-se termos que serão freqüentemente usados neste trabalho.

Um sensor pode ser definido como um equipamento que mede a intensidade de radiação eletromagnética. Este termo é aqui usado em um sentido amplo, incluindo não apenas o detetor em si, mas também todas as partes associadas a ele, tais como o aparato ótico e os circuitos eletrônicos. O sensor possui um campo de visão instantâneo-IFOV ("Instantaneous Field of View") do qual são captados os fluxos de energia. O IFOV é o ângulo subtendido pela projeção geométrica de um detetor no solo.

Uma Cena é definida como uma distribuição espacial e temporal de matéria e fluxos de energia de onde o sensor efetua medidas.

Uma Imagem é uma coleção de medidas efetuadas pelo sensor, arranjadas de maneira sistemática (Strahler et alii, 1986). Cada componente da imagem é chamado de "pixel" (picture element) ou elemento de imagem. A área na cena correspondente a um elemento de imagem será aqui denotada por elemento de cena.

Associado à imagem está o conceito de célula de resolução, definida como a área da projeção geométrica de um detetor no solo. Esta área é definida pelo IFOV. A resolução espacial pode ser definida como o número de pixels que representa uma dada área na cena. Assim, são chamadas imagens de alta resolução aquelas que possuem muitos pixels representando uma dada área na cena e imagens

de baixa resolução aquelas que possuem poucos pixels representando a mesma área.

As cenas reais não são caóticas; elas apresentam uma coerência ou organização espacial. Em geral, um problema em sensoriamento remoto pode ser visto como uma tentativa de se inferirem as propriedades e organização das distribuições de matéria e energia na cena, a partir do conjunto de medidas que constituem a imagem.

Seja explicitamente ou não, essa inferência a respeito da cena implica na aplicação de um modelo de sensoriamento remoto. As suposições precisam sempre ser feitas considerando-se a cena, a atmosfera e o sistema sensor.

Como modelo da cena pode-se considerar o modelo discreto (Strahler et alii; 1986), onde se supõe que a cena é constituída de objetos discretos, ou sejam, objetos com limites bem definidos. Um elemento, nesse modelo, é uma abstração de um objeto real na cena que pode ser considerado como tendo propriedades ou parâmetros uniformes. Os elementos, por sua vez, podem ser vistos como classes de elementos. Todos os elementos de uma mesma classe são caracterizados pelo mesmo conjunto de parâmetros e/ou propriedades. Os elementos e as classes de elementos de uma cena podem variar consideravelmente, de acôrdo com o interesse do interpretador. Alguns exemplos de elementos e/ou classes são: folha, árvore, plantação de trigo; carro, rua, jardim, casa; aeroporto, avião, prédio, indústria.

Na superfície terrestre, existe uma grande variedade de materiais. Estes, em geral, estão dispostos de maneira interrelacionada, apresentando uma estrutura hierárquica de organização. Para melhor descrição da cena,

é necessário um modelo que retrate este encadeamento entre os objetos que constituem a cena (modelo hierárquico). Neste modelo, podem-se distinguir vários níveis de elementos, ou classes, onde os elementos de um nível mais baixo se agrupam para formar os elementos do nível superior, formando uma estrutura hierárquica. Para exemplificação, pode-se considerar a Figura 2.1, onde é feita a descrição de uma cena urbana, com sua estrutura organizacional representada sob a forma de árvore, mostrando a sucessiva subdivisão das diversas classes. Percorrendo-se esta estrutura de cima para baixo, nota-se o aumento progressivo no nível de detalhes na descrição da cena.

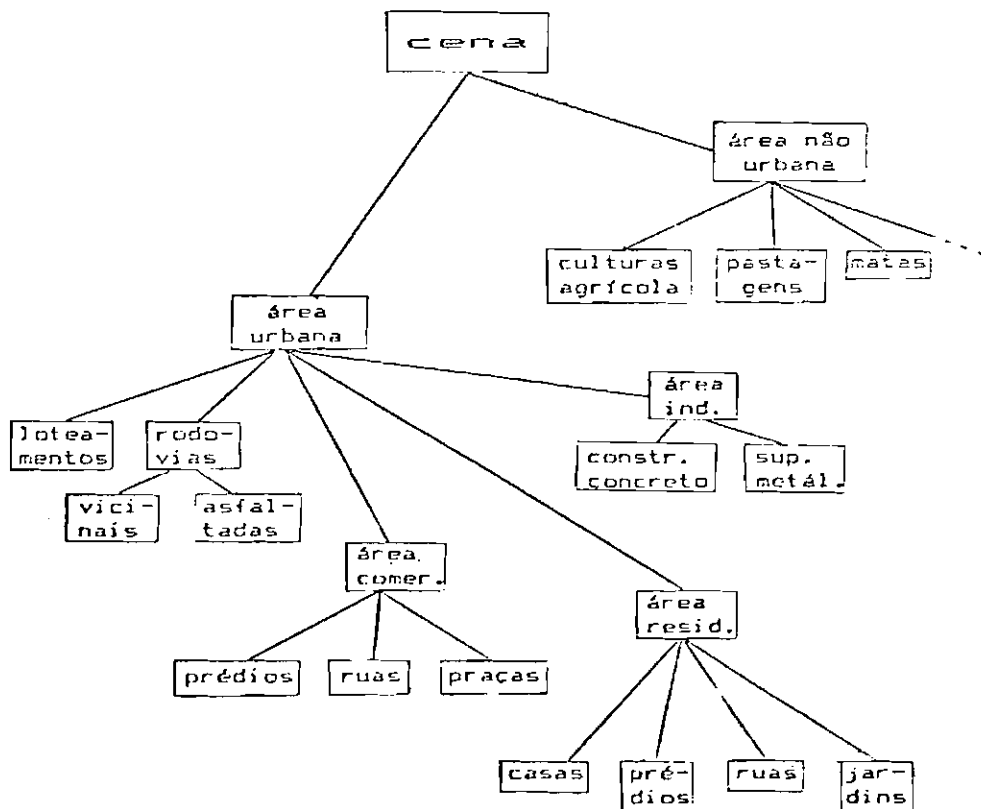


Fig. 2.1 - Estrutura organizacional de uma cena urbana.

De posse de um modelo que descreva a estrutura organizacional de uma dada cena, é importante verificar em que nível hierárquico se encontram os elementos que poderão ser identificados a partir da observação da imagem obtida desta cena. Sob este aspecto, a resolução espacial da imagem desempenha papel fundamental, pois ela irá determinar a classe de informação que poderá ser obtida. O aumento na resolução propiciará um maior aprofundamento dentro da estrutura de organização da cena, ou seja, permitirá que se obtenham informações mais detalhadas da cena.

O processamento digital de imagens é definido como a utilização de sistemas computacionais que visam a auxiliar o elemento humano, na interpretação das informações contidas nas imagens. A classificação automática supervisionada é uma das etapas dentro do processo de análise de imagens e pode ser vista como um passo para se fazerem inferências a respeito da cena.

Na classificação de imagens, as classes são formadas por elementos de cena. O problema de classificação consiste em, dadas várias classes e um elemento de cena suposto pertencer a uma delas, decidir a qual destas classes o elemento pertence. No caso, por exemplo, de cenas agrícolas, pode-se dizer que as classes são os diversos tipos de culturas agrícolas desejando-se saber, neste caso, qual a cultura plantada em cada elemento de cena.

Para que um elemento de cena possa ser classificado é necessário que ele seja caracterizado através de um conjunto de n medidas, relativas a n atributos. Este conjunto de n medidas pode ser visto como um ponto num espaço n -dimensional conhecido como espaço de atributos. Qualquer ponto no espaço de atributos pode ser

representado por um vetor X de n componentes ($X = (x_1 \ x_2 \ \dots \ x_n)$), denominado vetor de atributos. No caso de imagens obtidas por satélite, cada componente deste vetor usualmente representa a radiância recebida pelo satélite numa determinada banda do espectro eletromagnético. O classificador (que é o mecanismo que executa a tarefa de classificação), conhecendo o vetor de atributos X , indica o nome de uma das classes, de acordo com uma regra de decisão.

A possibilidade de se trabalhar com imagens com várias resoluções leva a uma reflexão a respeito de como a variação na resolução espacial pode afetar a classificação destas imagens.

Algumas investigações neste sentido foram conduzidas por ocasião do lançamento do sensor Thematic Mapper (Latty e Hoffer, 1981; Markham e Townshend, 1981). Estes trabalhos comparam o desempenho de classificação de dados obtidos em diferentes resoluções. Nestes dois trabalhos, foi empregado o classificador de máxima verossimilhança com hipótese gaussiana para representar as classes.

Estes e outros estudos têm indicado que a ação conjunta de dois fatores afeta o desempenho de classificação como função da resolução espacial. O primeiro é o efeito dos pixels misturados (pixels que representam um elemento de cena onde se encontram objetos pertencentes a mais de uma classe diferente). O segundo é a heterogeneidade espectral das classes, chamado por Wiersma e Landgrebe(1978) de "ruído de cena".

O problema de pixels misturados está associado a imagens de baixa resolução. Quanto maior for a

célula de resolução, maior será a frequência relativa de pixels englobando mais de um objeto diferente, ou sejam, objetos de classes diferentes. Como estes pixels contêm uma mistura de classes, são chamados de pixels misturados. O certo seria que todos os pixels misturados deixassem de ser classificados, uma vez que eles pertencem a mais de uma classe. Certas técnicas para estimar a proporção de classes dentro dos pixels misturados (Nalepka e Hyde, 1972; Horowitz et alii, 1975; Correia, 1983) podem minimizar os problemas acarretados pela não classificação destes pixels. No entanto, de um modo geral, o aumento na porcentagem de pixels misturados com resoluções mais baixas pode provocar um decréscimo no desempenho de classificação.

Já o problema da heterogeneidade espectral está associado à imagens de alta resolução e terá maior intensidade nas imagens relativas a cenas mais bem caracterizadas por modelos hierárquicos complexos. Como já foi mencionado, a resolução espacial irá determinar o nível de informação que é possível extrair da imagem. Usualmente, isto não é levado em consideração. Em geral, as classes a serem identificadas se encontram nos níveis mais elevados (no modelo de cena), mas, com resoluções mais finas, é possível se identificarem os elementos que se combinam para formar estas classes e que, conseqüentemente, se encontram nos níveis hierárquicos mais baixos. Assim, nas imagens de alta resolução, o valor radiométrico de um pixel corresponde à resposta espectral de um objeto individual na cena relativo aos níveis hierárquicos mais baixos, não mais correspondendo ao resultado da integração de respostas espectrais de vários objetos como nas imagens de baixa resolução. Como nos níveis inferiores existe maior variedade de elementos, os valores dos pixels relativos a uma mesma classe apresentarão grande heterogeneidade de um para o outro. O aumento da variabilidade espectral de uma

classe, faz com que esta ocupe maior área no espaço de atributos, resultando numa maior sobreposição de classes, como mostra a Figura 2.2. O aumento na sobreposição das classes implica em um aumento na probabilidade de erro na classificação (representada pela área hachurada na Figura 2.3), diminuindo o desempenho do classificador. À medida que a resolução é degradada, uma melhora na qualidade de classificação é esperada. Isto porque as variações na imagem vão diminuindo. Na maior parte das vezes, a variância de cada assinatura espectral diminui, mas a média tende a permanecer constante (constatado experimentalmente por Sadowski et alii (1977)), contribuindo para o decréscimo na sobreposição das classes.

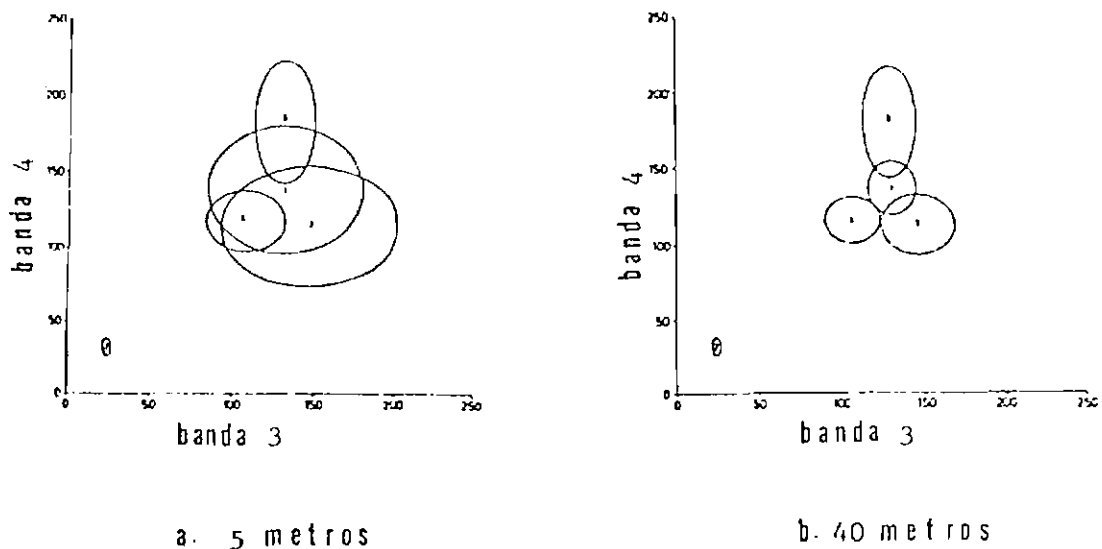


Fig. 2.2 - Mudança na sobreposição das classes no espaço de atributos.

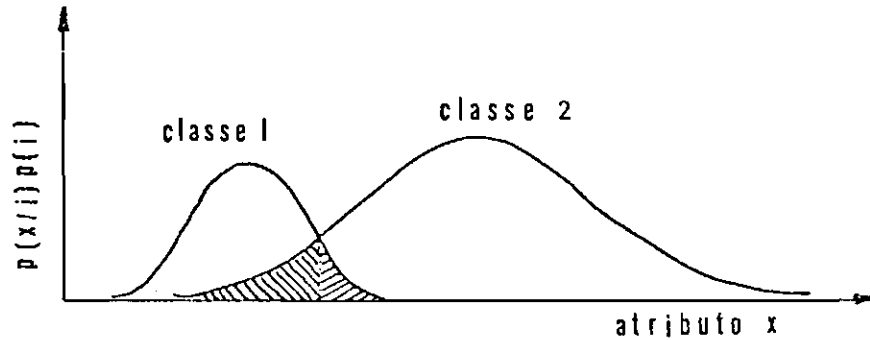


Fig. 2.3 - Probabilidade de erro na classificação

Woodcock e Strahler (1987) apresentam gráficos que expressam a variação local da imagem em função da resolução espacial para diferentes tipos de imagens. Como medida da variação local, é usado o valor médio dos desvios padrão computados em janelas móveis de 3 x 3 pixels. Dois destes gráficos são mostrados nas Figuras 2.4 e 2.5. Esses gráficos são relativos a cenas com estrutura espacial considerada complexa. Neles, se pode observar uma queda na variação local à medida que a imagem é degradada (resolução espacial é reduzida).




Fig. 2.4 - Imagem simulada (TM - banda 3) de uma área florestal ao norte da Califórnia com o gráfico da variação local em função da resolução para esta imagem.

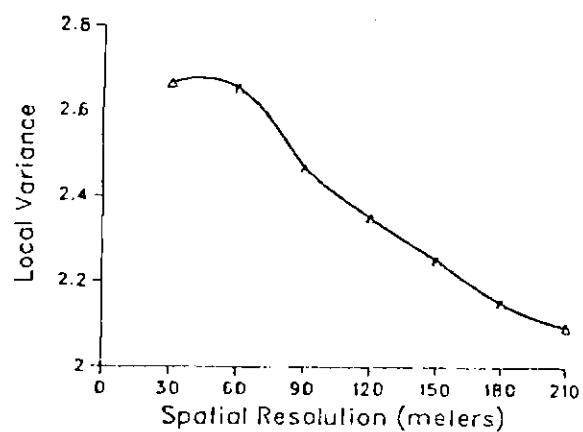


Fig. 2.5 - Imagem simulada (TM - banda 3) de Washington com o gráfico da variação local em função da resolução para esta imagem.

Ao analisar as consequências do aumento da resolução na qualidade de classificação de um determinado tipo de cobertura de solo, é necessário levar-se em conta a posição deste, em relação aos demais, no espaço de atributos. Categorias que, a baixas resoluções, se apresentam próximas no espaço de atributos, terão qualidade de classificação piorada com o aumento da resolução. No entanto, categorias que possuem boa separabilidade entre si poderão obter resultados de classificação melhorados com resoluções mais altas devido à redução dos pixels misturados.

Como se nota, procurar antever o efeito da alteração da resolução no desempenho de classificação de determinado tipo de ocupação de solo é uma tarefa complexa. Além da interrelação dos dois fatores discutidos acima, muitas são as variáveis que deverão ser consideradas em cada caso.

Markham e Townshend (1981) concluíram, para as áreas de teste investigadas, que:

- (1) O "ruído de cena" varia consideravelmente entre categorias diferentes de cobertura de solo.
- (2) As mudanças no "ruído de cena" em função do aumento na resolução, ocorrem de maneiras diferentes para categorias diferentes.
- (3) Para uma dada categoria de cobertura de solo, o nível de "ruído de cena" varia substancialmente entre bandas espectrais de imagem.
- (4) Variações no "ruído de cena" em função da resolução espacial afetam o desempenho de

classificação mas, de uma maneira geral, este dependerá também, da posição relativa de cada classe no espaço de atributos. Assim, é impossível se prever a magnitude do efeito das mudanças na resolução, baseando-se somente no ruído de cena de uma categoria individual.

- (5) Os efeitos dos pixels misturados e do "ruído de cena" podem exatamente se anular, quando a resolução é variada, de forma que o desempenho de classificação pode permanecer inalterado em uma larga faixa de resolução espacial.
- (6) Embora sejam necessários maiores estudos, em grandes áreas-alvo com altos níveis de "ruído de cena", os efeitos dos pixels misturados tendem a dominar os efeitos do "ruído de cena" para células de resolução acima de 40 metros.
- (7) A classificação errada de pixels misturados é mais grave quando eles tendem a ser atribuídos a uma classe não contida dentro deles.

Os experimentos realizados no trabalho de Latty e Hoffer (1981) demonstraram que:

- (1) O uso de dados com resoluções sucessivamente maiores resultou numa queda no desempenho de classificação usando-se o classificador de máxima verossimilhança.
- (2) Altos desempenhos foram obtidos com este classificador usando-se elementos de cena de 60 x 75 metros, de classes associadas a níveis relativamente altos de variabilidade espectral.

- (3) Classes associadas a níveis relativamente baixos de variabilidade espectral apresentaram pouca variação de desempenho de classificação em função da variação na resolução espacial.
- (4) Foi conseguido um melhor resultado de classificação de imagens com elementos de cena de 30 m x 30 m usando-se um classificador que considera as características radiométricas de um grupo de pixels adjacentes (classificador *SECHO - Supervised Extraction and Classification of Homogeneous Objects), ao invés do classificador de máxima verossimilhança.
- (5) Os melhores resultados foram conseguidos, usando-se este classificador (*SECHO) na classificação de dados de classes associadas a níveis relativamente altos de variabilidade espectral.

Com base nestes resultados pode-se tentar inferir o que deverá ocorrer com o desempenho de classificação de dados nas resoluções das imagens recebidas pelo INPE (MSS, TM, SPOT, etc).

As imagens MSS (com elementos de cena de 80 m x 80 m) têm sido amplamente usadas nas mais diversas áreas de aplicação do sensoriamento remoto. Apesar de os resultados de classificação das imagens nesta resolução não serem, em certos casos, totalmente satisfatórios, melhores resultados não têm sido obtidos com resoluções como as do TM ou SPOT.

No caso de classificação de imagens de florestas ou de áreas urbanas, é esperado um decréscimo na

qualidade de classificação com o aumento de resolução. Isto devido à estrutura espacial complexa dessas cenas. Essas cenas são compostas por vários tipos de objetos. Nas imagens com resoluções mais altas, mais tipos de objetos presentes na cena poderão ser distingüidos na imagem. No caso de imagens florestais poderão ser distingüidas, por exemplo, árvores de tipos e tamanhos diferentes. Estes objetos correspondem a elementos, no modelo hierárquico da cena, de nível bem inferior ao das classes que em geral se procuram identificar nestas imagens. Estas classes podem ser, por exemplo, diferentes tipos de mata. Nas imagens de áreas urbanas, os objetos distingüíveis poderão estar ao nível de casas, ruas, carros, sendo que o interesse poderá ser, por exemplo, o de identificar áreas residenciais, industriais e comerciais em determinado município. A possibilidade de se distingüirem maiores detalhes da cena nas imagens de alta resolução, torna-se um defeito, pois as classes de interesse terão grande variabilidade nos valores de seus pixels. Isto, como já foi dito aqui, dificulta a tarefa de classificação quando são empregados métodos tradicionais. Além deste, outro fator relevante é responsável pelo baixo desempenho de classificação. No classificador de máxima verossimilhança geralmente supõe-se que as classes possuem distribuição de probabilidade gaussiana ou normal e portanto unimodal. Com a presença de detalhes na imagem, o que pode ocorrer é que mais de um tipo de pixel se torne bem freqüente ocasionando uma distribuição multimodal. Como os algoritmos de classificação não prevêm esta hipótese, a média estimada poderá estar fora da realidade, pois poderá localizar-se entre dois valores de grande ocorrência, como no caso da Figura 2.6.




Fig. 2.6 - Histograma multimodal.

No caso de imagens agrícolas, este problema é mais improvável. As áreas agrícolas geralmente apresentam-se uniformes nas imagens obtidas por satélite e mesmo em imagens de alta resolução (imagens SPOT), a variância espectral das classes é baixa, podendo-se portanto, obter bons resultados de classificação. Isto se as classes analisadas apresentarem boa separabilidade.

Na tentativa de melhorar a classificação das imagens onde a presença de "ruído de cena" traz resultados insatisfatórios, duas medidas poderiam ser adotadas.

A primeira delas seria a aplicação de um algoritmo de agregamento ("cluster") em cada classe, para que, dentro delas, sejam encontradas subclasses. Cada uma destas subclasses teria sua média e sua matriz de covariância como parâmetros de sua distribuição. Cada elemento de imagem a ser classificado seria atribuído a subclasse mais provável e no final do processo de classificação todos os elementos de imagem pertencentes às subclasses de uma certa classe seriam considerados como elementos de imagem desta classe.

A segunda medida seria a aplicação de métodos que aproveitassem esta variabilidade dentro das classes como uma característica a mais na diferenciação destas. Esta variação de tons na imagem dá a idéia de textura, o que será assunto do próximo capítulo.

CAPÍTULO 3

TEXTURA

3.1 - INTRODUÇÃO

Tonalidade e textura são duas características visuais importantes na análise de vários tipos de imagens. Tonalidade refere-se às diversas gradações de tons cinza dos elementos de imagem, enquanto textura está relacionada com a distribuição espacial destes tons de cinza.

A impressão de rugosidade ou suavidade causada pelos diferentes arranjos de tonalidades ou pela repetição de certos padrões visuais na imagem traz a noção intuitiva de textura. No entanto, uma definição precisa ou uma abordagem formal a respeito de textura ainda não existe.

Para que se possam aplicar estas duas características na análise automática de imagens é necessária uma caracterização quantitativa de cada uma. As imagens na forma digital já possuem os diversos tons de cinza quantificados e por isto, tonalidade vem sendo rotineiramente usada nos sistemas de análise digital de imagens. Já uma informação quantitativa de textura precisa ser extraída da imagem digital, o que não tem sido usual.

O que se pretende aqui é tentar obter uma medida de textura para que esta característica possa ser incluída no processo de classificação automática de imagens.

3.2 - CARACTERIZAÇÃO DE TEXTURA

Várias abordagens do problema de extração de características texturais de imagens vêm sendo propostas. Segundo alguns autores (Ahuja e Rosenfeld, 1981; Haralick, 1979 ; Gool et alli, 1985), existem dois grandes tipos de abordagens nos quais todos estes trabalhos podem ser enquadrados: abordagem estrutural e abordagem estatística. Esta distinção, no entanto, não é rígida; métodos classificados por um autor , em um tipo de abordagem, podem ser diferentemente classificados por outros autores.

A abordagem estrutural considera a textura como um arranjo, descrito por regras, de um conjunto de padrões ou primitivos . Estes padrões, por sua vez, são, em geral, formados por padrões menores arranjados de acordo com outras regras. A natureza recursiva desta abordagem capta a estrutura hierárquica das cenas naturais. Para descrever a textura segundo esta abordagem, é preciso descrever seus primitivos e as regras que determinam o arranjo destes. Texturas com estrutura regular se prestam mais a este tipo de análise.

A abordagem estatística tenta uma caracterização global de textura. Estatísticas conjuntas de tons de cinza de dois ou mais elementos de imagem são usadas como descritores de textura. Haralick(1979) destaca oito modelos dentro deste tipo de abordagem: funções de autocorrelação, transformadas óticas (transformada de Fourier, etc.), transformadas digitais (transformada discreta de Fourier, etc.), contagem do número de bordas, elementos estruturais, frequência de ocorrência espacial de tons de cinza, comprimento de arranjos retilíneos de tons de cinza ("gray tone run length") e modelos autorregressivos.

Todos estes modelos caracterizam a textura de uma superfície através de suas propriedades tais como finura, rugosidade, suavidade, granulação, irregularidade, etc.

Os três primeiros métodos citados estão interrelacionados porque todos eles, direta ou indiretamente, medem frequência espacial. Frequência espacial está relacionada com textura porque texturas finas são ricas em altas frequências enquanto texturas grossas são ricas em baixas frequências.

Outra maneira de qualificar textura é através do número de bordas por unidade de área. Texturas rugosas possuem um grande número de bordas por unidade de área.

O método dos elementos estruturais, da morfologia matemática, usa um procedimento que consiste em testar experimentalmente relações binárias entre um elemento estruturante numa dada posição e o objeto a ser analisado. Originalmente o elemento estruturante e os objetos eram binários, mas já existem extensões para objetos em tons de cinza. Quando os elementos estruturais consistem em dois pontos de uma imagem binária situados em uma certa posição relativa, a informação extraída por erosão é a função de autocorrelação da imagem binária. Usando-se formas maiores e mais complexas, uma autocorrelação generalizada pode ser computada (Haralick, 1979).

O método da dependência espacial de tons de cinza caracteriza a textura através da coocorrência de seus tons de cinza. Ele se baseia na estimação da distribuição de probabilidade conjunta dos tons de cinza de dois

elementos de imagem situados em certas posições relativas. A estimação da distribuição de probabilidade conjunta é dada pela matriz de coocorrência ou dependência espacial de tons de cinza.

O método do comprimento dos arranjos retilíneos de tons de cinza ("gray level run length") caracteriza texturas grossas como tendo vários pontos, em um arranjo retilíneo, com tons de cinza constantes. Texturas finas possuem poucos pontos em um arranjo.

O modelo autorregressivo e média móvel produz estimativas lineares do tom de cinza de um ponto de imagem dados os tons de cinza de seus vizinhos. A textura é caracterizada através dos coeficientes do modelo autorregressivo e média móvel, que a estima melhor.

Estudos comparativos entre alguns destes métodos (Conners e Harlow, 1980; Weszka, 1976) indicam que o método da dependência espacial dos tons de cinza é um dos mais poderosos na análise de texturas. A justificativa para o uso deste tipo de caracterização de textura é dada por experiências feitas com a percepção humana de texturas. Estas indicam que distribuições de probabilidade conjunta na forma medida pela matriz de coocorrência desempenham papel importante na discriminação visual humana de textura.

Baseando neste fato, o trabalho de Haralick et alii(1973) foi usado como referência inicial para o desenvolvimento deste trabalho. Esses autores propõem um conjunto de quatorze medidas de características texturais, que podem ser extraídas da matriz de coocorrência da seguinte forma:

uma imagem discreta (de uma banda) definida em uma grade retangular $K \times L$ é denotada por I e cada nó da grade é notado (k,l) . Seja $G = \{1,2,\dots,N_g\}$ o conjunto dos N_g possíveis níveis de cinza quantizados. A imagem I pode ser representada como uma função que atribui um nível de cinza i em G a cada ponto (k,l) em $K \times L$;

$$\begin{aligned} I: (K \times L) &\rightarrow G \\ I: (k,l) &\mapsto i. \end{aligned}$$

O nível de cinza $i = I(k,l)$ (de um ponto qualquer) pode ser visto como a realização de uma variável aleatória Y . Seja Y_1 a variável aleatória associada ao ponto (k,l) e Y_2 a variável aleatória associada ao ponto $(k+d_1, l+d_2)$. A posição relativa destes dois pontos é fixada pelo deslocamento relativo (d_1, d_2) , que pode, equivalentemente, ser caracterizado por uma distância radial d e por um ângulo θ em relação ao eixo horizontal. A distribuição de probabilidade conjunta destas duas variáveis aleatórias é notada por P_{y_1, y_2} . A probabilidade de se observar os níveis de cinza i e j em uma posição relativa fixa, especificada por (d_1, d_2) é notada por

$$P(i,j) = P_{Y_1, Y_2}(i,j) = \text{Prob}[Y_1=i, Y_2=j] \quad (1)$$

e é suposta não depender dos índices absolutos (k,l) (campo estacionário). Seja D o subconjunto de índices especificado pela região da imagem a ser analisada. A matriz de coocorrência ou dependência espacial de tons de cinza com parâmetros (d_1, d_2) é definida por

$$c(i,j) = \text{Card} \{ (k,l) \in D; \\ I(k,l)=i \text{ e } I(k+d1,l+d2)=j \}. \quad (2)$$

A contagem total é

$$N = \text{Card} \{ D \} = \sum_{i,j \in G} c(i,j), \quad (3)$$

onde $\text{Card} \{ \}$ refere-se ao número de elementos de um conjunto. A matriz de coocorrência normalizada é uma estimativa da distribuição de probabilidade conjunta definida por (1) ou seja,

$$\hat{P}(i,j) = c(i,j) / N. \quad (4)$$

A partir da distribuição de probabilidade conjunta definida por (4) as quatorze medidas de características texturais podem ser calculadas.

As equações que definem este conjunto de medidas são dadas no Apêndice A. Algumas destas medidas referem-se a características como homogeneidade, contraste, etc. Três delas são dadas por:

- Segundo momento angular:

$$f1 = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (P(i,j))^2$$

- Contraste:

$$f_2 = \sum_{n=0}^{Ng-1} n^2 \sum_{|i-j|=n} P(i,j) = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i-j)^2 P(i,j)$$

- Correlação:

$$f_3 = \frac{\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} [ij P(i,j) - \mu_x \mu_y]}{\sigma_x \sigma_y}$$

onde μ_x , μ_y , σ_x , σ_y são as médias e desvios padrão das distribuições marginais associadas a $P(i,j)$.

O segundo momento angular f_1 é uma medida de homogeneidade da imagem. A característica f_2 é o momento de segunda ordem da diferença de tons de cinza na imagem e é uma medida do contraste ou da variação local presente em uma imagem. A característica f_3 , correlação, é uma medida das dependências lineares dos tons de cinza na imagem.

O problema em se usar o método proposto por Haralick et alii(1973), bem como os demais mencionados dentro da abordagem estatística, é que todos eles definem características ou atributos de textura correspondentes a pequenas áreas de imagem contendo um só tipo de textura. Estas áreas são tratadas como entidades uniformes e categorizados de acordo com seus atributos. No caso das imagens que aqui serão analisadas, supõe-se que estas conterão diversas classes ou categorias de cobertura de solo, cada uma com suas características próprias de tonalidade e textura, sendo objetivo deste trabalho a

separação automática destas categorias. Para isto é necessária uma análise ponto a ponto da imagem, sendo cada ponto categorizado tanto pelas suas características espectrais como pelas relações espaciais mantidas pelas características espectrais de seus vizinhos (ou seja, pela textura caracterizada pelo grupo de pontos de sua vizinhança).

Para adequar a proposta de Haralick et alii(1973), ao caso aqui em questão, o seguinte procedimento poderia ser adotado:

Para cada ponto da imagem, seria tomada uma área retangular de imagem (aqui denotado de janela de imagem), na qual o ponto em questão fosse o ponto central. A esta janela de imagem seria então aplicado normalmente o método de extração de atributos da matriz de coocorrência.

Este procedimento, no entanto, tem alguns inconvenientes. Como medida de simplificação todas as janelas tomadas deverão ser do mesmo tamanho. A questão é decidir qual seria o tamanho ideal. Para que se possa ter o maior número possível de janelas homogêneas ou seja, contendo um só tipo de textura, é necessário que estas tenham dimensões pequenas. Janelas que englobarem transições entre diferentes classes, provavelmente terão uma ausência de classificação, afetando, assim, a qualidade de classificação. Por outro lado, dependendo do tipo de cena e da resolução da imagem, certos padrões de textura podem não ficar bem caracterizados em janelas muito pequenas. O ideal seria que se tivessem diferentes tamanhos de janela para diferentes áreas da imagem.

Como solução deste problema da escolha do tamanho da janela, Chen e Pavlidis (1980) propõem o uso de uma pirâmide de sucessivas versões de uma dada imagem com resoluções cada vez mais reduzidas (abordagem piramidal). Nesta pirâmide, podem ser construídas árvores representando partes homogêneas da imagem, ligando-se os nós (que representam blocos de imagem) de determinado nível aos nós mais semelhantes no nível superior. Pietikainen e Rosenfeld (1981) usam esta abordagem na segmentação de imagens (particionamento da imagem em regiões que têm propriedades relativamente homogêneas) com base na textura. Neste trabalho, o processo de segmentação é iniciado a partir da partição da imagem em pequenos blocos (8 x 8 pixels) não sobrepostos de imagem; para cada bloco é calculada uma propriedade textural (contraste - Haralick et alii (1973)), construindo uma matriz de valores; a partir de versões reduzidas desta matriz é construída uma pirâmide e é então iniciado um processo de ligação dos nós desta pirâmide. As árvores resultantes das ligações definem a segmentação da imagem. Na análise ponto a ponto da imagem seria necessário se trabalhar com blocos com cinquenta por cento de sobreposição, como é feito no trabalho de Burt et alii (1981).

A abordagem piramidal, embora venha solucionar o problema da escolha do tamanho da janela, é um processo de elevado custo computacional; além dos procedimentos de ligação dos nós, é necessário que se extraia para cada bloco de imagem, de cada nível da pirâmide, a propriedade textural.

Para a extração de atributos de textura é necessária a montagem da matriz de coocorrência para cada bloco. A matriz de coocorrência possui uma grande dimensionalidade determinada pelo número de níveis de cinza

quantizados, Card G (para imagens com 256 níveis a matriz terá dimensões de 256 linhas por 256 colunas). O número de pontos contidos em janelas pequenas (ou blocos) poderá não ser suficiente para se obter uma boa estimativa da distribuição de probabilidade conjunta. Além disto, existem os problemas de espaço de memória requerido para o armazenamento temporário da matriz e o tempo de processamento gasto no cálculo dos diversos atributos dela extraídos. No trabalho de Pietikainen e Rosenfeld (1981), como medida de otimização, a propriedade textural é extraída do histograma da diferença, somando-se o quadrado da diferença dos valores dos pares de pixels que apresentam o deslocamento requerido. Também na tentativa de reduzir o tempo de processamento e o espaço de memória requerido pela matriz de coocorrência, Unser (1986) propõe que a matriz de coocorrência seja substituída pelas estimativas das funções densidade de probabilidade de primeira ordem ao longo de seus eixos principais, denominadas histogramas da soma e da diferença (sum and difference histograms). Unser se baseou no fato de a soma e a diferença de duas variáveis aleatórias de mesma variância serem decorrelacionadas e definirem os eixos principais da função de distribuição de probabilidade a elas associada.

No entanto, deve-se levar em consideração que todo o processo de extração de atributos de textura deverá ser repetido tantas vezes quantos forem os pontos da imagem que se deseja processar (geralmente 512 x 512 pontos). Sendo assim, o tempo de processamento gasto a cada vez se torna um item importante e, para alcançar eficientemente o objetivo desejado, optou-se por buscar uma abordagem mais simplificada do problema.

3.3 - MÉTODO PROPOSTO

Face à inviabilidade do uso dos atributos de textura extraídos da matriz de coocorrência na análise ponto a ponto da imagem, surgiu a idéia de se tentar computar atributos semelhantes aos propostos por Haralick et alii(1973), usando-se diretamente os pontos dentro de pequenas janelas de imagem, sem a necessidade de se computar a matriz. Visando a reduzir ao máximo o tempo de processamento e minimizar o número de janelas com mistura de classes, procurou-se explorar as possibilidades de se trabalhar com janelas de menor tamanho possível. Assim, para janelas de tamanho 3 x 3 conseguiram-se doze tipos de propriedades locais (aqui chamados de atributos de textura), facilmente computáveis.


Sejam

a	b	c
d	e	f
g	h	i

os nove níveis de cinza relacionados a uma janela de imagem de tamanho 3 x 3; os seguintes atributos podem ser calculados usando-se os níveis de cinza (em uma banda espectral) de pares de pontos vizinhos:

- (1) Medida de contraste entre o ponto central e seus vizinhos nas direções horizontal e vertical:


$$f1 = \text{sqrt} \left(\frac{1}{4} \sum_X (e - x)^2 \right),$$



onde $X = \{b, d, f, h\}$

- (2) Correlação entre os valores de dois pontos adjacentes nas direções horizontal e vertical:

$$f2 = \frac{\text{cov } XY}{\text{sqrt}(\text{var } X \cdot \text{var } Y)},$$



sendo :

$$\text{cov } XY = \sum_{(x,y) \in D} xy / 12 - \left(\sum_X x / 12 * \sum_Y y / 12 \right),$$

$$\text{var } X = \sum_X x^2 / 12 - \left(\sum_X x / 12 \right)^2$$

$$\text{var } Y = \sum_Y y^2 / 12 - \left(\sum_Y y / 12 \right)^2$$

onde:

$$D = \{(a,b), (a,d), (b,c), (b,e), (c,f), (d,e), \\ (d,g), (e,f), (e,h), (f,i), (g,h), (h,i)\},$$

$$X = \{a, a, b, b, c, d, d, e, e, f, g, h\},$$

$$Y = \{b, d, c, e, f, e, g, f, h, i, h, i\}.$$

- (3) Diferença absoluta média entre os valores do ponto central e de seus vizinhos nas direções horizontal e vertical:

$$f3 = 1/4 \sum_X |e - x|,$$

a	b	c
d	- e -	f
g	- h -	i

onde $X = \{b, d, f, h\}$.

- (4) Desvio padrão:

$$f4 = \text{sqrt}(\text{var } X),$$

a	b	c
d	e	f
g	h	i

$$\text{sendo } \text{var } X = \sum_X x^2 / 9 - \left(\sum_X x / 9 \right)^2$$

onde $X = \{a, b, c, d, e, f, g, h, i\}$.

(5) Diferença absoluta média entre os valores de dois pontos vizinhos:

$$f_5 = 1/4 \sum_{(x,y) \in D} |x - y|,$$

a	-	b	-	c
d	-	e	-	f
g	-	h	-	i

onde $D = \{(a,b), (c,f), (i,h), (g,d)\}$.

(6) Diferença absoluta média entre os valores de dois pontos adjacentes nas direções horizontal e vertical:

$$f_6 = 1/12 \sum_{(x,y) \in D} |x - y|,$$

a	-	b	-	c
d	-	e	-	f
g	-	h	-	i

onde

$D = \{(a,b), (a,d), (b,c), (b,e), (c,f), (d,e), (d,g), (e,f), (e,h), (f,i), (g,h), (h,i)\}$.

(7) Correlação entre os valores de dois pontos vizinhos:

$$r = \frac{\text{cov } XY}{\sqrt{(\text{var } X \cdot \text{var } Y)}},$$

$$D = \{(a,b), (c,f), (i,h), (g,d)\},$$

$$X = \{a,c,i,g\},$$

$$Y = \{b,f,h,d\}.$$

a	-	b	-	c
d	-	e	-	f
g	-	h	-	i

sendo :

$$\text{cov } XY = \sum_{(x,y) \in D} xy / 4 - \left(\sum_X x / 4 * \sum_Y y / 4 \right),$$

$$\text{var } X = \sum_X x^2 / 4 - \left(\sum_X x / 4 \right)^2$$

$$\text{var } Y = \sum_Y y^2 / 4 - \left(\sum_Y y / 4 \right)^2$$

onde:

(8) Valor mínimo:

$$f_8 = \text{MIN } X,$$

onde $X = \{a, b, c, d, e, f, g, h, i\}$.

(9) Valor máximo:

$$f_9 = \text{MAX } X,$$

onde $X = \{a, b, c, d, e, f, g, h, i\}$.

(10) Diferença entre o maior e o menor valor:

$$f_{10} = \text{MAX } X - \text{MIN } X,$$

onde $X = \{a, b, c, d, e, f, g, h, i\}$.

(11) Variação total mínima nas direções horizontal e vertical:

$$f_{11} = \text{MIN} \left[\left(\sum_{(x,y) \in H} |x-y| \right), \left(\sum_{(x,y) \in V} |x-y| \right) \right],$$

onde:

$$H = \{(a,b), (b,c), (d,e), (e,f), (g,h), (h,i)\},$$

$$V = \{(a,d), (d,g), (b,e), (e,h), (c,f), (f,i)\}.$$

(12) Variação total mínima nas quatro direções:

$$f12 = \text{MIN} \left[\frac{1}{6} \left(\sum_{(x,y) \in H} |x-y| \right), \frac{1}{6} \left(\sum_{(x,y) \in V} |x-y| \right), \right.$$

$$\left. \frac{1}{4} \left(\sum_{(x,y) \in D1} |x-y| \right), \frac{1}{4} \left(\sum_{(x,y) \in D2} |x-y| \right) \right],$$

onde:

$$H = \{(a,b), (b,c), (d,e), (e,f), (g,h), (h,i)\},$$

$$V = \{(a,d), (d,g), (b,e), (e,h), (c,f), (f,i)\}$$

$$D1 = \{(a,e), (e,i), (b,f), (d,h)\}$$

$$D2 = \{(c,e), (e,g), (b,d), (f,h)\}$$

Estes dois últimos atributos (f11 e f12) foram extraídos do trabalho de Dondes e Rosenfeld (1982).

Para janelas de tamanho 5 x 5 podem ser calculados de maneira análoga os atributos (2), (4), (6), (8), (9), (10), (11), (12).

No cálculo dos atributos que envolvem a operação de divisão foram usados números reais. Como no caso de imagens os valores dos atributos devem ser inteiros variando de 0 a 255, os valores dos atributos foram truncados de modo a se obter um número inteiro. No entanto, para alguns atributos, ao se fazer o truncamento, os valores ficaram restritos a uma pequena faixa de variação. Nestes casos, antes de se fazer o truncamento, foi feito um reescalamento dos valores para que estes ficassem mais bem distribuídos dentro da faixa de 0 a 255.

Computando-se um destes atributos em uma pequena janela de imagem, centrada em determinado ponto, será obtido um valor que representará, de alguma forma, o tipo de textura desta pequena região de imagem. Tomando-se uma janela para cada e todo ponto da imagem e calculando-se para cada uma um certo atributo, ter-se-á ao final um conjunto de valores. Atribuindo-se a cada ponto de imagem o valor calculado na janela nele centrada um novo atributo da imagem será obtido. Este novo atributo pode ser considerado como uma nova banda de imagem denominada "banda de textura".

Para cada banda espectral de imagem podem ser geradas até vinte novas bandas. Diferentes combinações de bandas de textura e bandas espectrais podem ser usadas como atributos, na análise de imagens.

Esta proposta se assemelha muito à abordagem feita por Hsu (1978) e que serviu de base para o trabalho de Irons e Petersen (1981). Estes autores se referem às bandas de textura como transformadas texturais da imagem I (Haralick, 1979), por considerarem que estas são geradas através de transformações texturais da imagem original.

Hsu (1978) obteve transformadas texturais de fotografias aéreas digitalizadas especificando dezessete propriedades locais calculadas em janelas de 3×3 pontos de uma banda de imagem. As imagens referem-se à quatro cenas no estado de Nova York, nas resoluções de 2,67 e 17,30 metros; as classes identificadas foram: metal (telhados, tanques de óleo, carros), pavimentos, água, solo, áreas cultivadas, vegetação e áreas com mistura de classes (tais como áreas urbanas). As propriedades locais são: (1) a (4), os quatro momentos dos níveis de cinza (média, desvio padrão, medida de assimetria ("skewness") e medida de

achatamento ou curtose); (5) desvio absoluto médio; (6) contraste entre o ponto central e seus vizinhos; (7) brilho médio do ponto central; (8) contraste médio entre um ponto e seu vizinho mais próximos; (9) o quadrado de (8); (10) contraste médio entre um ponto e o seu segundo vizinho; (11) a soma dos valores de (10) ao quadrado; (12) a (17) área média de imagem com níveis de cinza acima e abaixo de três valores fixos - 50, 100 e 150 -(valores estes representando, aproximadamente, a reflectância média de certos tipos de terreno). Para as dezessete bandas resultantes, foram definidas as estatísticas de cada classe, através de treinamento supervisionado. Resultados de análises subsequentes indicaram que quatro das dezessete bandas não se prestaram à discriminação das classes analisadas. Estas bandas eram as derivadas de propriedades locais de terceira e quarta ordem incluindo a medida de assimetria e a curtose. As treze bandas remanescentes e o algoritmo da distância de Mahalanobis foram usadas na classificação, sendo alcançado o resultado de 85 a 90 por cento de classificação correta.

Os atributos definidos por Irons e Petersen (1981) diferem dos de Hsu por usarem, ao invés de apenas uma banda, as bandas adicionais de uma imagem multiespectral. Estes autores fazem uso do conceito de textura multiespectral, tratado por Rosenfeld et alii (1982). Os tons de cinza correspondentes à cada ponto de uma imagem multiespectral com n-bandas pode ser considerado como um vetor n-dimencional $x(i,j)$. A Norma Euclidiana do vetor $x(i,j)$ é a distância da origem ao ponto final do vetor no espaço n-dimencional. Dos onze atributos definidos por Irons e Petersen, apenas dois não fazem uso da Norma Euclidiana dos vetores de tons de cinza representando cada ponto da janela de imagem considerada. Estes atributos, que estão especificados na Tabela 3.1,

podem ser calculados usando-se qualquer combinação de bandas espectrais. Quando se usa apenas uma banda a Norma do vetor unidimensional $x(i,j)$ é equivalente ao nível de cinza $x(i,j)$ da banda considerada.

TABELA 3.1

ATRIBUTOS DEFINIDOS POR IRONS E PETERSEN (1981)

NOME	DESCRIÇÃO	FÓRMULA COMPUTACIONAL
MNL	Média	$\frac{\sum x_{ij}}{n}$ onde x_{ij} = norma do vetor de níveis de cinza para o pixel (i,j) n = número de pixels em uma janela
VNL	Variança	$\frac{\sum (x_{ij} - MNL)^2}{n - 1}$
SKEW	"Skewness"	$\frac{ \sum (x_{ij} - MNL)^3 }{(n - 1)(VNL)^{3/2}}$
KURT	Curtose	$\frac{\sum (x_{ij} - MNL)^4}{(n - 1)(VNL)^2}$
RNL	Intervalo de Variação	$\max(x_{ij}) - \min(x_{ij})$
PSKFM	Segundo Coeficiente de Pearson de "skewness"	$\frac{ MNL - x_m }{(VNL)^{1/2}}$ onde x_m = média das normas dos vetores em uma janela
MDIF	Valor absoluto das diferenças das normas	$\frac{ \sum (x_{ij} - x_c) }{n - 1}$ onde x_c = norma do vetor representando o pixel central de uma janela
MSQ	Média do quadrado das diferenças das normas	$\frac{\sum (x_{ij} - x_c)^2}{n - 1}$
MAXSQ	Máximo do quadrado das diferenças das normas	$\max(x_{ij} - x_c)^2$
MEUC	Distância euclidiana média	$\frac{\sum [\sum_{\lambda} (x_{c\lambda} - x_{ij\lambda})^2]^{1/2}}{n - 1}$ onde $x_{ij\lambda}$ = nível de cinza do pixel (i,j) relativo ao canal λ de uma imagem multispectral $x_{c\lambda}$ = nível de cinza do pixel central da janela para o canal espectral λ
MAXEUC	Distância euclidiana máxima	$\max[\sum_{\lambda} (x_{c\lambda} - x_{ij\lambda})^2]^{1/2}$

Os resultados de classificação alcançados usando-se as transformadas texturais de imagens LANDSAT-MSS (80 metros de resolução) diferem dos obtidos por Hsu. Estas imagens referem-se a uma área à nordeste de Clearfiel County, Pennsilvânia, coberta na maior parte por florestas entremeadas por campos agrícolas e pastagens, sendo grande parte desta área afetada pela mineração de carvão. Diferentes combinações de transformadas texturais foram testadas na identificação automática de categorias de uso do solo, mas nenhum resultado satisfatório foi obtido. As transformadas texturais apenas se mostraram úteis na detecção de bordas ou no realce de imagens. Irons e Petersen apontam como possíveis causas desta diferença contrastante entre os resultados por eles obtidos e aqueles obtidos por Hsu as seguintes:

- (1) uso de dados de imagens em diferentes resoluções nos dois trabalhos
- (2) emprêgo de classificadores diferentes
- (3) número diferente de bandas consideradas no cálculo dos atributos.

Estes dois trabalhos obtiveram apenas uma similaridade de resultados. Como Hsu, Irons e Petersen concluíram que as propriedades de terceira e quarta ordem (incluindo as medidas de assimetria e achatamento) não produzem informações úteis na discriminação das diferentes categorias de uso de solo presentes nas imagens analisadas.

CAPÍTULO 4

PARTE EXPERIMENTAL

4.1 - INTRODUÇÃO

Com o objetivo de se verificarem experimentalmente, os efeitos da variação na resolução espacial na classificação convencional de imagens (classificação convencional usa somente atributos espectrais), foram feitos os testes, com imagens em diferentes resoluções, descritos no próximo item.

Como foi visto nos capítulos anteriores, a classificação ponto a ponto de imagens com níveis elevados de variabilidade radiométrica entre "pixels" de uma mesma classe poderia ser melhorada com o uso de atributos que considerem, também, as características radiométricas dos pontos que constituem a vizinhança de um dado ponto. Estes atributos foram chamados de "atributos de textura".

No Capítulo 3, foi proposto um método para a extração de atributos de textura a partir de uma banda espectral de imagem. No item 4.3 deste capítulo, serão descritos os experimentos necessários à verificação da utilidade destes atributos, na classificação de imagens.

Procurando-se obter um bom exemplo de aplicação para os atributos de textura, buscou-se, junto aos pesquisadores do Departamento de Pesquisa e Aplicações em Sensoriamento Remoto, uma imagem onde se pudesse identificar pelo menos duas classes distintas de textura e que fosse relativa a uma região da qual se tivesse bom conhecimento da verdade terrestre. Optou-se, então, por se trabalhar com imagens de áreas urbanas, por apresentarem

uma textura característica e contrastante com a das áreas não urbanizadas.

Assim, foi escolhida como área teste a cidade de São José dos Campos, que se localiza a 23 10' de latitude sul e 45 50' de longitude oeste de Greenwich, no Estado de São Paulo. Esta área é abrangida pela imagem TM LANDSAT, órbita 219/76E de 7 de novembro de 1985 (Figura 4.1). Na verificação dos resultados, foi utilizado, como verdade terrestre, o mapa de uso da terra do Município de São José dos Campos, obtido a partir de fotografias aéreas na escala de 1:25000 referentes a agosto de 1985 (Pereira et alii, 1988).



Fig. 4.1 - Imagem TM/LANDSAT de São José dos Campos (R: banda 5, G: banda 4, B: banda 3).

A classificação supervisionada da imagem teste foi feita a partir da utilização do algoritmo de

máxima verossimilhança com hipótese gaussiana para as classes. Este algoritmo está implementado no SITIM - Sistema de Tratamento de Imagens - com o nome de MAXVER.

A escolha das amostras de treinamento foi feita com base nas bandas espectrais do TM, principalmente a banda 3.

Analisando-se a imagem na composição colorida, pôde-se identificar quatro subclasses com características espectrais bem distintas dentro da classe urbana e seis subclasses na classe não urbana. Assim, todo o procedimento de classificação foi feito considerando-se estas dez subclasses. São elas:

áreas urbanas	residencial 1
	residencial 2
	indústria
	loteamento
áreas não urbanas	solo preparado
	vegetação natural/artificial
	pastagem melhorada
	pastagem natural
	pastagem
	área agrícola

Para fins de verificação de desempenho de classificação estas subclasses foram, no final, reagrupadas de modo a ser ter, novamente, apenas as classes urbana e não urbana.

A composição colorida das bandas 5, 4 e 3 do TM com amostras de treinamento é mostrada na Figura 4.2. Na Figura 4.3, são mostradas as amostras teste.



Fig. 4.2 - Composição colorida: R - banda 5, G - banda 4, B - banda 3 com amostras de treinamento.




Fig. 4.3 - Amostras teste.

Na Tabela 4.1 tem-se o número de elementos de cena das áreas de treinamento e áreas teste para cada classe.

TABELA 4.1

NÚMERO DE ELEMENTOS DE CENA PARA AMOSTRAS DE TREINAMENTO
E AMOSTRAS TESTE

CLASSES	AMOSTRAS TREINAMENTO	AMOSTRAS TESTE
1.URBANA	1140	3093
2.NÃO URBANA	643	2815
TOTAL	1783	5908

A verificação do desempenho de classificação foi feita através de matrizes de classificação para áreas teste e áreas de treinamento. Essas matrizes apresentam, de forma sucinta, o resultado da classificação de áreas com verdade terrestre conhecida, fornecendo a porcentagem de elementos de cena de cada classe classificados em cada uma das classes adquiridas. A matriz de classificação também fornece a porcentagem de elementos de cena de cada classe, que não foram classificados. A partir dessas matrizes, se obtém o "desempenho médio" (DM), que fornece a porcentagem de elementos de cena corretamente classificados, a "abstenção média" (AM), que fornece a porcentagem de elementos de cena não classificados e a "confusão média"

(CM), que fornece a percentagem de elementos de cena classificados incorretamente.

4.2 - AVALIAÇÃO DA INFLUÊNCIA DA RESOLUÇÃO NA CLASSIFICAÇÃO

4.2.1 - DESCRIÇÃO DOS EXPERIMENTOS

Na verificação da influência da resolução na classificação, foram usadas três imagens com resoluções diferentes. Para que se pudesse ter imagens relativas a uma mesma região em uma mesma data, foram feitas duas simulações de imagens. Uma com resolução próxima à do sensor MSS e outra com resolução próxima à do sensor que equipará o primeiro Satélite Brasileiro de Sensoriamento Remoto - SSR-1, que deverá ser de 200 metros. Visando a facilitar, em trabalhos futuros, a redução das imagens filtradas, as simulações foram feitas de modo a se terem 90 metros de resolução para a imagem MSS aproximada (3 vezes 30 metros) e 210 metros para a imagem SSR aproximada (7 vezes 30 metros).

Estas imagens foram obtidas por meio da convolução da banda 3 da imagem TM de São José dos Campos, com máscaras de degradação. Os dados que permitiram estas simulações podem ser encontrados em BANON (1989).

Para gerar a imagem MSS aproximada, foi repetido, por quatro vezes, o procedimento de filtragem linear da imagem TM, usando-se a seguinte máscara que permite a mesma perda de resolução tanto nas linhas, quanto nas colunas:

90	120	90
120	160	120
90	120	90

A imagem SSR aproximada foi gerada repetindo-se, por tres vezes, o procedimento de filtragem linear da imagem TM. No entanto, nesta filtragem com uma máscara 3x3, para cada grupo de pontos de um bloco de 7 linhas e 7 colunas de imagem (numeradas de 1 a 7), são utilizados somente os pontos das linhas e colunas 1, 4 e 7, pulando-se, portanto, de 3 em 3 linhas e colunas a cada vez. A máscara usada foi a seguinte:

73	124	73
124	212	124
73	124	73

De posse de imagens com 30, 90 e 210 metros de resolução, foram feitas 7 seções de classificação, utilizando-se, assim, todas as combinações possíveis destas imagens com resoluções diferentes, usando-se, sempre, apenas uma banda de cada imagem. Para maior simplicidade, estas imagens foram denominadas por TM, MSS e SSR. Nas figuras 4.4 e 4.5, têm-se as imagens MSS e SSR, respectivamente.




Fig. 4.4 - Imagem simulada com resolução próxima ao MSS. (com ampliação de 3 vezes).




Fig. 4.5 - Imagem simulada com resolução próxima ao SSR. (com ampliação de 7 vezes).

Os limiares de classificação usados para todas as combinações de bandas foram os correspondentes a 95% de aceitação.

Os resultados das classificações feitas usando-se as seguintes combinações de imagens são mostrados nas figuras 4.6 à 4.12:

- 1) TM (Figura 4.6)
- 2) MSS (Figura 4.7)
- 3) SSR (Figura 4.8)
- 4) TM + MSS (Figura 4.9)
- 5) TM + SSR (Figura 4.10)
- 6) MSS + SSR (Figura 4.11)
- 7) TM + MSS + SSR (Figura 4.12)

Em cada uma destas figuras são mostradas as distribuições dos pixels em seis subclasses (duas da classe "urbana" e quatro da "não urbana"). Este procedimento teve por objetivo mostrar onde ocorrem os erros mais graves de confusão entre as classes "urbana" e "não urbana". Assim, as dez subclasses (mencionadas na seção anterior) foram agrupadas da seguinte forma:

classe 1 (em vermelho): res.1/res.2	urbana
classe 2 (em amarelo): lot./ind.	
classe 3 (em branco): solo preparado	
classe 4 (em verde): área agrícola	não
classe 5 (em azul): vegetação nat./artif.	urbana
classe 6 (em azul claro): pastagens	




Fig. 4.6 - Classificação usando imagem TM (banda 3).




Fig. 4.7 - Classificação usando imagem MSS.




Fig. 4.8 - Classificação usando imagem SSR.





Fig. 4.9 - Classificação usando imagens TM e MSS.



Pag. 4.10 - Classificação usando imagens TM e SSR.




Fig. 4.11 - Classificação usando imagens MSS e SSR.




Fig. 4.12 - Classificação usando imagem TM, MSS e SSR.

Para avaliação quantitativa do desempenho de classificação, obtido através de matrizes de classificação, foram consideradas, novamente, apenas as classes globais "urbana" e "não urbana". As matrizes de classificação para áreas de treinamento e amostras teste se encontram nas Tabelas 4.2 à 4.8.

TABELA 4.2

MATRIZES DE CLASSIFICAÇÃO PARA AMOSTRAS DE TREINAMENTO E
AMOSTRAS TESTE USANDO IMAGEM TM

CLASSES	AMOSTRAS TREINAMENTO			AMOSTRAS TESTE		
	N	1	2	N	1	2
1.URBANA	0,61	45,88	53,51	1,49	50,57	47,95
2.NÃO URBANA	0,31	1,40	98,29	1,99	0	98,01
	DM = 64,78 %			DM = 73,17 %		
	AM = 0,50 %			AM = 1,73 %		
	CM = 34,72 %			CM = 25,10 %		

N = Não classificado, DM = Desempenho Médio, AM = Abstenção Média, CM = Confusão Média.

TABELA 4.3

MATRIZES DE CLASSIFICAÇÃO PARA AMOSTRAS DE TREINAMENTO E
AMOSTRAS TESTE USANDO IMAGEM MSS

CLASSES	AMOSTRAS TREINAMENTO			AMOSTRAS TESTE		
	N	1	2	N	1	2
1.URBANA	2,19	58,16	39,65	9,47	57,19	33,33
2.NÃO URBANA	0,78	2,64	96,58	12,40	0,99	86,61
	DM = 72,01 %			DM = 71,21 %		
	AM = 1,68 %			AM = 10,87 %		
	CM = 26,30 %			CM = 17,92 %		

N = Não classificado, DM = Desempenho Médio, AM = Abstenção Média, CM = Confusão Média.

TABELA 4.6

MATRIZES DE CLASSIFICAÇÃO PARA AMOSTRAS DE TREINAMENTO E
AMOSTRAS TESTE USANDO IMAGENS TM E SSR

CLASSES	AMOSTRAS TREINAMENTO			AMOSTRAS TESTE		
	N	1	2	N	1	2
1.URBANA	2,81	82,89	14,30	5,95	82,80	11,25
2.NÃO URBANA	2,02	0,93	97,05	25,61	5,65	68,74
	DM = 88,00 %			DM = 76,10 %		
	AM = 2,52 %			AM = 15,32 %		
	CM = 9,48 %			CM = 8,58 %		

N = Não classificado, DM = Desempenho Médio, AM = Abstenção Média, CM = Confusão Média.

TABELA 4.7

MATRIZES DE CLASSIFICAÇÃO PARA AMOSTRAS DE TREINAMENTO E
AMOSTRAS TESTE USANDO IMAGENS MSS E SSR

CLASSES	AMOSTRAS TREINAMENTO			AMOSTRAS TESTE		
	N	1	2	N	1	2
1.URBANA	2,37	82,37	15,26	14,10	77,47	8,44
2.NÃO URBANA	1,71	0,47	97,82	31,33	7,10	61,56
	DM = 87,94 %			DM = 69,89 %		
	AM = 2,13 %			AM = 22,31 %		
	CM = 9,93 %			CM = 7,80 %		

N = Não classificado, DM = Desempenho Médio, AM = Abstenção Média, CM = Confusão Média.

TABELA 4.4

MATRIZES DE CLASSIFICAÇÃO PARA AMOSTRAS DE TREINAMENTO E
AMOSTRAS TESTE USANDO IMAGEM SSR

CLASSES	AMOSTRAS TREINAMENTO			AMOSTRAS TESTE		
	N	1	2	N	1	2
1.URBANA	0,00	71,14	28,86	0,16	80,80	19,04
2.NÃO URBANA	0,47	2,64	96,89	23,34	1,03	75,63
	DM = 80,43 % AM = 0,17 % CM = 19,40 %			DM = 78,33 % AM = 11,21 % CM = 10,46 %		

N = Não classificado, DM = Desempenho Médio, AM = Abstenção Média, CM = Confusão Média.

TABELA 4.5

MATRIZES DE CLASSIFICAÇÃO PARA AMOSTRAS DE TREINAMENTO E
AMOSTRAS TESTE USANDO IMAGENS TM E MSS

CLASSES	AMOSTRAS TREINAMENTO			AMOSTRAS TESTE		
	N	1	2	N	1	2
1.URBANA	3,42	74,30	22,28	9,96	68,02	22,02
2.NÃO URBANA	2,64	2,80	94,56	11,40	3,73	84,87
	DM = 81,60 % AM = 3,14 % CM = 15,26 %			DM = 76,05 % AM = 10,65 % CM = 13,30 %		

N = Não classificado, DM = Desempenho Médio, AM = Abstenção Média, CM = Confusão Média.

TABELA 4.8

MATRIZES DE CLASSIFICAÇÃO PARA AMOSTRAS DE TREINAMENTO E
AMOSTRAS TESTE USANDO IMAGENS TM MSS E SSR

CLASSES	AMOSTRAS TREINAMENTO			AMOSTRAS TESTE		
	N	1	2	N	1	2
1.URBANA	3,95	89,47	6,58	16,84	77,30	5,85
2.NÃO URBANA	4,04	1,25	94,71	29,06	7,78	63,16
		DM = 91,36 %			DM = 70,57 %	
		AM = 3,98 %			AM = 22,66 %	
		CM = 4,66 %			CM = 6,77 %	

N = Não classificado, DM = Desempenho Médio, AM = Abstenção Média, CM = Confusão Média.

4.2.2 - ANÁLISE DOS RESULTADOS

Analisando-se as imagens classificadas das Figuras 4.6, 4.7 e 4.8, observa-se que, se a subclasse "área agrícola", que tem características bem próximas às de subclasses urbanas, não tivesse sido considerada, a área urbanizada ficaria melhor delimitada nas imagens de menor resolução. Vê-se que existe muita semelhança entre as classes, e algumas delas podem ser distingüidas visualmente apenas na imagem TM, justamente por apresentarem textura diferentes. Assim, o processo de degradação da imagem TM não contribuiu muito para a melhoria do desempenho de classificação. Mesmo assim, nota-se um maior agregamento de pontos classificados em uma só classe quando foram usadas imagens com resolução mais baixa. Destes agregamentos de

pontos podem ser tiradas algumas informações úteis. Por exemplo, conhecendo-se os limites da área urbana, nota-se que na região central da cidade formou-se um agregamento de elementos de cena classificados como "urbanos", o que indica ser grande a concentração urbana. Já nos bairros extritamente residenciais, onde a taxa de ocupação é menor, sendo grande a presença de áreas verdes, ocorreu um agregamento de elementos de cena classificados como "área agrícola".

Observa-se através das matrizes de classificação, um melhor desempenho, em relação ao obtido com a imagem TM, quando foi usada imagem SSR, apesar do aumento na abstenção média nas áreas teste. Já a classificação da imagem MSS apresentou pior desempenho para áreas teste. Isto devido também ao aumento na abstenção média não contrabalançado pela queda na confusão média. Quanto ao uso conjunto de imagens com diferentes resoluções (Tabelas 4.5 a 4.8), nota-se que, apesar do bom desempenho apresentado para áreas de treinamento, a imagem MSS contribuiu menos, para a melhoria do desempenho de classificação, que a imagem SSR. Percebe-se, ainda, que houve um aumento na abstenção média, sempre que foram usadas imagens MSS e/ou SSR. Isto provavelmente ocorreu porque, na geração destas imagens, o valor original (na imagem TM) de cada pixel foi alterado, sendo substituído por um novo valor, resultante da integração de valores de pixels vizinhos; como muitas vezes alguns pixels pertencem a classes diferentes, o valor resultante pôde não se enquadrar em nenhuma das classes existentes. Verifica-se, portanto, o problema dos "pixels misturados".

É ainda interessante observar que, nas imagens MSS e SSR classificadas, percebe-se um nítido contorno em algumas regiões da imagem. Estes contornos são

formados por pontos não classificados ou por uma estreita faixa de pontos com uma classe diferente da presente no interior da região, seguida de outro contorno de pontos com uma outra classe. Este fato pode também ser explicado pelo resultado da integração de valores de pixels vizinhos. Nas regiões de transição, à medida que se caminha do interior de uma região para a sua borda, os valores dos pixels ora são mais influenciados pela classe interna ora pela classe externa, resultando, assim, em valores intermediários entre as duas classes. Como algumas das subclasses urbanas e não urbanas se intercalam na escala de níveis de cinza, os pixels são atribuídos ora a uma subclasse ora a outra.

4.3 - TESTE DOS ATRIBUTOS DE TEXTURA

4.3.1 - INTRODUÇÃO

No Capítulo 3 foram apresentados doze atributos de textura que podem ser calculados usando-se os níveis de cinza dos nove elementos de imagem em uma janela 3x3, e oito atributos que podem ser calculados usando-se os níveis de cinza dos vinte e cinco elementos de imagem em uma janela 5x5. Como foi visto, para cada um desses atributos pode-se gerar uma nova banda de imagem, chamada aqui de "banda de textura".

Os programas que geram as "bandas de textura" foram implementados no Sistema de Tratamento de Imagens - SITIM. Esses foram feitos em linguagem C e usam as Rotinas Básicas do Sitim na comunicação de dados.

Tendo sido geradas, essas bandas ficam armazenadas em disco, passando a fazer parte do conjunto de

atributos da imagem, a partir da qual foram geradas. Assim, as bandas de textura podem ser tratadas da mesma maneira que uma banda espectral de imagem, podendo ser visualizadas, realçadas, filtradas e, o que é mais importante, usadas na classificação.

Para fins de teste, as vinte "bandas de textura" foram geradas a partir da banda 3 original da imagem de São José dos Campos. As "bandas de textura" foram denominadas da seguinte maneira: as bandas obtidas usando-se janelas 3x3 são T1, T2, T3, T4, T5, T6, T7, T8, T9, T10, T11 e T12, com os números correspondendo aos tipos de atributos calculados (f1 a f12); as bandas geradas a partir de janelas 5x5 são 5T2, 5T4, 5T6, 5T8, 5T9, 5T10, 5T11 e 5T12.

4.3.2 - SELEÇÃO DOS ATRIBUTOS DE TEXTURA

Como se têm vários atributos de textura, a adoção de mecanismos de seleção de atributos se fez necessária.

O primeiro critério de seleção adotado parte do princípio de que os melhores atributos seriam aqueles segundo os quais as distribuições de probabilidade das diversas classes contidas na imagem apresentem-se mais próximas da distribuição normal ou gaussiana. Este critério não se baseia na questão relativa ao desempenho de classificação - como é usual - e, sim, na consideração de que, para uma dada classe, um dado atributo deve assumir valores homogêneos, ou sejam, valores com pouca variação em torno de uma média.

Assim, foi implementado um programa, que dá uma indicação relativa de quão próxima a distribuição de

probabilidade de uma dada classe encontra-se de uma distribuição normal, através do cálculo do qui-quadrado (Brandt, 1983; Cochran, 1952).

Como saída, o programa fornece um valor alfa, que é a probabilidade de o qui-quadrado assumir um valor maior do que seu valor observado, supondo-se que a hipótese de normalidade é verdadeira. Quanto menor for alfa, menos próxima a distribuição testada encontra-se de uma distribuição normal.

Na Tabela 4.9 é apresentado um quadro comparativo com o resultado do cálculo de alfa para duas classes com características espectrais semelhantes e texturas distintas, segundo cada atributo de textura. Neste quadro têm-se, além do valor de alfa, o intervalo de variação dos valores para cada classe, a média e o desvio padrão.

TABELA 4.9

RESULTADOS DO CÁLCULO DE ALFA PARA BANDAS DE TEXTURA

Banda	3 TM		T1		T2	
	amostra 1	amostra 2	amostra 1	amostra 2	amostra 1	amostra 2
intervalo	40 - 66	44 - 91	0 - 48	8 - 101	42 - 177	29 - 179
média	56,84	69,53	9,63	36,62	112,33	109,62
desvio padrão	3,81	8,42	6,63	15,12	28,36	26,05
alfa (%)	0,00	8,54	0,00	0,00	33,06	44,89

Banda	T3		T4		T5	
	amostra 1	amostra 2	amostra 1	amostra 2	amostra 1	amostra 2
intervalo	0 - 39	7 - 92	2 - 33	11 - 52	0 - 31	6 - 71
média	8,02	31,16	7,74	28,10	7,95	30,74
desvio padrão	5,75	14,05	4,36	8,10	4,95	12,88
alfa (%)	0,00	0,00	0,00	8,40	0,00	0,02

(continua)

Tabela 4.9 - Continuação

Banda	T6		T7		T8	
	amostra 1	amostra 2	amostra 1	amostra 2	amostra 1	amostra 2
intervalo	2 - 32	11 - 66	4 - 200	2 - 200	40 - 61	44 - 73
média	7,99	30,88	121,98	118,49	54,00	58,34
desvio padrão	4,55	9,55	56,20	56,42	3,43	6,44
alfa (%)	0,00	37,48	0,00	0,00	0,00	0,00

Banda	T9		T10		T11	
	amostra 1	amostra 2	amostra 1	amostra 2	amostra 1	amostra 2
intervalo	51 - 66	66 - 91	1 - 24	8 - 39	2 - 35	9 - 32
média	60,07	80,76	6,07	22,43	9,73	37,99
desvio padrão	2,91	4,65	3,39	6,93	5,37	13,58
alfa (%)	0,00	0,00	0,00	0,58	0,00	0,00

Tabela 4.9 - Continuação

Banda	T12		5T2		5T4	
	amostra 1	amostra 2	amostra 1	amostra 2	amostra 1	amostra 2
intervalo	1 - 23	6 - 51	87 - 179	71 - 159	4 - 22	20 - 47
média	5,51	22,84	132,18	119,33	9,34	31,10
desvio padrão	3,41	8,54	18,51	14,01	3,33	5,52
alfa (%)	0,00	2,32	20,27	63,77	20,88	23,65

Banda	5T6		5T8		5T9	
	amostra 1	amostra 2	amostra 1	amostra 2	amostra 1	amostra 2
intervalo	4 - 17	20 - 50	40 - 59	44 - 69	57 - 66	77 - 91
média	7,98	31,63	52,80	53,38	61,99	84,23
desvio padrão	2,84	6,47	3,28	5,97	2,09	3,51
alfa (%)	0,18	48,76	0,00	0,00	0,48	0,00

Tabela 4.9 - Conclusão

Banda	5T10		5T11		5T12	
	amostra 1	amostra 2	amostra 1	amostra 2	amostra 1	amostra 2
intervalo	4 - 24	17 - 42	16 - 72	77 - 240	3 - 14	14 - 46
média	9,19	30,85	34,10	141,57	6,44	27,79
desvio padrão	3,47	6,04	11,27	31,90	2,18	6,04
alfa (%)	0,00	0,00	7,81	8,77	0,49	40,44

amostra 1 - classe não urbana

amostra 2 - classe urbana.

Como segundo critério de seleção, adotou-se um procedimento de análise visual de cada "banda de textura". Os pontos determinantes neste tipo de seleção estão relacionados com o desempenho de classificação. Um bom atributo de textura deve apresentar valores homogêneos para uma dada classe de textura, sendo estes valores ao mesmo tempo contrastantes com os de outras classes.

Teoricamente, os atributos de textura representam uma medida da variação local dos níveis de cinza da imagem da qual foram extraídos. Assim, é de se esperar que as áreas com textura de aparência "lisa" apresentem valores baixos nas "bandas de textura", indicando pouca variação local. Já nas regiões com textura "rugosa", esperam-se valores mais altos.

Na prática isto é verificado, mas surge também um fator indesejável. Observa-se nas "bandas de textura" um acentuado realçamento de bordas. Borda é o limite entre duas regiões com características (ou classes) diferentes. Sendo uma medida da variação local na imagem, os atributos de textura apresentam valores muito elevados nestas regiões de transição. Alguns atributos são mais sensíveis às transições, considerando como bordas até mesmo micropadrões de textura. Como a presença acentuada de bordas prejudica o desempenho de classificação, pois as bordas tendem a não ser classificadas, este fato também foi considerado na seleção de atributos.

Baseando-se nestes dois critérios, foram selecionadas como melhores bandas aquelas geradas com janelas 5x5 e atributos f6 e f12 denominadas, respectivamente, por bandas 5T6 e 5T12. Na Figura 4.13 é mostrada a banda 3 do TM, a partir da qual foram geradas as

"bandas de textura". Nas Figuras 4.14 e 4.15 têm-se as bandas 5T6 e 5T12.




Fig. 4.13 - Imagem de São José dos Campos
banda 3 do TM/LANDSAT.




Fig. 4.14 - Banda de textura (5T6).




Fig. 4.15 - Banda de textura (5T12).

4.3.3 - CLASSIFICAÇÃO

A fim de verificar o efeito do uso de atributos de textura na identificação de áreas urbanizadas na imagem de São José dos Campos, foram consideradas apenas as classes "urbana" e "não urbana".

A avaliação do efeito da adição de atributos de textura na classificação foi realizada comparando-se os resultados obtidos nas classificações e usando-se as seguintes combinações de bandas:

- bandas 3, 4 e 5 do TM (Figura 4.16)
- bandas 3 e 4 do TM e 5T12 (Figura 4.17)
- bandas 3 do TM, 5T6 e 5T12 (Figura 4.18)

O limiar usado na classificação foi o correspondente ao limite de 95 % de aceitação.




Fig. 4.16 - Classificação da imagem teste usando bandas 3, 4 e 5 do TM.



Fig. 4.17 - Classificação da imagem teste usando bandas 3, 4 do TM e 5T12.




Fig. 4.18 - Classificação da imagem teste usando bandas 3 do TM, 5T6 e 5T12.

Nas Tabelas 4.10 a 4.12 são apresentadas as matrizes de classificação para áreas de treinamento e áreas teste.

TABELA 4.10

MATRIZES DE CLASSIFICAÇÃO PARA AMOSTRAS DE TREINAMENTO E
AMOSTRAS TESTE USANDO BANDAS 3 4 5 TM

CLASSES	ÁREAS DE TREINAMENTO			AMOSTRAS TESTE		
	N	1	2	N	1	2
1.URBANA	3,25	76,49	20,26	4,33	75,17	20,50
2.NÃO URBANA	3,73	2,95	93,31	28,67	19,57	51,76
	DM = 82,56 %			DM = 64,01 %		
	AM = 3,42 %			AM = 15,93 %		
	CM = 14,02 %			CM = 20,06 %		

N = Não classificado, DM = Desempenho Médio, AM = Abstenção Média, CM = Confusão Média.

TABELA 4.11

MATRIZES DE CLASSIFICAÇÃO PARA AMOSTRAS DE TREINAMENTO E
AMOSTRAS TESTE USANDO BANDAS 3 4 TM E 5T12

CLASSES	ÁREAS DE TREINAMENTO			AMOSTRAS TESTE		
	N	1	2	N	1	2
1.URBANA	3,33	96,14	0,53	8,31	90,91	0,78
2.NÃO URBANA	4,67	0,15	95,18	42,45	1,78	55,77
	DM = 95,79 %			DM = 74,17 %		
	AM = 3,81 %			AM = 24,58 %		
	CM = 0,39 %			CM = 1,25 %		

N = Não classificado, DM = Desempenho Médio, AM = Abstenção Média, CM = Confusão Média.

TABELA 4.12

MATRIZES DE CLASSIFICAÇÃO PARA AMOSTRAS DE TREINAMENTO E
AMOSTRAS TESTE USANDO BANDAS 3 TM 5T6 E 5T12

CLASSES	ÁREAS DE TREINAMENTO			AMOSTRAS TESTE		
	N	1	2	N	1	2
1.URBANA	3,77	95,70	0,53	9,73	89,59	0,68
2.NÃO URBANA	4,04	0,16	95,80	15,38	2,20	82,42
		DM = 95,74 %			DM = 86,17 %	
		AM = 3,87 %			AM = 12,42 %	
		CM = 0,39 %			CM = 1,40 %	

N = Não classificado, DM = Desempenho Médio, AM = Abstenção Média, CM = Confusão Média.

4.3.4 - ANÁLISE DOS RESULTADOS

A análise qualitativa das imagens classificadas nas Figuras 4.16 a 4.18 mostra uma melhor definição das áreas urbanizadas quando foram usados atributos de textura. Na classificação com base nos atributos puramente espectrais, pode-se verificar um espalhamento, por toda a imagem, de pontos atribuídos à classe urbana. Isto se deve ao fato de as classes possuírem objetos comuns, como, por exemplo, áreas de solo exposto. Com o uso de atributos de textura este problema é minimizado, pois são consideradas as características do arranjo dos objetos em cada classe.

Nas classificações onde foram usados atributos de textura pôde-se notar que muitos dos erros de

classificação foram provocados pelo efeito de "realçamento de bordas" na bandas de textura. Nestas bandas, as bordas, além de serem realçadas, foram também alargadas. Como a classe urbana apresenta predominância de níveis de cinza mais altos, todas as bordas foram atribuídas a esta classe.

As bordas nas bandas de textura surgem, muitas vezes, porque as janelas usadas na extração de atributos de textura são pequenas em relação a alguns padrões de textura; certos subpadrões, como, por exemplo, os contornos das sombras formadas nas regiões montanhosas, são isoladas como bordas. Também relacionado com o tamanho das janelas, está o problema de "alargamento de bordas". Quanto maior a janela usada, maior é o "alargamento de bordas". Isto porque janelas maiores abrangem maior área da imagem e, assim, mesmo janelas referentes a pixels distantes das bordas ainda apresentam grande variação local.

Em termos quantitativos, através dos dados constantes das matrizes de classificação, pode-se verificar que a adição de atributos de textura na classificação da imagem teste resultou em um melhor desempenho na identificação de áreas urbanizadas. Apesar de ainda não se ter conseguido um bom desempenho de classificação para áreas teste, o uso da textura veio contribuir bastante para o decréscimo da confusão média na classificação.

CAPÍTULO 5

COMENTÁRIOS FINAIS

Na verificação da influência da resolução espacial na classificação, observou-se que existem situações em que o uso de imagens de resolução mais baixas pode contribuir para a melhoria do desempenho de classificação. Mas, para isto, é preciso que as classes, nas imagens de alta resolução, não apresentem médias muito próximas.

Nos casos de classes com médias próximas, a textura pode ser útil para a diferenciação destas classes, sendo assim necessário o uso de imagens de alta resolução. Também na obtenção de informações detalhadas a respeito de pequenas regiões é preciso se trabalhar com imagens de alta resolução.

As imagens de baixa resolução são muito úteis na extração de informações globais a respeito de grandes extensões.

Assim sendo, em se podendo escolher a resolução da imagem de uma certa área, conclui-se que esta escolha deve ser influenciada principalmente pelos seguintes fatores: extensão da área que se quer estudar (continente, país, estado, município etc) e tipo de informação que se deseja obter. Por exemplo, ao analisar uma área onde se encontram florestas, é preciso saber se o objetivo é fazer um levantamento da cobertura vegetal da região visando a estudos climáticos ou se se está procurando identificar áreas desmatadas. No primeiro caso, o mais apropriado seria uma imagem que cobrisse uma região maior, sendo, portanto, uma imagem de baixa resolução. No

segundo caso seria mais indicado o uso de uma imagem de alta resolução, pelo fato de se poder identificar mais detalhes. Para isto é necessária a aplicação de métodos de classificação que considerem esta característica das imagens de alta resolução.

Quanto ao uso de atributos de textura na classificação, verificou-se que houve grande melhoria no desempenho de classificação, mas, ainda assim, ocorreram muitos erros de classificação. A partir da análise destes erros, algumas observações podem ser feitas.

Notou-se que muitos dos erros de classificação estão relacionados com o tamanho de janelas usado na extração dos atributos de textura. O ideal seria que se pudesse encontrar um tamanho ótimo de janelas, tamanho este dependente do tipo de cena e resolução da imagem. Além disto, seria recomendável que as janelas fossem menores próximo às regiões de transição. Talvez a melhor opção fosse a adoção de abordagens do tipo piramidal, pois assim poder-se-ia ter janelas de tamanhos diferentes para diferentes regiões na imagem. Para isto, no entanto, seria necessário o uso de hardwares mais eficientes (por exemplo, uso de placas aceleradoras).

Outro fator importante é a definição das classes de textura. As classes precisam ser escolhidas de forma a se terem padrões de textura mais homogêneos. No caso da imagem teste, foram consideradas como classes de textura distintas a área urbana e a área não urbana. No entanto, nota-se que, apesar de a área urbana apresentar um padrão característico, muitas são as discontinuidades ocorridas neste padrão. Nas áreas residenciais, por exemplo, estas discontinuidades são causadas por objetos (lembrando aqui o modelo de discreto da cena), não muito

comuns a estas áreas, dispostos de maneira irregular na cena, não fazendo parte do conjunto dos objetos que contribuem para a formação do padrão de textura característico. Estes objetos são, por exemplo, grandes áreas verdes, ginásios esportivos ou outros grandes galpões. Como, em geral, as janelas usadas na extração de atributos são menores ou de tamanho comparável a estes objetos, as bordas destes objetos ficaram bem marcadas nas "bandas de textura". Assim, a classe urbana apresentou-se, ainda, com certa heterogeneidade, nas "bandas de textura".

Como se pode ver, o problema de extração de atributos de textura, aplicado a um caso prático, como o da classificação da imagem de São José dos Campos, torna-se ainda mais complexo. Dependendo do grau de precisão de classificação que se deseja, talvez o problema não possa ser tratado de maneira tão simplificada como foi feito neste trabalho. No entanto, deve-se salientar que é preciso estabelecer um compromisso entre o desempenho de classificação desejado e o tempo de computação requerido para se alcançar este desempenho.

Na tentativa de se explicarem os erros de classificação observados, sentiu-se a necessidade de se fazer referência a um modelo que descreva a cena. Com base neste modelo, pode-se constatar que muitos erros de confusão na classificação se explicam pela existência de objetos comuns a mais de uma classe. Isto leva a concluir que, talvez, muitos erros, ao invés de serem agora explicados, poderiam não ter sido cometidos, se a classificação tivesse sido feita com o modelo da cena em mente.

Pensando-se na classificação com base em atributos espectrais, seria conveniente que, de posse de um

modelo hierárquico da cena que se deseja estudar, as classes de informação a serem extraídas da imagem estivessem a um nível compatível com a resolução da imagem. Isto é, a nível dos elementos de cena possíveis de serem identificados na imagem. Desejando-se classes mais abrangentes (de nível mais elevado), a classificação deveria ser feita em etapas. Numa primeira etapa, as classes estariam no nível compatível com a resolução; posteriormente, as classes seriam reagrupadas para formar as classes do nível superior e assim por diante, até chegar-se ao nível desejado. No caso das classes compartilharem elementos comuns, informações do tipo "contexto" poderiam ser usadas. Este procedimento de se fazer a classificação em etapas na verdade se enquadra dentro da abordagem piramidal.

É também preciso lembrar que a textura não é uma característica apenas das imagens de alta resolução. Nas imagens de baixa resolução, também poderão ser notados padrões de textura. A diferença é que estarão em uma escala diferente. Por exemplo, na imagem teste, apesar de não ser perceptível, devido à ampliação da imagem, o padrão formado nas regiões montanhosas na imagem TM provavelmente poderá ser observado na imagem SSR.

Assim, é importante que se continue a buscar métodos eficientes para a extração de atributos de textura que, sendo uma característica tão utilizada na interpretação visual de imagens, não pode deixar de ser usada nos procedimentos automáticos.

REFERÊNCIAS BIBLIOGRÁFICAS

- AHUJA, N.; ROSENFELD, A. Mosaic models for textures. IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-3(1):1-11, Jan. 1981.
- BANON, G.J.F. Simulação de imagens de baixa resolução. Submetido à Revista da Sociedade Brasileira de Automação; SBA: Controle e Automação, em Abril de 1989.
- BRANDT, S. Statistical and computational methods in data analysis. 2.ed. rev. Amsterdam, North-Holland, 1983.
- BURT, P.J.; HONG, T.H.; ROSENFELD, A. Segmentation and estimation of image region properties through cooperative hierarchical computation. IEEE Transactions on Systems, Man and Cybernetics, SMC-11(12):802-809, Dec. 1981.
- CHEN, P.C.; PAVLIDIS, T. Image segmentation as an estimation problem. Computer Graphics and Image Processing, 12(2):153-172, Feb. 1980.
- COCHRAN, W.G. The test of goodness and fit. Annals of Mathematical Statistics, 23:315-345, 1952.
- CONNERS, R.W.; HARLOW, C.A. A theoretical comparison of texture algorithms. IEEE Transactions on Pattern Analysis and Machine Intelligence. PAMI-2(3):204-222, May 1980.

- CORREIA, V.R.M. Estudo de medidas de qualidade para estimação de proporções de classe em elementos de resolução de imagens. Dissertação de Mestrado em Análise de Sistemas. São José dos Campos, INPE, Abril 1983. (INPE-2712-TDL/131).
- DONDES, P.A.; ROSENFELD, A. Pixel classification based on local "busyness". IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-4(1):79-84, Jan. 1982.
- GOOL, L.V.; DEWAELE, P.; OOSTERLINCK, A. Texture analysis anno 1983. Computer Vision, Graphics and Image Processing, 29(3):336-357, Mar. 1985.
- HARALICK, R.M. Statistical and structural approaches to texture. Proceedings of the IEEE, 67(5):786-804, May 1979.
- HARALICK, R.M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. IEEE Transactions on Systems, Man and Cybernetics, SMC-3(6):610-621, Sept. 1973.
- HORWITZ, H.M.; LEWIS, J.T.; PENTLAND, A.P. Estimating proportions of objects from multispectral scanner data. Final Report, Ann Arbor, MI, ERIM 117p. May 1975. (NASA CR-141862).
- HSU, S. Texture-tone analysis for automated land-use mapping. Photogrammetric Engineering and Remote Sensing, 44(11):1393-1404, Nov. 1978.
- IRONS, J.R.; PETERSEN, G.W. Texture transforms of remote sensing data. Remote Sensing of Environment, 11(4):359-370, Sept. 1981.

- ISHIZAWA, Y. The japonese MOS and LOS program. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 15., Ann Arbor, MI, May 1981. Proceedings. Ann Arbor, MI, 1981. p.433-443.
- LATTY, R.S.; HOFFER, R.M. Computer-based classification accuracy due to the spacial resolution using per-point versus per-field classification techniques. In: INTERNATIONAL SYMPOSIUM ON MACHINE PROCESSING OF REMOTELY SENSED DATA, 7., West Lafayette, IN, June 23-26, 1981. Proceedings. West Lafayette, IN, Purdue University, 1981. p.384-393.
- MARKHAM, B.L.; TOWNSHEND, J.R.G. Land cover classification accuracy as a function of sensor spatial resolution. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 15., Ann Arbor, MI, May 1981. Proceedings. Ann Arbor, MI, ERIM, 1981. p.1075-1090.
- NALEPKA, R.F.; HYDE, P.D. Classifying unresolved objects from simulated space data. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 8., Ann Arbor, MI, 1972. Proceedings. Ann Arbor, MI, Oct. 1972. p.935-949.
- PEREIRA, M.N.; NOVO, E.M.L. de M.; KURKDJIAN, M. de L.N. de O.; D'ALGE, J.C.L.; FLORENZANO, T.G. Atualização do uso da terra de São José dos Campos através de dados de sensoriamento remoto. São José dos Campos, INPE. Março, 1988. (INPE-4479-RPE/562).
- PIETIKAINEN, M.; ROSENFELD, A. Image segmentation by texture using piramid node linking. IEEE Transactions on Systems, Man and Cybernetics, SMC-11(12):822-825, Dec. 1981.

- ROSENFELD, A.; WANG, C.; WU, A.Y. Multispectral texture. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-12(1):79-84, Feb. 1982.
- SADOWSKI, F.G.; MALILA, W.A.; SARNO, J.E.; NALEPKA, R.F. The influence of multispectral scanner spatial resolution forest feature classification. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 11., Ann Arbor, MI, Apr. 1977. *Proceedings*. Ann Arbor, MI, 1977. p.1279-1288.
- STRAHLER, A.H.; WOODCOCK, C.E.; SMITH, J.A. On the nature of models in remote sensing. *Remote Sensing of Environment*, 20(2):121-139, Oct. 1986.
- TUCKER, C.J.; TOWNSHEND, J.R.G.; GOFF, T.E. African landcover classification using satellite data. *Science* 227(4685):369-375, Jan. 1985.
- UNSER, M. Sum and difference histograms for texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, PAMI-8(1):269-285, Jan. 1986.
- WESZKA, J.S.; DYER, C.R.; ROSENFELD, A. A comparative study of texture measures for terrain classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-6(4):269-285, Apr. 1976.
- WIERSMA, D.J.; LANDGREBE, D.A. The analytical design of spectral measurements for multispectral remote sensor systems. West Lafayette, IN, LARS, 1978. 256 p. (LARS Technical Report 122678).

WOODCOCK, C.E.; STRAHLER, A.H. The factor of scale in remote sensing. *Remote Sensing of Environment*, 21:311-332, Apr. 1987.