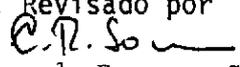


1. Classificação INPE-COM.4/RPE C.D.U.: 681.3.019	2. Período	4. Distribuição interna <input type="checkbox"/> externa <input checked="" type="checkbox"/>
3. Palavras Chaves (selecionadas pelo autor) PROCESSAMENTO DE IMAGENS ATRIBUTOS ESPACIAIS CLASSIFICAÇÃO MULTIESPECTRAL ANÁLISE DE TEXTURA		7. Revisado por  Celso de Renna e Souza
5. Relatório nº INPE-1885-RPE/229	6. Data Setembro, 1980	9. Autorizado por  Nelson de Jesus Parada Diretor
8. Título e Sub-Título EXTRAÇÃO DE ATRIBUTOS ESPACIAIS EM IMAGENS MULTIESPECTRAIS		11. Nº de cópias 05
10. Setor DSR/DSE Código		14. Nº de páginas 21
12. Autoria Luciano Vieira Dutra Nelson Delfino d'Ávila Mascarenhas		15. Preço
13. Assinatura Responsável 		
16. Sumário/Notas <p><i>Extração de atributos é um fator importante na determinação da precisão que se pode alcançar em tarefas de classificação de imagens multiespectrais. Os métodos tradicionais de classificação ponto a ponto não utilizam toda a informação disponível, pois desprezam o relacionamento espacial existente entre os pontos da imagem que pertencem a uma mesma classe. São desenvolvidos métodos para extração de atributos espaciais de imagem multiespectral através de filtragem linear e não-linear. Métodos de seleção de atributos são também utilizados porque restrições físicas, custos computacionais e disponibilidade de padrões de treinamento inviabilizam o uso de um grande número de atributos extraídos da imagem. O classificador usado supõe que essas características têm distribuição gaussiana, mas o uso de filtros não-lineares não garante a normalidade das características resultantes. Usam-se, pois, curvas de transferência não-lineares para tentar recuperar o caráter gaussiano dos atributos em questão. A análise do desempenho dos atributos espaciais em conjunto com atributos espectrais revelou que o uso da informação espacial melhora a precisão da classificação.</i></p>		
17. Observações Trabalho apresentado na 32ª Reunião Anual da SBPC, Rio de Janeiro, julho de 1980.		

ÍNDICE

ABSTRACT	<i>iv</i>
LISTA DE FIGURAS	<i>v</i>
LISTA DE TABELAS	<i>vi</i>
1. INTRODUÇÃO	1
2. A IMPORTÂNCIA DA ADEQUADA EXTRAÇÃO DE ATRIBUTOS	4
3. EXTRAÇÃO DE ATRIBUTOS ESPACIAIS POR FILTRAGENS	5
4. O ALGORITMO DE CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA	8
5. SELEÇÃO DE ATRIBUTOS	10
6. RESULTADOS	11
BIBLIOGRAFIA	17

ABSTRACT

Feature extraction is an important factor in determining the precision that can be attained on the classification of multispectral images. The traditional point-by-point classification methods do not use all the available information since they disregard the spatial relationship that exists among pixels belonging to the same class. Methods are developed to extract image spatial features by means of linear and non-linear filtering. Feature selection methods are also developed, since it is not possible to use all the generated features because physical restrictions, computational costs and availability of training patterns do not allow the manipulation of a large number of extracted image features. The classifier that is used assumes that the features have a gaussian distribution but the use of non-linear filters does not guarantee the normality of the resulting features. Therefore, non-linear transfer functions are employed as an attempt to restore the gaussian character of the involved features. The analysis of the performance of the spatial features in conjunction with the spectral ones demonstrated that the use of spatial information increases the precision of the classification.

LISTA DE FIGURAS

1.1 - Sistema de classificação de padrões	2
3.1 - Filtros passa-baixa. (a) média em uma região 3x3, (b) média em região 5x5, (c) filtro gaussiano passa-baixa	6
3.2 - Aproximações digitais do operador laplaciano $\nabla^2(\cdot) = \frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2}$	6
3.3 - Aproximação digital do operador bi-laplaciano $\frac{\partial^4}{\partial x^2 \partial y^2}$	7
3.4 - Curvas de transferências não lineares para uso posterior a filtragem linear. (a) módulo multiplicado por 2, (b) tipo raiz quadrada	7

LISTA DE TABELAS

6.1 - Classes de interesse	12
6.2 - Resultados das matrizes de classificação para as áreas de treinamento	14
6.3 - Resultados das matrizes de classificação para as áreas tes_ te	14

EXTRAÇÃO DE ATRIBUTOS ESPACIAIS EM IMAGENS MULTIESPECTRAIS

Luciano V. Dutra

Nelson D.A. Mascarenhas

Instituto de Pesquisas Espaciais

Conselho Nacional de Desenvolvimento Científico e Tecnológico - CNPq

Cx. Postal 515 - (12200) São José dos Campos, São Paulo, Brasil

1. INTRODUÇÃO

Desde o advento dos computadores digitais tem havido um constante esforço no sentido de desenvolver métodos automáticos de decisão em tarefas que, se efetuadas manualmente, seriam, muitas vezes, monótonas e repetitivas.

Estudos intensivos de problemas de classificação - ato de associar um objeto físico ou evento a uma dentre várias categorias ou classes especificadas - têm conduzido à formulação de muitos modelos matemáticos, que determinam a base teórica para o projeto de classificadores.

Como exemplo de problemas de classificação de padrões, podem-se citar: a previsão numérica de tempo, o diagnóstico automático pela análise de eletrocardiogramas e raios x, o reconhecimento de assinaturas, de impressões digitais etc.

O uso de satélites de recursos terrestres e das imagens por eles obtidas veio facilitar consideravelmente a tarefa de se analisar, com rapidez e economia, grandes áreas agrícolas, possibilitando o levantamento de dados, tais como áreas cultivadas por espécie e projeções de safras.

Os métodos de partição das imagens multiespectrais em re

giões, associando a cada região uma classe ou cultura, foram desenvolvidos com base na teoria estabelecida para a resolução dos problemas gerais de classificação de padrões.

Um sistema básico de classificação de padrões pode ser decomposto em 3 partes: o transdutor, o extrator de atributos e o classificador (Figura 1.1)

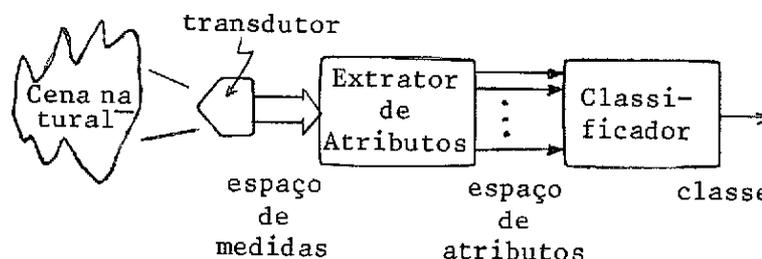


Fig. 1.1 - Sistema de classificação de padrões

O *transdutor* recebe a radiação que chega do objeto natural, em todos os comprimentos de onda, mas capta apenas a informação contida em algumas bandas estreitas no espectro de frequência. Normalmente, essas bandas estão localizadas desde o visível ao infravermelho. Essa informação, chamada "espectral", é digitalizada tanto espacialmente, quanto em intensidade (o nível de cinza, ou seja, o valor medido para a radiação em determinada banda só pode assumir valores inteiros).

Obtêm-se, assim, para representar uma determinada cena natural, uma matriz de pontos, onde cada ponto é na realidade um vetor, cujos componentes são os valores das "cores" espectrais, que o transdutor adquiriu para a pequena área correspondente à resolução do mesmo.

Chama-se a essa matriz de *imagem multiespectral*. A cada um dos componentes dos vetores chama-se *canal*. Cada ponto da imagem é chamado de um "*pixel*".

É conveniente lembrar que as M medidas obtidas pelo transdutor, assumidas contínuas, definem um ponto em um espaço euclidiano M -dimensional, chamado *espaço de medidas*.

Conforme os objetos que se quer classificar, o conjunto de medidas espectrais adquiridas pode não ser o mais conveniente para distinguir as classes de interesse. O *extrator de atributos* se encarrega de transformar os dados de medida para outra forma mais adequada, de acordo com as classes envolvidas.

Algumas vezes basta selecionar, dentre as M medidas oferecidas pelo transdutor, um conjunto menor de medidas que minimize a probabilidade de erro, considerando todos os subconjuntos com o mesmo número de componentes que se quer reduzir. Esse processo pertence à classe de algoritmos desenvolvidos para resolver problemas de *seleção de atributos*.

O *classificador* associa o objeto à uma classe, de acordo com as atributos apresentados. Ele toma, portanto, uma decisão baseada nas evidências (atributos) apresentadas.

Podem-se dividir os algoritmos de classificação em 2 tipos: estatístico e determinístico. Como os nomes indicam, o primeiro tipo sugere que se considere os atributos dos objetos como tendo um comportamento estatístico (caracterizado por distribuições de probabilidade); o segundo, supõe que os atributos possam ser descritos por funções determinísticas.

Alguns algoritmos de classificação necessitam de uma fase anterior à sua operação, denominada *fase de treinamento*, na qual o sistema determina, a partir de padrões pré-selecionados, as características das classes a serem usadas como termo de comparação em tempo de classificação. Neste caso, o operador do sistema determina quais as possíveis decisões que o sistema pode tomar. O método de classificação que se utiliza da *fase de treinamento* é chamado de *classificação supervisionada*.

Outros algoritmos de classificação não necessitam de uma fase de treinamento, pois o classificador visa dividir ele próprio a massa de dados, procurando estruturas internas a essa, agrupando dados semelhantes segundo determinados critérios de similaridade ou afinidade. Neste caso, o operador do sistema não determina quais as possíveis decisões a serem tomadas, e, normalmente, o operador não sabe quais as classes que resultarão nem quantas serão. É necessário, portanto, um trabalho posterior de interpretação do resultado. Esta classificação é chamada *não-supervisionada*.

2. A IMPORTÂNCIA DA ADEQUADA EXTRAÇÃO DE ATRIBUTOS

Um dos principais problemas no projeto de sistemas de classificação é a escolha, ou, dependendo do caso, a extração de atributos que sejam os melhores para distinguir as classes de interesse.

Vários processos de extração e seleção de atributos têm sido estudados, e a literatura no campo é vasta. Apresentam-se, no final, apenas algumas referências a respeito do assunto.

O número de padrões disponíveis para treinamento e/ou o custo computacional dos algoritmos podem requerer que se reduza a dimensionalidade dos vetores de atributos para uso no classificador. Para isso, podem-se utilizar técnicas conhecidas como *seleção de atributos*, seja por simples escolha de algumas das medidas disponíveis, seja por processos mais complexos como a chamada *rotação espectral*, por meio da qual é feita uma transformação sobre o espaço de medidas, de maneira que o novo espaço de atributos gerado possa dispor de qualidades desejáveis, tais como, os eixos não serem correlacionados, e a informação se concentrar em algumas determinadas componentes do novo espaço. Uma transformação que apresenta essas qualidades é a chamada Karhunen-Loève.

Os sistemas de classificação mais comuns utilizam os atributos gerados segundo os processos descritos acima. Desta maneira, despreza-se a informação chamada *espacial* de cada uma das imagens componentes da imagem multiespectral já que cada "pixel", representado pelo seu

vetor, é classificado independentemente dos seus vizinhos. A informação espacial é determinada por relações existentes entre "pixels" vizinhos.

Em muitos casos, a separação de certas classes só é possível quando se leva em consideração a "textura" da imagem. O problema importante, no entanto, é como definir o que seria "textura". Não existe, ainda, uma definição formal de textura universalmente aceita, mas várias tentativas têm sido apresentadas (Haralick, 1979).

Uma das formas de extração de atributos espaciais é a da utilização de filtros espaciais, já que o conteúdo de frequência de uma imagem é uma forma de expressão do relacionamento espacial entre "pixels", e os filtros podem ressaltar um ou outro aspecto desse relacionamento.

O presente trabalho baseia-se na utilização de certos filtros lineares e não-lineares para a extração de atributos espaciais da imagem.

Utilizando-se filtros, no entanto, é possível a produção de um grande número de atributos do tipo espacial. Neste caso, será necessário selecionar atributos para que se possa diminuir os custos computacionais, e garantir uma boa estimativa dos parâmetros necessários à classificação.

3. EXTRAÇÃO DE ATRIBUTOS ESPACIAIS POR FILTRAGENS

Filtros são operadores, lineares ou não, que podem ressaltar o conteúdo de certas faixas de frequência de uma imagem, sendo utilizados também para detecção de bordas, linhas ou manchas.

No caso de filtragem linear, e em aplicação para a extração de atributos, a imagem resultado é obtida do original pela convolução, desta, com diversos filtros *curtos* (poucos pontos) chamados *máscaras*, ou seja:

$$[r(i,j)] = [h(i,j)] * [f(i,j)] \quad (3.1)$$

onde

$[r(i,j)]$ - imagem resultado

$[h(i,j)]$ - máscara

$[f(i,j)]$ - imagem original

* - denota convolução

A Figura 3.1 apresenta algumas máscaras possíveis para a realização de filtragem "passa-baixa".

$$\begin{array}{ccc} \frac{1}{9} \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} & \frac{1}{25} \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix} & \frac{1}{15} \begin{bmatrix} 1 & 2 & 1 \\ 2 & 3 & 2 \\ 1 & 2 & 1 \end{bmatrix} \\ \text{(a)} & \text{(b)} & \text{(c)} \end{array}$$

Fig. 3.1 - Filtros passa-baixa. (a) média em uma região 3x3, (b) média em região 5x5, (c) filtro gaussiano passa-baixa.

As Figuras 3.2 e 3.3 apresentam máscaras que são aproximações dos operadores derivativos laplaciano e bi-laplaciano. Tais filtros reforçam o conteúdo de alta frequência da imagem.

$$\begin{array}{ccc} \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} & \begin{bmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{bmatrix} \\ \text{(a)} & \text{(b)} \end{array}$$

Fig. 3.2 - Aproximações digitais do operador laplaciano $\nabla^2(\cdot) = \frac{\partial^2}{\partial x^2} + \frac{\partial^2}{\partial y^2}$

$$\begin{bmatrix} 1 & -2 & 1 \\ -2 & 4 & -2 \\ 1 & -2 & 1 \end{bmatrix}$$

Fig. 3.3 - Aproximação digital do operador bi-laplaciano,

$$\frac{\partial^4}{\partial x^2 \partial y^2} .$$

Os filtros não-lineares são, normalmente, realizados por processos em 2 estágios: primeiro, uma convolução linear, e, em seguida, uma operação pontual como, por exemplo, módulo ou função de transferência não linear. A Figura 3.4 apresenta 2 (duas) funções de transferência, normalmente utilizadas neste trabalho, para uso subsequente à filtragem por laplaciano.

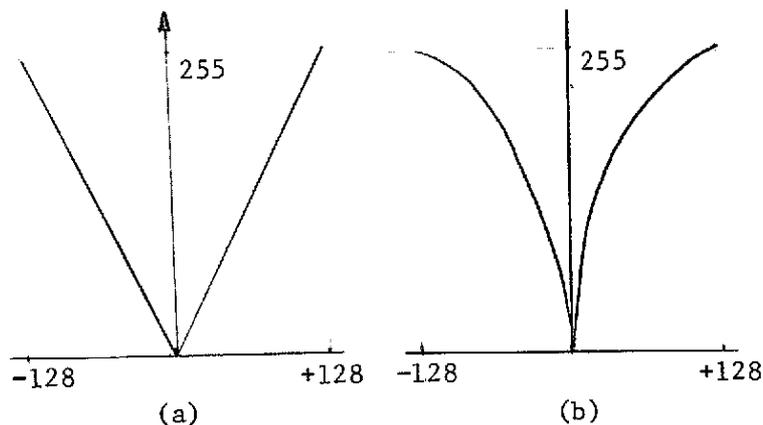


Fig. 3.4 - Curvas de transferências não lineares para uso posterior à filtragem linear. (a) módulo multiplicado por 2, (b) tipo raiz quadrada.

Panda (1977) prova, para o caso contínuo, que o operador módulo do laplaciano ($|\nabla^2(\cdot)|$) decorrelaciona o campo imagem, ou seja, o campo aleatório resultado da operação $|\nabla^2(\cdot)|$ tem função autocorrelação impulsiva. Essa propriedade indica que o campo resultante não tem informação espacial, e sugere que, pelo menos, parte da informação espacial, contida na imagem original, foi transformada em informação pontual na imagem resultado. Além disso, é mais adequada a utilização de campos decorrelacionados em classificadores pontuais, como se verá a seguir.

O uso da função de transferência tipo raiz quadrada visa redistribuir os níveis de cinza resultantes da operação $|\sqrt{(\cdot)}|$, visto que a maior parte desses valores se concentra na região dos níveis baixos.

Define-se, também, um operador heurístico chamado "variação", cuja saída é proporcional à rugosidade do relevo em uma pequena região 3x3. Considerando-se uma vizinhança 3x3 de um ponto, podem-se rotular os pontos dessa vizinhança segundo a convenção:

a b c
d x e
f g h

A função denominada variação (Schachter et al., 1979) é a soma da variação vertical com a variação horizontal. Assim:

$$VTV = |a-d| + |d-f| + |b-x| + |x-g| + |c-e| + |e-h| \quad (3.1)$$

$$HTV = |a-b| + |b-c| + |d-x| + |x-e| + |f-g| + |g-h| \quad (3.2)$$

$$\text{Variação total} = V.T. = VTV + HTV \quad (3.3)$$

4. O ALGORITMO DE CLASSIFICAÇÃO POR MÁXIMA VEROSSIMILHANÇA

O método escolhido neste algoritmo, para a classificação, é o do tipo estatístico paramétrico. Supõe-se que o comportamento das classes envolvidas pode ser descrito por funções densidade de probabilidade gaussianas.

A classificação se faz ponto a ponto, ou seja, supõe-se que cada "pixel" é não correlacionado com o vizinho, porque a classe a ser associada ao "pixel" não depende dos vetores representativos dos "pixels" vizinhos. Em alguns algoritmos de classificação, chamados de *decisão composta*, a classe do ponto não vai depender somente do vetor que o representa, mas, também, dos valores dos "pixels" vizinhos, intro

duzindo, assim, a informação espacial como elemento a influenciar a decisão. No caso do presente trabalho, embora a classificação seja feita ponto a ponto, uma ou mais das dimensões do vetor que representa o "pixel" é proporcional a algum tipo de informação espacial em torno desse ponto. A segunda maneira oferece, no entanto, uma eficiência computacional muito maior.

O algoritmo de classificação chamado de decisão por máxima verossimilhança pode ser descrito, resumidamente (Velasco et al., 1978): decide-se que um padrão \vec{x} pertence à classe ω_i se uma função $g_i(\vec{x})$, chamada função discriminante para a classe i , satisfizer às seguintes condições:

$$g_i(\vec{x}) > g_j(\vec{x}) \quad i \neq j \quad i, j = 1, 2, \dots, M, \text{ onde } M \text{ é o número de classes} \quad (4.1)$$

$$g_i(\vec{x}) > T_i \quad \text{onde } T_i \text{ é o limiar para a classe } i.$$

A função discriminante, para o caso gaussiano, é dada por

$$g_i(\vec{x}) = \ln P(\omega_i) - \frac{1}{2} \ln |\Sigma_i| - \frac{1}{2} (\vec{x} - \vec{\mu}_i)^T \Sigma_i^{-1} (\vec{x} - \vec{\mu}_i) \quad (4.2)$$

onde μ_i é o vetor de média para classe i e Σ_i é a matriz de covariância para a classe i .

A avaliação do classificador é feita classificando-se, novamente, as próprias áreas de treinamento utilizadas para estimar os parâmetros de cada classe, e também classificando-se outras áreas, que não de treinamento, mas que têm classificação conhecida "a priori", chamadas áreas teste.

Os erros que o classificador vai cometer ao categorizar pontos de identidade conhecida, darão uma idéia da probabilidade de erro envolvida no processo.

5. SELEÇÃO DE ATRIBUTOS

Como foi apresentado nas seções 1 e 2, os processos de extração de atributos, tendem a multiplicar demasiadamente o número deles, prejudicando, assim, a eficiência computacional e tornando mais crítica a estimativa dos parâmetros necessários, por exigir um número maior de pontos na área de treinamento.

Como foi indicado nessas seções, pode-se simplesmente escolher alguns canais ou usar métodos mais complexos, como o da rotação espectral. Analisar-se-á, com brevidade, como escolher N canais dos M disponíveis, depois de um processo de extração de atributos.

O critério natural, para a escolha do subconjunto com N elementos, é o da minimização da probabilidade de erro. Acontece que a aplicação direta desse critério envolve custos computacionais elevados. Optou-se, portanto, pela utilização de uma classe de funções, que indicam a "distância normalizada" entre funções densidade de probabilidade. Quanto maior a distância entre funções, menor a probabilidade de erro envolvida entre as classes.

Utilizar-se-á, neste trabalho, a chamada "Distância de Bhattacharyya" (Distância-B) e sua relacionada "Distância Jeffreys-Matusita" (Distância JM).

A distância-B é dada por

$$B = - \ln \rho \quad (5.1)$$

onde ρ é o coeficiente de Bhattacharyya, dado por:

$$\rho = \int (P(\vec{x}/\omega_1) P(\vec{x}/\omega_2))^{1/2} dx \quad (5.2)$$

A distância JM é dada por:

$$d_{JM}^2 = 2(1-\rho) \quad (5.3)$$

É possível derivar limitantes superiores e inferiores da probabilidade de erro, em função do coeficiente de Bhattacharyya (Chen, 1973).

$$\frac{1}{4} \rho^2 \leq P(\omega_1)P(\omega_2) \rho^2 \leq \frac{1}{2} (1 - \sqrt{1 - 4P_1P_2\rho^2}) \leq P_E \leq \sqrt{P_1P_2} \rho \leq \frac{1}{2} \rho \quad (5.4)$$

Para densidades gaussianas, a distância B é dada por

$$B = \frac{1}{8} (\vec{\mu}_1 - \vec{\mu}_2)^T \left(\frac{\Sigma_1 + \Sigma_2}{2} \right) (\vec{\mu}_1 - \vec{\mu}_2) + \frac{1}{2} \ln \left\{ \frac{|\frac{1}{2}(\Sigma_1 + \Sigma_2)|}{|\Sigma_1|^{1/2} |\Sigma_2|^{1/2}} \right\} \quad (5.5)$$

onde: $\vec{\mu}_1$ e $\vec{\mu}_2$ são vetores médias, e

Σ_1 e Σ_2 são matrizes de covariância para as classes 1 e 2.

6. RESULTADOS

O primeiro experimento foi efetuado com uma imagem do satélite LANDSAT, sobre a área de Ribeirão Preto, órbita 178 ponto 27, de abril de 1978.

Utilizam-se doze atributos, que foram os seguintes:

- para os canais de 1 a 4, foram utilizados os canais originais de 4 a 7 do LANDSAT;
- os canais de 5 a 8 foram obtidos da seguinte maneira: cada canal original de 4 a 7 do LANDSAT foi processado pelo filtro laplaciano da Figura 3.2b; reescalado pela curva tipo raiz quadrada da Figura 3.4b e, em seguida, cada canal resultante foi suavizado pela máscara da Figura 3.1b;
- os canais de 9 a 12 foram obtidos dos originais pela filtragem através da máscara da Figura 3.1b (suavização).

Obteve-se, assim, 12 canais para se escolher quatro, que é a capacidade máxima de manipulação do imageador automático I-100, do

Laboratório de Interpretação Automática do INPE, em São José dos Campos.

Os canais escolhidos, pelo critério do subconjunto com máxima distância JM média, e do subconjunto de canais com máxima distância JM mínima entre os pares de canais, foram os mesmos, que são:

- 6 - laplaciano suavizado do canal 5 do LANDSAT;
- 9 - média 5x5 do canal 4 do LANDSAT;
- 10 - média 5x5 do canal 5 do LANDSAT;
- 12 - média 5x5 do canal 7 do LANDSAT.

As classes usadas são mostradas na Tabela 6.1.

TABELA 6.1

CLASSES DE INTERESSE

	Classe	Número de pontos-área de treinamento	número de pontos - áreas teste
1	cana	252.	108.
2	cana nova	216	108.
3	pasto	108.	72.
4	água	72.	36.
5	infraestrutura	72.	36.
6	mata	72.	36.

O segundo experimento foi efetuado para a mesma imagem do experimento anterior. Extraíram-se também mais 8 atributos, além dos 4 originais.

Os canais de 1 a 4 e de 9 a 12 são os mesmos anteriores. Os atributos de 5 a 8 foram agora obtidos pelo filtro de variação (equação 3.3), aplicado a cada canal original. Em seguida, cada um deles foi suavizado, realizando-se uma média, como indica a Figura 3.1b.

Obteve-se, da mesma forma, outros 12 canais, dos quais se escolheu quatro, pelos mesmos critérios do experimento anterior. Também, nesse caso, o subconjunto escolhido é o mesmo, considerando-se os 2 critérios disponíveis.

Os canais escolhidos foram:

- 7 - variação do canal 6, suavizada pelo filtro de média da Figura 3.1b;
- 9 - média 5x5 do canal 4;
- 10 - média 5x5 do canal 5;
- 11 - média 5x5 do canal 7.

Para comprovar a eficiência do método, foram obtidas as matrizes de classificação das áreas de treinamento (essas matrizes apresentam, de forma sucinta, o resultado da classificação das áreas de identificação conhecida - áreas de treinamento - quando é aplicado a essas áreas, o algoritmo de classificação com os parâmetros obtidos a partir delas. Os erros cometidos ao classificar incorretamente pontos de identidade conhecida permitem estimar os erros envolvidos) e também as matrizes de classificação para áreas teste (áreas de identidade conhecida, mas que não foram usadas na extração dos parâmetros para a classificação).

A partir dessas matrizes foi possível obter o "desempenho médio", definido como a média das percentagens de classificação correta de cada área de treinamento, ponderada pelo número de pontos de cada uma. A "abstenção média" foi definida como sendo a percentagem média de abstenção das áreas de treinamento, ponderada pelo número de pontos

de cada área. A "confusão média" foi definida como sendo o erro médio ponderado de classificação das áreas.

As Tabelas 6.2 e 6.3 apresentam, para as áreas de treinamento e teste, os valores obtidos para o desempenho médio, confusão média e abstenção média, considerando os canais originais e os escolhidos pelos 2 (dois) experimentos, com limiar igual a 5 para a classificação.

TABELA 6.2

RESULTADOS DAS MATRIZES DE CLASSIFICAÇÃO PARA
AS ÁREAS DE TREINAMENTO

	canais originais	canais escolhidos 1a. experiência	canais escolhidos 2a. experiência
desempenho médio (D_m)	94.8%	99.5%	98.7%
confusão média (C_m)	4.8%	0.1%	0.0%
abstenção média (A_m)	0.4%	0.4%	1.3%

TABELA 6.3

RESULTADOS DAS MATRIZES DE CLASSIFICAÇÃO PARA
AS ÁREAS TESTE

	canais originais	canais escolhidos 1a. experiência	canais escolhidos 2a. experiência
D_m	77.8%	80.3%	89.4%
C_m	17.4%	3.3%	1.0%
A_m	4.8%	16.4%	9.6%

Os resultados demonstram uma boa melhoria no desempenho médio, e sensível diminuição na confusão média, pelo uso dos atributos espaciais.

Na maioria dos casos, porém, a abstenção média aumentou, resultado que não é tão nocivo quanto a classificação errônea. Isso indica que o poder discriminatório do algoritmo de classificação, com base nos novos canais, aumentou, ou seja, a classificação ficou mais aguda em virtude das variâncias em jogo terem diminuído.

Observando-se diretamente as matrizes de classificação dos novos canais, notou-se que, nos casos em que as áreas de treinamento estavam localizadas próximas às fronteiras entre diferentes regiões, a percentagem de classificação correta diminuiu. Isto se deve ao efeito de "borramento", ou difusão, que ocorre nas fronteiras entre regiões, quando se usa operadores lineares como as médias.

O campo classificado mostrou ser mais homogêneo, e menos ruidoso do que no caso em que se usou os canais originais; as fronteiras entre regiões não foram classificadas, indicando que o método desenvolvido permitiu detetar melhor as regiões de classificação normalmente confusas, como é o caso das regiões de transição entre campos de diferentes texturas, e não classificá-las, ao invés de classificá-las erradamente.

Novos testes serão efetuados, com outros operadores, para extrair atributos de relevo. Pode-se estudar também a utilização de operadores de suavização, ou passa-baixa, não-lineares, de maneira a evitar o efeito de borramento das fronteiras. Estudos mais profundos devem ser feitos para analisar o problema dos erros de classificação na fronteira entre regiões.

A rotação espectral poderá ser usada também como pré-processamento, antes das extrações de atributos espaciais. Os resultados preliminares, no entanto, demonstram que o método pode ser útil na resolução de vários problemas de sensoriamento remoto.

BIBLIOGRAFIA

CHEN, C.H. *Statistical pattern recognition*. Rochelle Park, N.J., Spartan Books, 1973.

HARALICK, R.M. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5): 786-804, May 1979 (survey).

PANDA, D.P. *Statistical analysis of some edge operators*. Maryland, M.D., University of Maryland, 1977. (Techn. Report n^o 558)

PICKETT, R.M. Visual analysis of texture in the detection and recognition of objects. In: LIPKIN, B.S.; ROSENFELD, A., ed. *Picture Processing and Psychopictories*, New York, N.Y., Academic Press, 1970. pp. 289-308.

SCHACHTER, B.J.; DAVIS, L.S.; ROSENFELD, A. Some experiments in image segmentation by clustering of local features values. *Pattern Recognition*, 11(1): 19-28, 1979.

VELASCO, F.R.D.; PRADO, L.O.C.; SOUZA, R.C.M. *Sistema MAXVER: manual do usuário*. São José dos Campos, INPE, jul. 1978. (INPE-1315-NTI/110)